

基于 SDNSR-Net 深度网络的大规模 MIMO 信号检测算法 *

曾相誌,申 滨,阳 建

(重庆邮电大学 通信与信息工程学院,重庆 400065)

摘要: 大规模多输入多输出(MIMO)系统能有效地提高频谱效率,当天线规模渐进趋向于无穷时,最小均方误差(MMSE)检测算法能达到接近最优的检测性能。然而由于算法中存在矩阵求逆的步骤,带来极高的计算复杂度,在大规模 MIMO 系统中难以实现。理查森(Richardson)算法能够在不对矩阵求逆的情况下,以迭代的形式达到 MMSE 算法的检测性能,但该算法受其松弛参数影响较大。在结合最陡梯度下降算法的 Richardson 算法(SDNSR)中,松弛参数的误差可由梯度下降算法弥补,却提高了计算复杂度。首先通过深度展开的思想,将 SDNSR 的迭代过程映射为深度检测网络(SDNSR-Net);然后,通过修改网络结构及添加可训练参数来降低计算复杂度并提高检测精度。实验结果表明,在上行链路大规模 MIMO 系统中不同信噪比和天线配置的情况下,SDNSR-Net 都优于其他典型的检测算法,可作为实际中有效的待选检测方案。

关键词: 大规模 MIMO 系统;信号检测;模型驱动;深度学习

中图分类号: TN925

文献标识码: A

DOI:10.16157/j.issn.0258-7998.222520

中文引用格式: 曾相誌,申滨,阳建. 基于 SDNSR-Net 深度网络的大规模 MIMO 信号检测算法[J]. 电子技术应用, 2022, 48(11): 84–88.

英文引用格式: Zeng Xiangzhi, Shen Bin, Yang Jian. Signal detection based on SDNSR-Net deep network for massive MIMO systems[J]. Application of Electronic Technique, 2022, 48(11): 84–88.

Signal detection based on SDNSR-Net deep network for massive MIMO systems

Zeng Xiangzhi, Shen Bin, Yang Jian

(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications,
Chongqing 400065, China)

Abstract: Massive multiple-input multiple-output(MIMO) systems can effectively improve the spectrum efficiency. When the antenna scale gradually tends to infinity, the minimum mean square error (MMSE) detection algorithm can achieve near-optimal detection performance. However, due to the matrix inversion required in the algorithm, which brings extremely high computational complexity, it is difficult to implement in a massive MIMO system. The Richardson algorithm can achieve the detection performance of the MMSE algorithm in an iterative form without matrix inversion, but the algorithm is greatly affected by its relaxation parameters. In the Richardson algorithm combined with the steepest gradient descent algorithm (SDNSR), the error of the relaxation parameter can be compensated by the gradient descent algorithm, but the computational complexity is increased. This paper firstly uses the idea of deep expansion to map the iterative process of SDNSR to a deep detection network (SDNSR-Net); then, by modifying the network structure and adding trainable parameters, the computational complexity is reduced and the detection accuracy is improved. The experimental results show that SDNSR-Net is superior to other typical detection algorithms in the case of different signal-to-noise ratios and antenna configurations in the uplink massive MIMO system and can be used as an effective detection scheme in practice.

Key words: massive MIMO system; signal detection; modern driven; deep learning

0 引言

大规模 MIMO 系统中存在信道硬化现象,即由信道矩阵生成的 Gram 矩阵的对角项远大于非对角项。在该情况下最小均方误差(Minimum Mean Square Error, MMSE)检测算法已证明可以达到次优的检测性能^[1]。然而该算

法中存在矩阵求逆运算,因此难以适用于大规模 MIMO 系统。

为降低线性检测算法的计算复杂度,出现了 Richardson 迭代^[2]、Jacobi 迭代^[3]和逐次超松弛(Successive Over Relaxation, SOR)迭代^[4]等迭代检测算法。然而,在大规模 MIMO 系统中,随着用户增加,该类算法的检测性能退化严重。

* 基金项目:国家自然科学基金(62071078)

