



(12) 发明专利申请

(10) 申请公布号 CN 116418633 A

(43) 申请公布日 2023. 07. 11

(21) 申请号 202310174517.1

(22) 申请日 2023.02.27

(71) 申请人 华南理工大学

地址 510640 广东省广州市天河区五山路
381号

(72) 发明人 李杰 黄婷婷 赵昊 季飞

(74) 专利代理机构 广州市华学知识产权代理有
限公司 44245

专利代理师 黄卫萍

(51) Int. Cl.

H04L 25/02 (2006.01)

G06N 3/0464 (2023.01)

G06N 3/048 (2023.01)

G06N 3/08 (2023.01)

H04B 13/02 (2006.01)

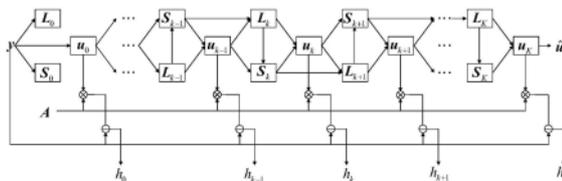
权利要求书2页 说明书7页 附图4页

(54) 发明名称

基于稀疏与低秩特征的深度展开水声信道估计方法

(57) 摘要

本发明公开了一种基于稀疏与低秩特征的深度展开水声信道估计方法,包括以下步骤:联合利用水声双扩展信道在时延-多普勒域的稀疏和低秩先验知识,将稀疏和低秩两部分矩阵采用交替线性化最小化方法来求解水声信道。同时,通过设置一定的阈值,使深度展开算法网络具有自适应迭代深度。本发明在时延-多普勒域弱稀疏性的背景下,无需依赖水声双扩展信道的稀疏性,采用深度展开算法,使改进后的深度学习方法既具有基于模型方法的良好解释性又具有经典深度学习网络方法的稳定性,该方法在用于仿真数据和真实数据测试时,表现出良好的估计性能。



1. 一种基于稀疏与低秩特征的深度展开水声信道估计方法,其特征在于,所述信道估计方法包括以下步骤:

S1、搭建水声双扩展信道,假设水声双扩展信道存在时延和多普勒效应,该水声双扩展信道在时延-多普勒域的信道参数包括:时延域维度M、时间采样间隔T、多普勒域维度为L,频率间隔 Δf 、多普勒分辨率 $1/(L*T)$ 、时延分辨率 $1/(M*\Delta f)$;

S2、根据公式 $U(m,l) = a\delta(m - \frac{1}{M\Delta f})\delta(l - \frac{1}{LT})$,生成时延-多普勒域的双扩展函数 $U(m, l)$,其中 a 是信道增益, $\delta(\cdot)$ 是冲击函数, $m \in (0, M-1)$, $l \in (0, L-1)$, m 表示时延域第 m 维, l 表示多普勒域第 l 维;

S3、生成输入水声双扩展信道的发送信号 $x[n]$, n 代表时刻;

S4、步骤S2生成的时延-多普勒域的双扩展函数和步骤S3生成的发送信号 $x[n]$ 通过公式: $y[n] = \sum_{m=0}^{M-1} \sum_{l=0}^{L-1} U(m,l) e^{j2\pi ml/N_0} x[n-m] + w[n]$, $n = 0, \dots, N_0-1$,得到接收信号 $y[n]$,其中 N_0 是接收信号维度, $N_0 = N+M-1$,发送信号长度为 N , $w[n]$ 是高斯噪声;

将水声双扩展信道的输入输出写成向量形式:

$$y = Au + w$$

其中 $y = [y[0], \dots, y[N_0-1]]^T$, $w = [w[0], \dots, w[N_0-1]]^T$, $A \in \mathbb{C}^{N_0 \times ML}$ 是观测矩阵, $A = [\Phi_0 X, \dots, \Phi_{L-1} X]$,其中 $\Phi_l \in \mathbb{C}^{N_0 \times N_0}$ 是一个对角矩阵,定义为: Φ_l

$$= \text{diag}[e^{j2\pi l \cdot 0/N_0}, \dots, e^{j2\pi l(N_0-1)/N_0}] \quad , \quad X \in \mathbb{C}^{N_0 \times M} \text{ 为 } X = \begin{bmatrix} x[0], & \dots, & x[-M+1] \\ x[1], & \dots, & x[-M+2] \\ \vdots & & \\ x[N_0-1], & \dots, & x[N_0-M] \end{bmatrix},$$

$u \in \mathbb{C}^{ML \times 1}$ 是时延-多普勒域的信道向量,定义为

$$u = [U(0,0), U(0,M-1), U(1,0), U(1,M-1), U(L-1,0), U(L-1,M-1)]^T,$$

当已知测量向量 y ,可估计时延-多普勒域的信道向量 u ;

S5、搭建深度展开的神经网络;

S6、生成用于训练神经网络的数据集 \mathcal{D} ,数据集 \mathcal{D} 中每组数据样本包括测量向量 y 和时延-多普勒域的信道向量 u ;

S7、利用数据集 \mathcal{D} 对神经网络进行迭代训练,使损失函数收敛到最小值,得到模型参数集 \mathcal{S}^* ;

S8、使用模型参数集 \mathcal{S}^* 初始化神经网络,生成模拟信号或采集真实场景信号,经数据转换和归一化后输入神经网络,得到输出 \hat{u} , \hat{u} 为估计出来的时延-多普勒域的信道向量。

2. 根据权利要求1所述的基于稀疏与低秩特征的深度展开水声信道估计方法,其特征在于,所述步骤S5过程如下:

定义要解决的优化问题为:

$$\min_{L, S, u} \frac{1}{2} \|Au - y\|_2^2 + \lambda_L \|L\|_{w, *} + \|S\|_1 \quad s.t. \quad u = L + S$$

式中 $\|\cdot\|_1$ 代表L1范数, $\|\cdot\|_{w,*}$ 代表加权核范数,L和S分别代表u的低秩部分和稀疏部分;