深度学习技术作为一种流行的人工智能技术,目前已开始应用于解决信号检测的问题。例如:Ye^[5]等人提出利用深度神经网络进行OFDM系统的信道估计和信号检测;Samuel^[6]等人提出的DetNet通过将投影梯度下降算法的迭代过程展开为网络,从而获得了良好的检测性能;He^[7]等人提出了OAMPNet,在传统的OAMP检测算法的基础上增加了一些可优化参数,在不增加额外复杂度的同时获得了更好的检测性能。

受上述基于深度学习的相关工作的启发,本文在改进的Richardson迭代算法^[8](Steepest Descent and Non Stationary Richardson, SDNSR)的基础上提出一种基于深度学习的大规模MIMO信号检测器。该检测器为一个模型驱动的深度学习网络,称为SDNSR-Net。仿真结果表明,该检测网络能够有效提高原算法的检测性能。

1 系统模型

考虑一个有 N_r 根接收天线的基站同时服务于 N_t 个单天线用户的上行链路的大规模MIMO系统。接收矢量可以表示为 $\bar{y}=[\bar{y}_1, \bar{y}_2, \dots, \bar{y}_{N_r}]^T \in \mathbb{C}^{N_r \times 1}$:

$$\bar{y} = \bar{H}\bar{x} + \bar{n} \quad (1)$$

其中, $\bar{x}=[\bar{x}_1, \bar{x}_2, \dots, \bar{x}_{N_t}]^T \in \mathbb{C}^{N_t \times 1}$ 为发送信号矢量, \bar{x}_i 为第*i*个用户的发射信号,其值从调制星座符号集 $\Omega \subset \mathbb{C}$ 中随机选取; $\bar{n} \in \mathbb{C}^{N_r \times 1}$ 为均值为0、方差为 σ^2 的加性高斯白噪声; $\bar{H}=[\bar{h}_1, \bar{h}_2, \dots, \bar{h}_{N_t}] \in \mathbb{C}^{N_r \times N_t}$ 为信道矩阵,其各元素互相独立且服从高斯分布。

为了方便计算和加快深度学习处理速度,一般不直接处理复数域信号,而是使用等价的实数域信号。实数域信号是由对应复数域信号的实部和虚部拼接而成的,如下所示:

$$y = \begin{bmatrix} \Re(\bar{y}) \\ \Im(\bar{y}) \end{bmatrix} \in \mathbb{R}^{2N_r \times 1} \quad (2)$$

$$x = \begin{bmatrix} \Re(\bar{x}) \\ \Im(\bar{x}) \end{bmatrix} \in \mathbb{R}^{2N_t \times 1} \quad (3)$$

$$n = \begin{bmatrix} \Re(\bar{n}) \\ \Im(\bar{n}) \end{bmatrix} \in \mathbb{R}^{2N_r \times 1} \quad (4)$$

$$H = \begin{bmatrix} \Re(\bar{H}) & -\Im(\bar{H}) \\ \Im(\bar{H}) & \Re(\bar{H}) \end{bmatrix} \in \mathbb{R}^{2N_r \times 2N_t} \quad (5)$$

其中, $\Re(\cdot)$ 和 $\Im(\cdot)$ 分别表示复数域信号的实部和虚部。

2 SDNSR 检测算法

Richardson检测算法^[9]的迭代形式如下:

$$\tilde{x}_{i+1} = \tilde{x}_i + \omega(b - A\tilde{x}_i), i=0, 1, 2, \dots, T \quad (6)$$

其中, $A = H^T H + \sigma^2 I$, $b = H^T y$;*i*和*T*分别为当前迭代次数和总迭代次数; ω 为松弛此参数,当且仅当松弛参数取值范围为 $0 < \omega < 2/\lambda_{\max}$ 时,该算法收敛, λ_{\max} 是*A*的最大特征值^[10]。Richardson算法的检测性能受松弛参数影响较大。松弛参数值的确定没有特定的规则,常用的做法是在不同条件下根据过往经验进行选择,但往往存在误差。

SDNSR检测算法将最陡下降(Steepest Descent, SD)算法^[11]与Richardson算法的迭代过程进行结合,在每次迭代中通过SD算法来补偿Richardson算法中松弛参数值的误差。SD算法的迭代过程如下:

$$\tilde{x}_i^{\text{SD}} = \tilde{x}_{i-1} + \mu_i r_i \quad (7)$$

其中, \tilde{x}_{i-1} 为SDNSR检测算法中第*i*-1次迭代的检测值, $r_i = b - A\tilde{x}_i$ 为第*i*次迭代的残余误差向量, μ_i 为步长参数,计算公式如下:

$$p_i = A r_i \quad (8)$$

$$\mu_i = \frac{r_i^T r_i}{p_i^T p_i} \quad (9)$$

将SD算法的检测结果作为Richardson算法的输入形成SDNSR算法的一次迭代过程,如下所示:

$$\tilde{x}_i = \tilde{x}_{i-1}^{\text{SD}} + \omega_i(b - A\tilde{x}_{i-1}^{\text{SD}}) = \tilde{x}_{i-1} + (\mu_i + \omega_i)r_i - \mu_i\omega_i p_i \quad (10)$$

3 SDNSR-Net 检测网络

3.1 SDNSR-Net 网络结构

SDNSR-Net网络结构的设计参考了模型驱动深度学习的思想,在传统的SDNSR检测算法的基础上,利用深度展开策略进行网络结构的设计。

图1给出了SDNSR-Net的完整检测流程,它包含*L*+1个级联层。第0层为预处理器,它的作用是处理接收信号 y 和信道状态信息 H ,生成后续检测网络所需要的初始信号。由于残差向量 r_0 和 p_0 在预处理器中没有具体的实际意义,因此都初始化为零向量。 \tilde{x}_0 的值一般的做法是初始化为零向量,为了加快网络收敛速度, \tilde{x}_0 的初始值可设置为 $\omega=2/\lambda_{\max}+\lambda_{\min}$ 。

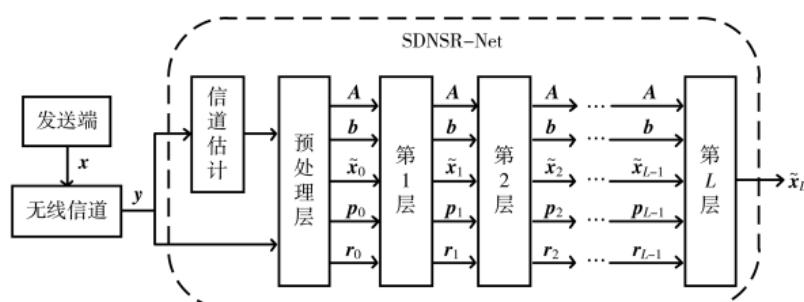


图1 SDNSR-Net 总体框架图

剩余的*L*层是根据SDNSR算法构建的SDNSR-Net检测网络,图2展示了SDNSR-Net第*i*层的标准结构,SDNSR-Net包含*L*个级联层,且每个层都有相同结构。从图中可以看出SDNSR-Net在第*i*层的输入为 r_{i-1}, p_{i-1}

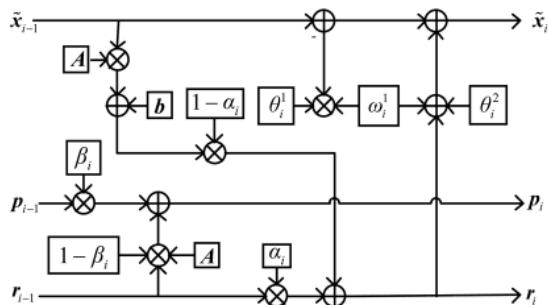


图 2 SDNSR-Net 标准结构图

和 \tilde{x}_{i-1} , 输出为 r_i 、 p_i 和 \tilde{x}_i 。在第 L 层输出发送信号 x 的检测值 \tilde{x}_L 。

SDNSR 算法的迭代表达式式(10)中 $b - A\tilde{x}_i^{\text{SD}}$ 为主要的残余误差向量, 主要包含 r_i 和 p_i 两部分。实际上 \tilde{x}_i 的取值不仅与当前层的残差向量相关, 还与迭代中前层的残差向量的有关。因此在 r_i 和 p_i 计算中考虑加入迭代中前面各层残差向量的影响:

$$r_i = \alpha_i(b - A\tilde{x}_{i-1}) + \alpha_{i-1}r_{i-1} + \alpha_{i-2}r_{i-2} + \cdots + \alpha_0r_0 \quad (11)$$

$$p_i = \beta_i Ar_i + \beta_{i-1}p_{i-1} + \beta_{i-2}p_{i-2} + \cdots + \beta_0p_0 \quad (12)$$