所述深度展开的神经网络由K个迭代块组成,每个迭代块分别由加权低秩模块 L^{k+1} 、稀疏模块 S^{k+1} 和信道向量恢复模块 u^{k+1} 组成,各模块的更新过程对应以下公式:

$$\begin{cases} L^{k+1} : L_{k+1} = H_{\lambda_L}(\mathbf{u}_k - \mathbf{S}_k) \\ S^{k+1} : S_{k+1} = T(\mathbf{u}_k, L_{k+1}) \\ u^{k+1} : \mathbf{u}_{k+1} = L_{k+1} + S_{k+1} - \gamma \nabla F(L_{k+1} + S_{k+1}) \end{cases}$$

首先搭建加权低秩模块 L^{k+1} ,其中 $H_{\lambda_L}(\mathbf{u}_k - \mathbf{S}_k) = \mathbf{U} \mathbb{S}_{\omega}(\boldsymbol{\Sigma}) \mathbf{V}^T$, $\boldsymbol{\Sigma}$ 是含有奇异值的对角矩阵,对于在 $\boldsymbol{\Sigma}$ 里的每一个对角元素 Σ_{ii} ,有 $\mathbb{S}_{\omega}(\boldsymbol{\Sigma})_{ii} = \max(\Sigma_{ii} - \omega, 0)$, $\mathbb{S}_{\omega}(\boldsymbol{\Sigma})$ 表示对奇异值用加权值 ω 进行收缩,即用加权核范数最小化方法,恢复第k+1次迭代的低秩部分 L_{k+1} ;

其次搭建稀疏模块 S^{k+1} , $T(\cdot)$ 代表稀疏正则化函数,用L1范数约束,稀疏模块 S^{k+1} 将 u_k 与 L_{k+1} 在通道维度进行拼接,拼接后的特征输入到连续的三层卷积核大小为 3×3 的卷积层来获取稀疏先验知识,并采用PReLU激活函数,恢复第k+1次迭代的稀疏部分 S_{k+1} ;

最后搭建信道向量恢复模块 u^{k+1} ,利用已经恢复出来的低秩部分 L_{k+1} 和稀疏部分 S_{k+1} ,使用可学习步长 γ 来解决参数选择问题,梯度项 ∇F 为 $A^+(A(L_{k+1} + S_{k+1}) - y)$,其中 A^+ 为观测矩阵的伪逆矩阵,将残差向量 $(A(L_{k+1} + S_{k+1}) - y)$ 依次输入连续的两层全连接层,全连接层的激活函数为Sigmoid函数,通过计算残差向量的L2范数得到停顿因子 h_k , h_k 用于与阈值参数 ϵ 比较,阈值参数 ϵ 是人为设定的,在满足 $K = \min(k : h_k \leq \epsilon)$ 条件时,神经网络停止迭代,K是神经网络运行的迭代块总数,所得信道向量恢复模块输出为 u_k ,最终将 u_k 输入到由神经元组成的全连接层中,输出估计的时延-多普勒域的信道向量 $\hat{\mathbf{u}}$ 。

3. 根据权利要求1所述的基于稀疏与低秩特征的深度展开水声双扩展信道估计方法,其特征在于,所述步骤S6中生成所需的数据集 \mathcal{D} 的过程如下:首先将测量向量y和可估计时

延-多普勒域的信道向量u输入以下公式: $\mathbf{y} = \begin{bmatrix} \text{real}(\mathbf{y}) \\ \text{imag}(\mathbf{y}) \end{bmatrix}$, $\mathbf{u} = \begin{bmatrix} \text{real}(\mathbf{u}) \\ \text{imag}(\mathbf{u}) \end{bmatrix}$,其中, $\text{real}(\cdot)$ 、

$\text{imag}(\cdot)$ 分别表示取实部和取虚部运算操作,然后将复数数据的实部虚部进行拼接,组成实数数据集,最后对每组数据进行归一化,得到数据集 \mathcal{D} 。

基于稀疏与低秩特征的深度展开水声信道估计方法

技术领域

[0001] 本发明涉及水声信道估计与深度学习技术领域,具体涉及一种基于稀疏与低秩特征的深度展开水声信道估计方法。

背景技术

[0002] 与陆地无线通信相比,水声信道的四个最主要特征为:严重的多径和长时延、频率选择性传输损失、多普勒扩展、低声速传播等。在多径和时变条件下,水声信道表现出典型的时延-多普勒双重扩展,即由多径传播导致的时延扩展,和由水体运动和收发端运动导致的多普勒频移扩展。为了消除信道影响,需要对多径时延,多普勒频移以及衰减因子等多个信道参数进行准确估计,这给高速水声通信带来挑战。

[0003] 在过去的十年中,压缩感知算法的应用显著提高了信道估计的速度和效率,因为它利用水声信道的稀疏性,能够从低维欠采样的信号中重建高维信道。但是,基于压缩感知算法的信道估计的性能高度依赖于信道的稀疏性。然而在实践中,由于水声信道的散射、密集多径传播以及信号处理的谱泄漏效应,水声信道的稀疏性假设并不总是得到很好的满足。因此基于压缩感知算法的估计器的性能会由于水声信道的弱稀疏性而显著下降。针对这一问题,现有的方法也给出了一些改进方案。例如,使用改进的基扩展来增强信道稀疏性(Yu H, Song A, Badiy M, et al. Iterative estimation of doubly selective underwater acoustic channel using basis expansion models[J]. Ad Hoc Networks, 2015, 34:52-61.); 还有使用块稀疏约束来处理信道聚类结构(Gong B, Gui L, Qin Q, et al. Block distributed compressive sensing-based doubly selective channel estimation and pilot design for large-scale MIMO systems[J]. IEEE Transactions on Vehicular Technology, 2017, 66(10):9149-9161.)。然而,上述方法本质上是测量双扩展信道的一维稀疏性,仍然没有充分利用双扩展信道在时延-多普勒二维域的内在特性。