其中, $\alpha_i, \alpha_{i-1}, \dots, \alpha_0$ 和 $\beta_i, \beta_{i-1}, \dots, \beta_0$ 是可以通过深度学习进行优化的可训练参数。由于相邻层的残差向量造成的影响最大, 因此为了简化网络, 只考虑相邻层的影响, 同时引入阻尼机制^[12], 进一步增加网络的收敛性能, 简化后的公式如下:

$$r_i = (1 - \alpha_i)(b - A\tilde{x}_{i-1}) + \alpha_i r_{i-1} \quad (13)$$

$$p_i = (1 - \beta_i)Ar_i + \beta_i p_{i-1} \quad (14)$$

其中, α_i 和 β_i 是可学习的参数。对于训练过程中 α_i 和 β_i 的初始值的设置, 若其值过大, 则未充分考虑前层检测网络的残余误差的影响; 而过小, 则前层检测网络的残余误差占比过大, 忽略了本层残余误差向量的影响, 因此出于均衡的考虑, 设置为 0.5。

式(9)为 SD 算法中计算步长参数的表达式, 式中涉及两次高阶向量之间的乘法以及一次除法操作。由于每一次迭代中都需要进行一次计算, 因此这在大规模的 MIMO 系统的检测算法中是一个较大的计算开销。在 SDNSR-Net 中并未使用式(9)来计算步长参数, 而是将步长设置为可学习参数, 并通过标准的深度学习技术去训练网络从而得到最优的步长参数, 从而完成检测任务, 如下所示:

$$\tilde{x}_i = \tilde{x}_{i-1} + (\theta_i^1 + \omega_i)r_{i-1} + \theta_i^2\omega_i p_{i-1} \quad (15)$$

其中, θ_i^1 和 θ_i^2 为替代步长 μ_i 的可训练参数。

为保证 SD 算法在训练之初不会因步长参数设置不当, 从而对 Richardson 算法造成影响, 因此 θ_i^1 和 θ_i^2 的初始值都设置 0。将 θ_i^1 和 θ_i^2 的初始值带入式(7)中可得到

SDNSR-Net 中 \tilde{x}_i 的初始更新公式:

$$\tilde{x}_i = \tilde{x}_{i-1} + \omega_i r_{i-1} = \tilde{x}_{i-1} + \omega_i(b - A\tilde{x}_{i-1}) \quad (16)$$

可以看出 SDNSR-Net 训练之初 \tilde{x}_i 的更新过程恰好是 Richardson 算法的迭代更新公式。因此, 本 SDNSR-Net 中最开始为 Richardson 算法, 而 SD 算法对特征值误差的补偿是通过检测网络对 θ_i^1 和 θ_i^2 的学习进行的。

3.2 损失函数

选择合适的损失函数对于 SDNSR-Net 的训练过程尤为重要, 一种常见的做法是使用 SDNSR-Net 输出的检测信号 \tilde{x}_L 和实际信号 x 的均方误差作为网络的损失函数。但是该方法只考虑到了最后一层的输出 \tilde{x}_L 的影响, 而实际上网络的每一层的输出都会对 SDNSR-Net 的检测性能造成影响, 因此损失函数应该考虑网络的所有输出:

$$\mathcal{L}(x, \tilde{x}_\Theta(H, y)) = \frac{1}{L} \sum_{i=1}^L \|x - \tilde{x}_i\|^2 \quad (17)$$

其中, $\Theta = \{\alpha_i, \beta_i, \theta_i^1, \theta_i^2\}_{i=1}^L$ 为网络中的可训练参数。由于在网络中后层的输出值越接近真实的检测结果, 因此在损失函数为各层的输出值加上权重 $\log(i)$, i 为网络中各层的下标。改进后的损失函数在越靠后的层可以获得更大的权重, 使其在损失函数中发挥的作用越大, 其表达式如下:

$$\mathcal{L}(x, \tilde{x}_\Theta(H, y)) = \frac{1}{L} \sum_{i=1}^L \log(i) \|x - \tilde{x}_i\|^2 \quad (18)$$

3.3 训练网络

本文所提出的检测网络使用 Python 语言进行编写并部署在 TensorFlow-1.15.0 环境下。网络中的可训练参数 Θ 通过标准的深度学习技术进行训练。

SDNSR-Net 并非直接训练 L 层的整个网络, 而是采用了增量学习^[13]的方式进行训练。具体地, 网络中的前 t 层的训练参数 $\Theta_t = \{\alpha_i, \beta_i, \theta_i^1, \theta_i^2\}_{i=1}^t$ 首先通过增量学习的方式训练好, 然后再将第 $t+1$ 层加入检测网络中, 第 $t+1$ 层的可学习参数 α_{t+1} 和 β_{t+1} 都初始化为 0.5, θ_{t+1}^1 和 θ_{t+1}^2 都初始化为 0。前 t 层的可训练参数 Θ_t 直接使用训练完成的值作为初始值, 然后 $t+1$ 层的检测网络采用同样的训练方式进行训练直到整个 L 层的网络全都训练结束。

4 仿真结果及分析

在本节中, 通过仿真实验对比 SDNSR-Net 和传统的各类检测算法, 验证了 SDNSR-Net 的检测性能。仿真中所对比的算法包括:(1)MMSE: 最小均方误差检测算法, 相比于 ZF 检测算法, 本算法考虑了噪声干扰的影响;(2)Richardson: 一种近似求解 MMSE 的检测算法, 避免了 MMSE 算法中的矩阵求逆操作;(3)Jacobi-Richardson: 在 Richardson 算法的基础上引入了 Jacobi 迭代的联合检测算法^[14];(4)SDNSR: 通过最陡梯度下降算法来弥补 Richardson

松弛参数估计误差的联合检测算法;(5)SDBB: 基于最陡梯度下降算法的 Barzilai-Borwein 算法的迭代检测算法^[15]。

4.1 仿真参数设定

本次仿真的参数设定如表 1 所示。由于提出的网络需要在不同的信噪比(Signal to Noise Ratio, SNR)条件下进行检测, 因此训练数据集 $\{(y_i, \mathbf{H}_i), \mathbf{x}_i\}_{i=1}^M$ 中的训练数据对应的 SNR 从 $\mathcal{U}(-1 \text{ dB}, 11 \text{ dB})$ 的均匀分布中随机选取。

表 1 仿真参数设定

参数	取值
迭代次数及网络层数 L	7
学习率	0.001
学习率衰减因子	0.9
训练次数	30 000
验证次数	20 000
数据批量大小	500

4.2 检测性能分析

图 3 比较了系统规模为 128×16 的情况下各算法在检测性能。从图中能够看出在信噪比为 $-4 \text{ dB} \sim 2 \text{ dB}$ 时, SDNSR、Richardson 以及 Jacobi-Richardson 检测算法都能达到 MMSE 算法的检测性能。随着 SNR 的增加这 3 类检测算法的检测性能虽然有所退化, 但也能达到接近 MMSE 算法的检测性能。本文提出的 SDNSR-Net 的检测性能总是优于各类比较的检测算法。