[0004] 除此之外,现有许多信道估计算法可以公式化为优化问题,这些优化问题通常使用迭代数值优化算法来解决。但是在实践中,具体的迭代算法并不一定完全匹配应用场景。近年来,由于深度学习引起了科学界和工程界越来越多的关注。深度学习通过使用大量数据训练网络,实现输入到特定功能输出的映射。然而,单纯数据驱动深度学习算法就像“黑匣子”一样,没有严格的算法思想约束。而基于模型驱动的神经网络将有性能保证的原则性算法与深度学习的工具相融合,目标是结合两种思想的优点。因此在水声信道估计任务中,利用深度展开这种模型驱动神经网络方法技术,将信道的稀疏与低秩模型与数据驱动的神经网络结合,实现双扩展信道向量的估计。

[0005] 总结现有的水声双扩展信道估计方法,有以下主要问题:

[0006] 1、水声信道由于密集多径和散射等原因,使得其在时延-多普勒域中稀疏性减弱,传统依赖稀疏性的算法性能退化甚至失效。

[0007] 2、现有基于纯数据驱动深度学习的方法,依赖大量的训练数据完成对信道特征的提取和估计,没有充分利用信道具有的先验模型特征。

发明内容

[0008] 本发明的目的是为了解决现有技术中的上述缺陷,提供一种基于稀疏与低秩特征的深度展开水声信道估计方法。

[0009] 本发明的目的可以通过采取如下技术方案达到:

[0010] 一种基于稀疏与低秩特征的深度展开水声信道估计方法,所述信道估计方法包括以下步骤:

[0011] S1、搭建水声双扩展信道,假设水声双扩展信道存在时延和多普勒效应,该水声双扩展信道在时延-多普勒域的信道参数包括:时延域维度M、时间采样间隔T、多普勒域维度为L,频率间隔 Δf 、多普勒分辨率 $1/(L*T)$ 、时延分辨率 $1/(M*\Delta f)$;

[0012] S2、根据公式 $U(m,l) = a\delta(m - \frac{1}{M\Delta f})\delta(l - \frac{1}{LT})$,生成时延-多普勒域的双扩展函数 $U(m,l)$,其中a是信道增益, $\delta(\cdot)$ 是冲击函数, $m \in (0, M-1)$, $l \in (0, L-1)$, m表示时延域第m维, l表示多普勒域第l维;

[0013] S3、生成输入水声双扩展信道的发送信号 $x[n]$, n代表时刻;

[0014] S4、步骤S2生成的时延-多普勒域的双扩展函数和步骤S3生成的发送信号 $x[n]$ 通过公式:

$y[n] = \sum_{m=0}^{M-1} \sum_{l=0}^{L-1} U(m,l) e^{j2\pi ml/N_0} x[n-m] + w[n], n=0, \dots, N_0-1$, 得到接收信号 $y[n]$, 其中

N_0 是接收信号维度, $N_0 = N + M - 1$, 发送信号长度为N, $w[n]$ 是高斯噪声;

[0015] 将水声双扩展信道的输入输出写成向量形式:

[0016] $y = Au + w$

[0017] 其中 $y = [y[0], \dots, y[N_0-1]]^T$, $w = [w[0], \dots, w[N_0-1]]^T$, $A \in \mathbb{C}^{N_0 \times ML}$ 是观测矩阵, $A = [\Phi_0 X, \dots, \Phi_1 X, \dots, \Phi_{L-1} X]$, 其中 $\Phi_l \in \mathbb{C}^{N_0 \times N_0}$ 是一个对角矩阵, 定义为:

$$= \text{diag}[e^{j2\pi l \cdot 0/N_0}, \dots, e^{j2\pi l(N_0-1)/N_0}] \quad , \quad X \in \mathbb{C}^{N_0 \times M} \text{ 为 } X = \begin{bmatrix} x[0], & \dots, & x[-M+1] \\ x[1], & \dots, & x[-M+2] \\ \vdots & & \vdots \\ x[N_0-1], & \dots, & x[N_0-M] \end{bmatrix} ,$$

$u \in \mathbb{C}^{ML \times 1}$ 是时延-多普勒域的信道向量, 定义为 $u = [U(0,0), \dots, U(0,M-1), \dots, U(1,0), \dots, U(1,M-1), \dots, U(L-1,0), \dots, U(L-1,M-1)]^T$, 当已知测量向量y, 可估计时延-多普勒域的信道向量u;

[0018] S5、搭建深度展开的神经网络;

[0019] S6、生成用于训练神经网络的数据集 \mathcal{D} , 数据集 \mathcal{D} 中每组数据样本包括测量向量y和时延-多普勒域的信道向量u;

[0020] S7、利用数据集 \mathcal{D} 对神经网络进行迭代训练, 使损失函数收敛到最小值, 得到模型参数集 ζ^* ;

[0021] S8、使用模型参数集 ζ^* 初始化神经网络, 生成模拟信号或采集真实场景信号, 经数据转换和归一化后输入神经网络, 得到输出 \hat{u} , \hat{u} 为估计出来的时延-多普勒域的信道向量。

[0022] 进一步地, 所述步骤S5过程如下:

[0023] 定义要解决的优化问题为:

$$[0024] \quad \min_{L,S,u} \frac{1}{2} \|Au - y\|_2^2 + \lambda_L \|L\|_{w,*} + \|S\|_1 \quad s.t. \quad u = L + S$$

[0025] 式中 $\|\cdot\|_1$ 代表L1范数, $\|\cdot\|_{w,*}$ 代表加权核范数, L和S分别代表u的低秩部分和稀疏部分;

[0026] 所述深度展开的神经网络由K个迭代块组成, 每个迭代块分别由加权低秩模块 L^{k+1} 、稀疏模块 S^{k+1} 和信道向量恢复模块 u^{k+1} 组成, 各模块的更新步骤对应公式:

$$[0027] \quad \begin{cases} L^{k+1} : L_{k+1} = H_{\lambda_L}(u_k - S_k) \\ S^{k+1} : S_{k+1} = T(u_k, L_{k+1}) \\ u^{k+1} : u_{k+1} = L_{k+1} + S_{k+1} - \gamma \nabla F(L_{k+1} + S_{k+1}) \end{cases}$$

[0028] 首先搭建加权低秩模块 L^{k+1} , 其中 $H_{\lambda_L}(u_k - S_k) = US_{\omega}(\Sigma)V^T$, Σ 是含有奇异值的对角矩阵, 对于在 Σ 里的每一个对角元素 Σ_{ii} , 有 $S_{\omega}(\Sigma)_{ii} = \max(\Sigma_{ii} - \omega, 0)$, $S_{\omega}(\Sigma)$ 表示对奇异值用加权值 ω 进行收缩, 即用加权核范数最小化方法, 恢复第k+1次迭代的低秩部分 L_{k+1} ;

[0029] 其次搭建稀疏模块 S^{k+1} , $T(\cdot)$ 代表稀疏正则化函数, 用L1范数约束, 稀疏模块 S^{k+1} 将 u_k 与 L_{k+1} 在通道维度进行拼接, 拼接后的特征输入到连续的三层卷积核大小为 3×3 的卷积层来获取稀疏先验知识, 并采用PReLU激活函数, 恢复第k+1次迭代的稀疏部分 S_{k+1} ;

[0030] 最后搭建信道向量恢复模块 u^{k+1} , 利用已经恢复出来的低秩部分 L_{k+1} 和稀疏部分 S_{k+1} , 使用可学习步长 γ 来解决参数选择问题, 梯度项 ∇F 为 $A^+(A(L_{k+1} + S_{k+1}) - y)$, 其中 A^+ 为观测矩阵的伪逆矩阵, 将残差向量 $(A(L_{k+1} + S_{k+1}) - y)$ 依次输入连续的两层全连接层, 全连接层的激活函数为Sigmoid函数, 通过计算残差向量的L2范数得到停顿因子 h_k , h_k 用于与阈值参数 ϵ 比较, 阈值参数 ϵ 是人为设定的, 在满足 $K = \min(k: h_k \leq \epsilon)$ 条件时, 神经网络停止迭代, K是神经网络运行的迭代块总数, 所得信道向量恢复模块输出为 u_k , 最终将 u_k 输入到由神经元组成的全连接层中, 输出估计的时延-多普勒域的信道向量 \hat{u} 。

[0031] 进一步地, 所述步骤S6中生成所需的数据集 \mathcal{D} 的过程如下: 首先将测量向量y和

可估计时延-多普勒域的信道向量u输入以下公式: $y = \begin{bmatrix} \text{real}(y) \\ \text{imag}(y) \end{bmatrix}$, $u = \begin{bmatrix} \text{real}(u) \\ \text{imag}(u) \end{bmatrix}$, 其中,

$\text{real}(\cdot)$ 、 $\text{imag}(\cdot)$ 分别表示取实部和取虚部运算操作, 然后将复数数据的实部虚部进行拼接, 组成实数数据集, 最后对每组数据进行归一化, 得到数据集 \mathcal{D} 。

[0032] 本发明相对于现有技术具有如下的优点及效果:

[0033] 1、传统的估计水声双扩展信道的方法一般依赖于时延-多普勒域的稀疏性, 在散射水声环境下双扩展信道稀疏性不强并且难以确定路径数目, 本发明联合利用时延-多普勒域的稀疏性和低秩性, 充分挖掘信道二维结构特征, 不仅仅依赖稀疏性, 估计效果更佳。

[0034] 2、本发明基于深度展开技术, 传统的深度学习方法相当于是一个“黑匣子”, 只是通过大量的样本数据训练模型, 并没有具体的算法思想来保证性能, 不具有逻辑可解释性。本发明将迭代算法的思想融入到深度学习当中, 分为三个迭代模块, 并且所有的参数均是可学习的, 可以利用较少的训练数据即可获得较好的估计性能。

[0035] 3、本发明相对于现有的深度展开算法, 结合所研究的水声双扩展信道具有的特

征,做了两点改进:(1)通过调整监督学习参数,引入阈值参数,使神经网络迭代次数自适应,加快估计的运行速度,增强了估计效果;(2)为了加强对矩阵奇异值的先验知识,采用加权核范数极小化方法;通过上述改进措施,本专利发明提出的算法在估计水声双扩展信道性能上,相比现有的压缩感知算法和深度学习算法可以得到更优越的性能结果。

附图说明

[0036] 此处所说明的附图用来提供对本发明的进一步理解,构成本申请的一部分,本发明的示意性实施例及其说明用于解释本发明,并不构成对本发明的不当限定。在附图中:

[0037] 图1是本发明公开的基于稀疏与低秩特征的深度展开水声双扩展信道估计方法的网络结构框图;

[0038] 图2是本发明所模拟搭建的“弱稀疏”和稀疏背景下的时延-多普勒域双扩展信道示意图;

[0039] 图3是本发明使用仿真数据测试结果图,是在“弱稀疏”的水声双扩展信道背景下进行的,其中图3(a)是三种深度学习方法示意图,图3(b)是包括两种压缩感知算法进行估计性能对比示意图;

[0040] 图4是本发明使用仿真数据测试结果图,是在稀疏的水声双扩展信道背景下进行的,其中图4(a)是三种深度学习方法示意图,图4(b)是包括两种压缩感知算法进行估计性能对比示意图。

具体实施方式

[0041] 为使本发明实施例的目的、技术方案和优点更加清楚,下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,所描述的实施例是本发明一部分实施例,而不是全部的实施例。基于本发明中的实施例,本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例,都属于本发明保护的范围。

[0042] 实施例1

[0043] 如附图1所示本实施例公开了基于稀疏与低秩特征的深度展开水声信道估计方法在仿真信号场景下的具体实施步骤:

[0044] S1、搭建水声双扩展信道,假设水声双扩展信道存在时延和多普勒效应,该水声双扩展信道在时延-多普勒域的信道参数包括:时延域维度 $M=16$ 、多普勒域维度为 $L=16$,频率间隔 $\Delta f=15\text{KHZ}$ 、时间采样间隔 $T=1/\Delta f$ 、多普勒分辨率 $1/(L*T)$ 、时延分辨率 $1/(M*\Delta f)$;

[0045] S2、根据公式 $U(m,l) = a\delta(m - \frac{1}{M\Delta f})\delta(l - \frac{1}{LT})$,生成时延-多普勒域的双扩展函数

$U(m,l)$,其中 a 是信道增益, $\delta(\cdot)$ 是冲击函数, $m \in (0, M-1)$, $l \in (0, L-1)$, $m \in (0, M-1)$, $l \in (0, L-1)$, m 表示时延域第 m 维, l 表示多普勒域第 l 维;

[0046] S3、生成输入水声双扩展信道的发送信号 $x[n]$, n 代表时刻;

[0047] S4、步骤S2生成的时延-多普勒域的双扩展函数和步骤S3生成的发送信号 $x[n]$ 通过公式:

$y[n] = \sum_{m=0}^{M-1} \sum_{l=0}^{L-1} U(m,l) e^{j2\pi ml/N_0} x[n-m] + w[n]$, $n=0, \dots, N_0-1$,得到接收信号 $y[n]$,其中

N_0 是接收信号维度, $N_0=N+M-1$, 发送信号长度为 N , $w[n]$ 是高斯噪声;

[0048] 将水声双扩展信道的输入输出写成向量形式:

[0049] $y=Au+w$

[0050] 其中 $y=[y[0], \dots, y[N_0-1]]^T$, $w=[w[0], \dots, w[N_0-1]]^T$, $A \in \mathbb{C}^{N_0 \times ML}$ 是观测矩阵, $A=[\Phi_0 X, \dots, \Phi_1 X, \dots, \Phi_{L-1} X]$, 其中 $\Phi_l \in \mathbb{C}^{N_0 \times N_0}$ 是一个对角矩阵, 定义为: Φ_l

$$= \text{diag}[e^{j2\pi l \cdot 0/N_0}, \dots, e^{j2\pi l(N_0-1)/N_0}] \quad , \quad X \in \mathbb{C}^{N_0 \times M} \text{ 为 } X = \begin{bmatrix} x[0], & \dots, & x[-M+1] \\ x[1], & \dots, & x[-M+2] \\ \vdots & & \vdots \\ x[N_0-1], & \dots, & x[N_0-M] \end{bmatrix} ,$$

$u \in \mathbb{C}^{ML \times 1}$ 是时延-多普勒域的信道向量, 定义为 $u=[U(0,0), \dots, U(0,M-1), \dots, U(1,0), \dots, U(1,M-1), \dots, U(L-1,0), \dots, U(L-1,M-1)]^T$, 当已知测量向量 y , 可估计时延-多普勒域的信道向量 u ;

[0051] S5、搭建深度展开的神经网络, 对应于图1;

[0052] 深度展开的神经网络由若干个迭代块组成, 每个迭代块分别由加权低秩模块 L^{k+1} , 稀疏模块 S^{k+1} 和信道向量恢复模块 u^{k+1} 组成, 各模块的更新步骤对应公式:

$$[0053] \quad \begin{cases} L^{k+1} : L_{k+1} = H_{\lambda_L}(u_k - S_k) \\ S^{k+1} : S_{k+1} = T(u_k, L_{k+1}) \\ u^{k+1} : u_{k+1} = L_{k+1} + S_{k+1} - \gamma \nabla F(L_{k+1} + S_{k+1}) \end{cases}$$

[0054] 首先搭建加权低秩模块 L^{k+1} , 其中 $H_{\lambda_L}(u_k - S_k) = US_{\omega}(\Sigma)V^T$, Σ 是含有奇异值的对角矩阵, 对于在 Σ 里的每一个对角元素 Σ_{ii} , 有 $S_{\omega}(\Sigma)_{ii} = \max(\Sigma_{ii} - \omega, 0)$, $S_{\omega}(\Sigma)$ 表示对奇异值用加权值 ω 进行收缩, 即用加权核范数最小化方法, 恢复第 $k+1$ 次迭代的低秩部分 L_{k+1} ;

[0055] 其次搭建稀疏模块 S^{k+1} , $T(\cdot)$ 代表稀疏正则化函数, 用 $L1$ 范数约束, 稀疏模块 S^{k+1} 将 u_k 与 L_{k+1} 在通道维度进行拼接, 拼接后的特征输入到连续的三层卷积核大小为 3×3 的卷积层来获取稀疏先验知识, 并采用PReLU激活函数, 恢复第 $k+1$ 次迭代的稀疏部分 S_{k+1} ;

[0056] 最后搭建信道向量恢复模块 u^{k+1} , 利用已经恢复出来的低秩部分 L_{k+1} 和稀疏部分 S_{k+1} , 使用可学习步长 γ 来解决参数选择问题, 梯度项 ∇F 为 $A^+(A(L_{k+1} + S_{k+1}) - y)$, 其中 A^+ 为观测矩阵的伪逆矩阵。将残差 $(A(L_{k+1} + S_{k+1}) - y)$ 依次输入连续的两层全连接层, 激活函数为Sigmoid函数, 计算残差向量的 $L2$ 范数从而得到停顿因子 h_k 。 h_k 用于与阈值参数 ϵ 比较, 阈值参数 ϵ 是人为设定的, 在满足 $K = \min(k: h_k \leq \epsilon)$ 条件时, 网络停止迭代, K 就是网络运行的最终层数, 所得信道向量恢复模块输出为 u_k 。最终将 u_k 输入到由神经元组成的全连接层中, 输出估计的时延-多普勒域的信道向量 \hat{u} 。