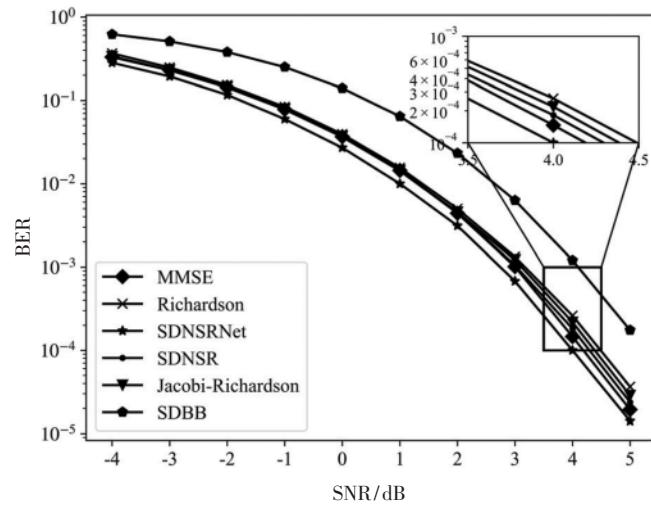


图 3 128×16 , 16QAM 调制情况下的检测误码率对比

图 4 比较了系统规模为 128×32 时各检测算法在 SNR 为 $-3 \text{ dB} \sim 6 \text{ dB}$ 时的检测性能。从图中可以看出随着发送端天线的增加, Richardson 以及 Jacobi-Richardson 算法的检测性能相对于 MMSE 算法开始出现退化且 SNR 越高现象越明显, SDNSR 虽然能够保持接近 MMSE 算法的检测性能, 但与 SDNSR-Net 的检测性能之间还是存在较大差距。在此情况下, 本文所提出的 SDNSR-Net

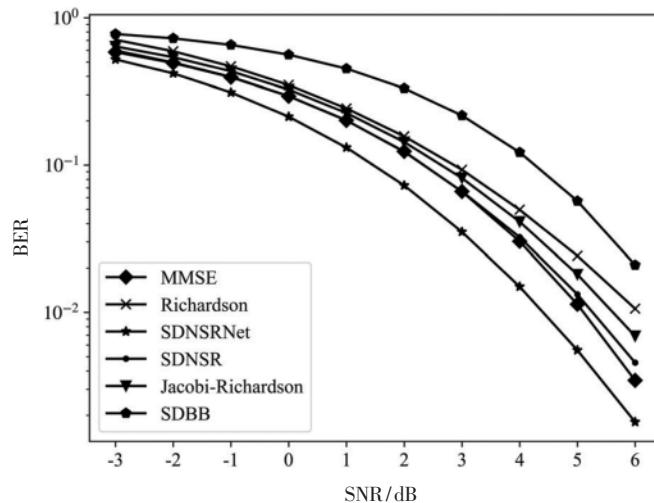


图 4 128×32 , 16QAM 调制情况下的检测误码率对比

算法仍保持优于各种对比算法。

图 5 比较了在负载系统规模为 128×64 时各检测算法在 SNR 为 $2 \text{ dB} \sim 11 \text{ dB}$ 之间的检测性能。可以看出随着用户数量的进一步增加, Richardson 和 Jacobi-Richardson 检测算法的性能出现严重退化, 基本不能完成检测任务。SDNSR 算法由于引入 SD 算法来弥补 Richardson 算法中由于近似计算松弛因子带来的误差, 因此在此情况依旧能保持不错的检测性能。而本文提出的 SDNSR-Net 能够比 SDNSR 算法给松弛参数带来更精确的补偿, 因此能够提供更好的检测性能。

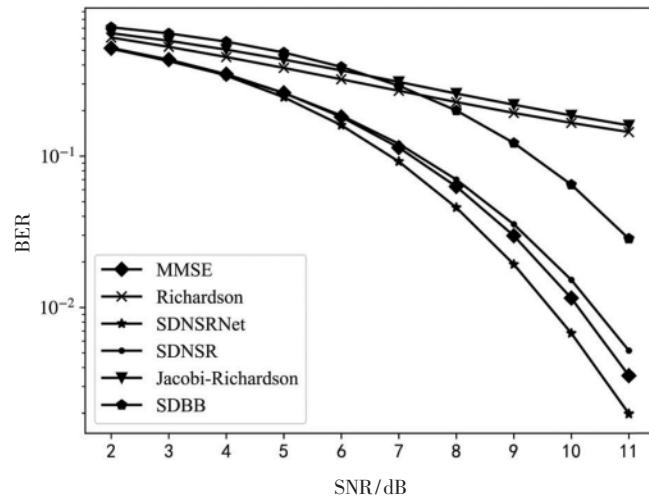


图 5 128×64 , 16QAM 调制情况下的检测误码率对比

结合以上各图可知, 随着用户数量和信噪比 SNR 的变化, 传统的各迭代检测算法的检测性能表现出的性能差异较大, 而本文提出的 SDNSR-Net 在各个场景下都保持了优于而对比算法的性能。使用深度学习技术, 通过离线训练获得 SDNSR-Net 算法训练参数的具体值。通过训练 SDNSR-Net 而得的步长参数值比 SDNSR 中通