[0057] S6、生成用于训练神经网络的数据集 \mathcal{D} , 数据集 \mathcal{D} 中每组数据样本包括测量向量 y , 时延-多普勒域的信道向量 u ;

[0058] S7、利用数据集 \mathcal{D} 对神经网络进行迭代训练, 使损失函数收敛到最小值, 得到模型参数集 ζ^* ;

[0059] S8、使用模型参数集 ζ^* 初始化神经网络, 生成模拟信号, 经数据转换和归一化后输

入神经网络,得到输出 $\hat{\mathbf{u}}$, $\hat{\mathbf{u}}$ 为估计出来的时延-多普勒域的信道向量。

[0060] 本实施例所要估计的时延-多普勒域信道分为“弱稀疏”和稀疏两种情况,分别对应于图2(a)和图2(b),可见,相比于稀疏情况,在“弱稀疏”背景下的水声双扩展信道,在时延-多普勒域的路径数目呈现“簇状”,路径数目增多,且无法判断准确的路径数目。

[0061] 本实施例测试结果如图3和图4所示,图3是在“弱稀疏”背景下的结果,由图3(a)可见,本发明公开的方法性能比端到端的深度学习算法和未改进的深度展开算法性能要优越。由图3(b)可见,本发明公开的方法性能显著优于OMP和CoSaMP两种压缩感知算法以及端到端的深度学习算法和未改进的深度展开算法。

[0062] 其中图4是在稀疏的背景下结果,由图4(a)可见,本发明公开的方法性能比端到端的深度学习算法和未改进的深度展开算法性能要优越。在图4(b)可见,加上OMP和CoSaMP两种压缩感知算法进行对比,可以看出,在信噪比较高的情况下,两种压缩感知算法也能达到不错的估计性能,这是因为在稀疏背景下的时延-多普勒域中,传统的迭代算法也是很匹配稀疏信道模型。但是在信噪比较低的情况下,可见本发明公开的深度展开学习算法估计性能更好。

[0063] 实施例2

[0064] 本实施例公开了一种基于稀疏与低秩特征的深度展开水声信道估计方法在真实信号场景下的具体实施步骤。

[0065] S1、在我们的实验中,根据实际的水声数据集,分别将信号和CP的长度设置为1024和128;

[0066] S2、经过数据处理,发送信号长度和接收信号长度均为768,通过最小二乘法获得导频处的信道向量 \mathbf{u}_p 和真实的信道向量 \mathbf{u}_{real} ;

[0067] S3、生成输入水声双扩展信道的发送信号 $x[n]$, n 代表时刻;

[0068] S4、步骤S2生成的时延-多普勒域的双扩展函数和步骤S3生成的发送信号 $x[n]$ 通

过公式: $y[n] = \sum_{m=0}^{M-1} \sum_{l=0}^{L-1} U(m,l) e^{j2\pi ml/N_0} x[n-m] + w[n]$, $n=0, \dots, N_0-1$, 得到接收信号 $y[n]$, 其中

N_0 是接收信号维度, $N_0=N+M-1$,发送信号长度为 N , $w[n]$ 是高斯噪声;

[0069] 将水声双扩展信道的输入输出写成向量形式:

[0070] $\mathbf{y} = \mathbf{A}\mathbf{u} + \mathbf{w}$

[0071] 其中 $\mathbf{y} = [y[0], \dots, y[N_0-1]]^T$, $\mathbf{w} = [w[0], \dots, w[N_0-1]]^T$, $\mathbf{A} \in \mathbb{C}^{N_0 \times ML}$ 是观测矩阵,

$\mathbf{A} = [\Phi_0 X, \dots, \Phi_1 X, \dots, \Phi_{L-1} X]$, 其中 $\Phi_l \in \mathbb{C}^{N_0 \times N_0}$ 是一个对角矩阵, 定义为: Φ_l

$$= \text{diag}[e^{j2\pi l \cdot 0 / N_0}, \dots, e^{j2\pi l (N_0-1) / N_0}] \quad , \quad \mathbf{X} \in \mathbb{C}^{N_0 \times M} \text{ 为 } \mathbf{X} = \begin{bmatrix} x[0], & \dots, & x[-M+1] \\ x[1], & \dots, & x[-M+2] \\ \vdots & & \\ x[N_0-1], & \dots, & x[N_0-M] \end{bmatrix} ,$$

$\mathbf{u} \in \mathbb{C}^{ML \times 1}$ 是时延-多普勒域的信道向量, 定义为 $\mathbf{u} = [U(0,0), \dots, U(0,M-1), \dots, U(1,0), \dots, U(1,M-1), \dots, U(L-1,0), \dots, U(L-1,M-1)]^T$, 当已知测量向量 \mathbf{y} , 可估计时延-多普勒域的信道向量 \mathbf{u} ;

[0072] S5、搭建深度展开的神经网络, 对应于图1;

[0073] 深度展开的神经网络由若干个迭代块组成,每个迭代块分别由加权低秩模块 L^{k+1} ,稀疏模块 S^{k+1} 和信道向量恢复模块 u^{k+1} 组成,各模块的更新步骤对应公式:

$$[0074] \quad \begin{cases} L^{k+1} : L_{k+1} = H_{\lambda_L}(\mathbf{u}_k - \mathbf{S}_k) \\ S^{k+1} : S_{k+1} = T(\mathbf{u}_k, L_{k+1}) \\ \mathbf{u}^{k+1} : \mathbf{u}_{k+1} = L_{k+1} + S_{k+1} - \gamma \nabla F(L_{k+1} + S_{k+1}) \end{cases}$$

[0075] 首先搭建加权低秩模块 L^{k+1} ,其中 $H_{\lambda_L}(\mathbf{u}_k - \mathbf{S}_k) = US_{\omega}(\Sigma)V^T$, Σ 是含有奇异值的对角矩阵,对于在 Σ 里的每一个对角元素 Σ_{ii} ,有 $S_{\omega}(\Sigma)_{ii} = \max(\Sigma_{ii} - \omega, 0)$, $S_{\omega}(\Sigma)$ 表示对奇异值用加权值 ω 进行收缩,即用加权核范数最小化方法,恢复第 $k+1$ 次迭代的低秩部分 L_{k+1} 。

[0076] 其次搭建稀疏模块 S^{k+1} , $T(\cdot)$ 代表稀疏正则化函数,用L1范数约束,稀疏模块 S^{k+1} 将 u_k 与 L_{k+1} 在通道维度进行拼接,拼接后的特征输入到连续的三层卷积核大小为 3×3 的卷积层来获取稀疏先验知识,并采用PReLU激活函数,恢复第 $k+1$ 次迭代的稀疏部分 S_{k+1} 。

[0077] 最后搭建信道向量恢复模块 u^{k+1} ,利用已经恢复出来的低秩部分 L_{k+1} 和稀疏部分 S_{k+1} ,使用可学习步长 γ 来解决参数选择问题,梯度项 ∇F 为 $A^+(A(L_{k+1} + S_{k+1}) - y)$,其中 A^+ 为观测矩阵的伪逆矩阵。将残差 $(A(L_{k+1} + S_{k+1}) - y)$ 依次输入连续的两层全连接层,激活函数为Sigmoid函数,计算残差向量的L2范数从而得到停顿因子 h_k 。 h_k 用于与阈值参数 ε 比较,阈值参数 ε 是人为设定的,在满足 $K = \min(k : h_k \leq \varepsilon)$ 条件时,网络停止迭代, K 就是网络运行的最终层数,所得信道向量恢复模块输出为 u_K 。最终将 u_K 输入到由神经元组成的全连接层中,输出估计的水声信道向量 $\hat{\mathbf{u}}$ 。

[0078] S6、生成用于训练神经网络的数据集 \mathcal{D} ,数据集 \mathcal{D} 中每组数据样本包括导频处的信道向量 u_p 和真实的信道向量 u_{real} ;

[0079] S7、利用数据集 \mathcal{D} 对神经网络进行迭代训练,使损失函数收敛到最小值,得到模型参数集 \mathcal{S}^* ;

[0080] S8、使用模型参数集 \mathcal{S}^* 初始化神经网络,采集真实场景信号,经数据转换和归一化后输入神经网络,得到输出 $\hat{\mathbf{u}}$, $\hat{\mathbf{u}}$ 为估计出来的信道向量。

[0081] 本实施例测试结果如下:端到端深度学习算法估计误差为0.02902,深度展开算法估计误差为0.01948,本发明改进的深度展开算法估计误差为0.01549。可见本发明公开的深度展开学习算法估计性能更好。

[0082] 上述实施例为本发明较佳的实施方式,但本发明的实施方式并不受上述实施例的限制,其他的任何未背离本发明的精神实质与原理下所作的改变、修饰、替代、组合、简化,均应为等效的置换方式,都包含在本发明的保护范围之内。

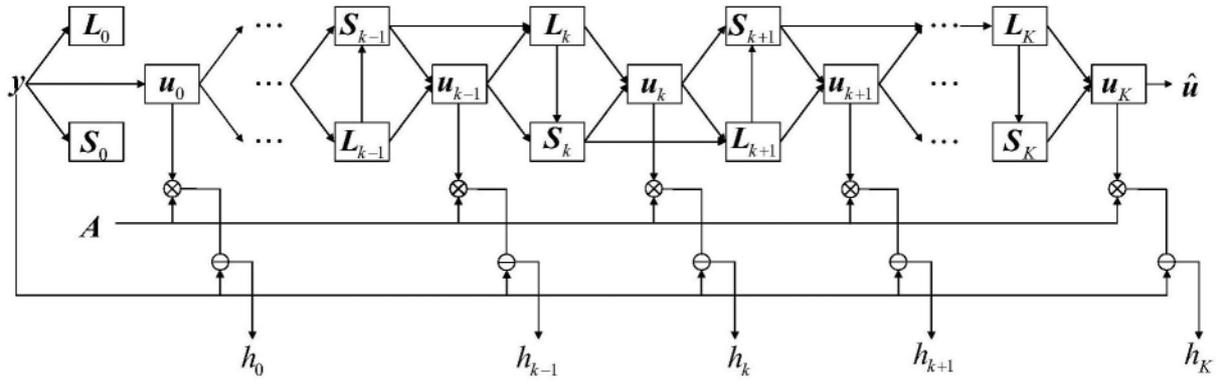


图1

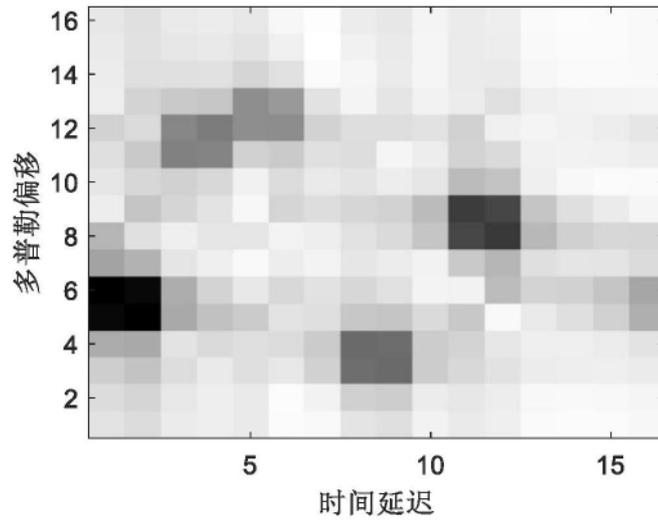


图 2(a)