过式(9)计算的步长参数值更加准确,因此能更好地补偿Richardson算法中由于近似计算松弛因子带来的误差,从而达到更好的检测性能。

5 结论

本文提出了一个全新的基于模型驱动深度学习的检测网络(SDNSR-Net),用以处理大规模MIMO系统中的信号检测问题。SDNSR-Net的网络结构通过展开传统迭代检测算法SDNSR进行构建,在传统算法的基础上对残余误差的计算公式进行改进,然后通过离线训练而得的可训练参数值替代SDNSR中的步长参数。实验结果表明,本文提出的检测网络相较于SDNSR能够以较低的计算复杂度和更优的检测性能完成大规模MIMO系统下的信号检测任务。

参考文献

- [1] RUSEK F , PERSSON D , LAU B K , et al . Scaling up MIMO : opportunities and challenges with very large arrays [J]. IEEE Signal Processing Magazine , 2012 , 30(1) : 40–60.
- [2] GAO X , DAI L , MA Y , et al . Low-complexity near-optimal signal detection for uplink large-scale MIMO systems [J]. arXiv : 1507.04443 , 2015 .
- [3] QIN X , YAN Z , HE G . A near-optimal detection scheme based on joint steepest descent and Jacobi method for uplink massive MIMO systems [J]. IEEE Communications Letters , 2015 , 20(2) : 276–279 .
- [4] 王明月,李方伟,景小荣,等.大规模MIMO-TRDMA系统中的改进SOR信号检测算法[J].通信学报,2021,42(10):153–161.
- [5] 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 , 2017 , 7(1) : 114–117 .
- [6] SAMUEL N , DISKIN T , WIESEL A . Learning to detect [J]. IEEE Transactions on Signal Processing , 2019 , 67(10) : 2554–2564 .
- [7] HE H , WEN C K , JIN S , et al . A model-driven deep learning network for MIMO detection [C]// 2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). IEEE , 2018 : 584–588 .
- [8] LOU M , TU J , SHU D , et al . A deeply fused detection algorithm based on steepest descent and non-stationary Richardson iteration for massive MIMO systems [J]. IEEE Communications Letters , 2020 , 24(12) : 2742–2745 .
- [9] GAO X , DAI L , YUEN C , et al . Low-complexity MMSE signal detection based on Richardson method for large-scale MIMO systems [C]// 2014 IEEE 80th Vehicular Technology Conference (VTC2014-Fall). IEEE , 2014 : 1–5 .
- [10] DENG Q , CHEN X , FU W , et al . Improved approximate expectation propagation massive MIMO detector with second-order Richardson iteration [J]. Wireless Communications and Mobile Computing , 2022 , 2022 : 5336187 .
- [11] QIN X , YAN Z , HE G . A near-optimal detection scheme based on joint steepest descent and Jacobi method for uplink massive MIMO systems [J]. IEEE Communications Letters , 2015 , 20(2) : 276–279 .
- [12] TACHIBANA J , OHTSUKI T . Learning and analysis of damping factor in massive MIMO detection using BP algorithm with node selection [J]. IEEE Access , 2020 , 8 : 96859–96866 .
- [13] TAKABE S , IMANISHI M , WADAYAMA T , et al . Deep learning-aided projected gradient detector for massive over-loaded MIMO channels [C]// ICC 2019–2019 IEEE International Conference on Communications (ICC). IEEE , 2019 : 1–6 .
- [14] KHOSO I A , JAVED T B , TU S , et al . A fast-convergent detector based on joint jacobi and richardson method for uplink massive MIMO systems [C]// 2019 28th Wireless and Optical Communications Conference (WOCC). IEEE , 2019 : 1–5 .
- [15] TAN M , QIAO X . An optimized low-complexity Barzilai-Borwein algorithm for signal detection in massive MIMO systems [C]// 2019 IEEE 4th International Conference on Integrated Circuits and Microsystems (ICICM). IEEE , 2019 : 228–232 .

(收稿日期:2022-01-03)

作者简介:

曾相誌(1996-),男,硕士,主要研究方向:深度学习、MIMO信号检测。

申滨(1978-),男,博士,教授,主要研究方向:信号处理、MIMO系统和认知无线电。

阳建(1996-),男,硕士,主要研究方向:深度学习、MIMO信号检测。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所