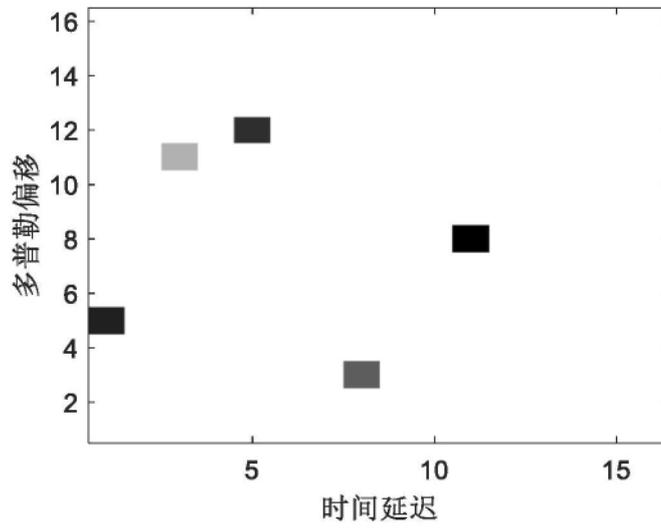


图 2(b)

图2

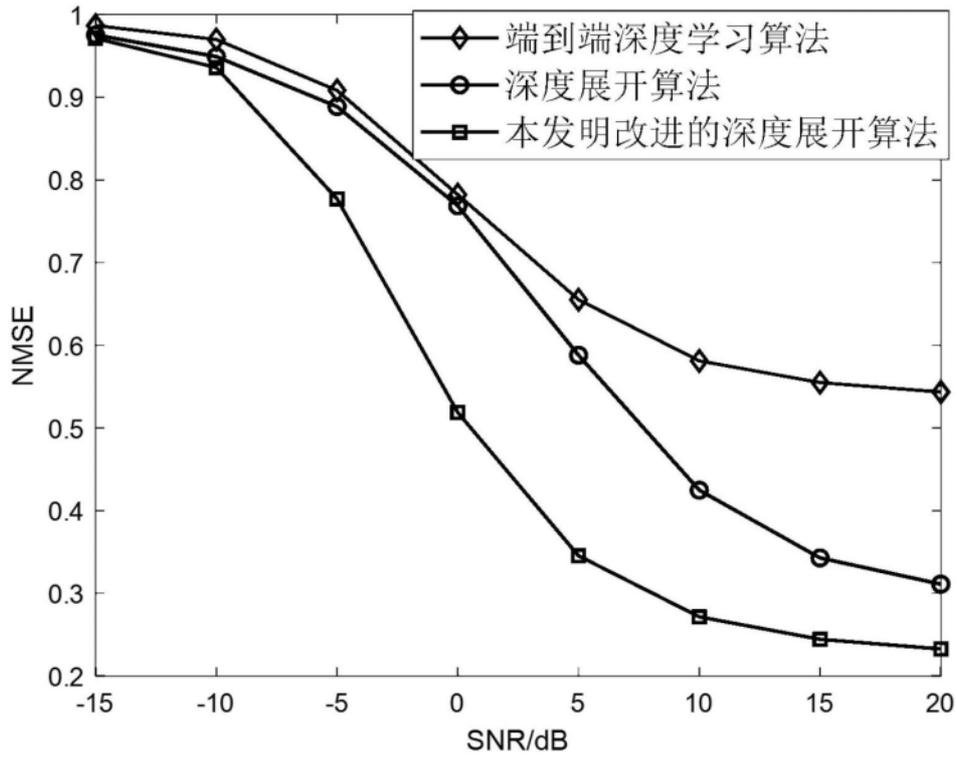


图 3(a)

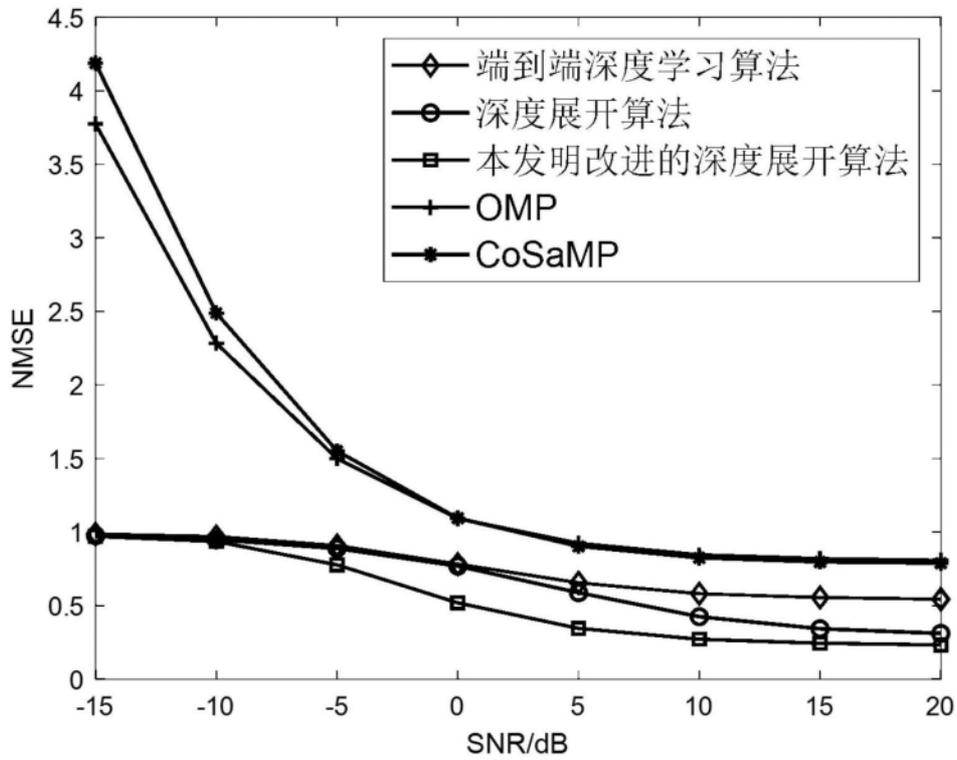


图 3(b)

图3

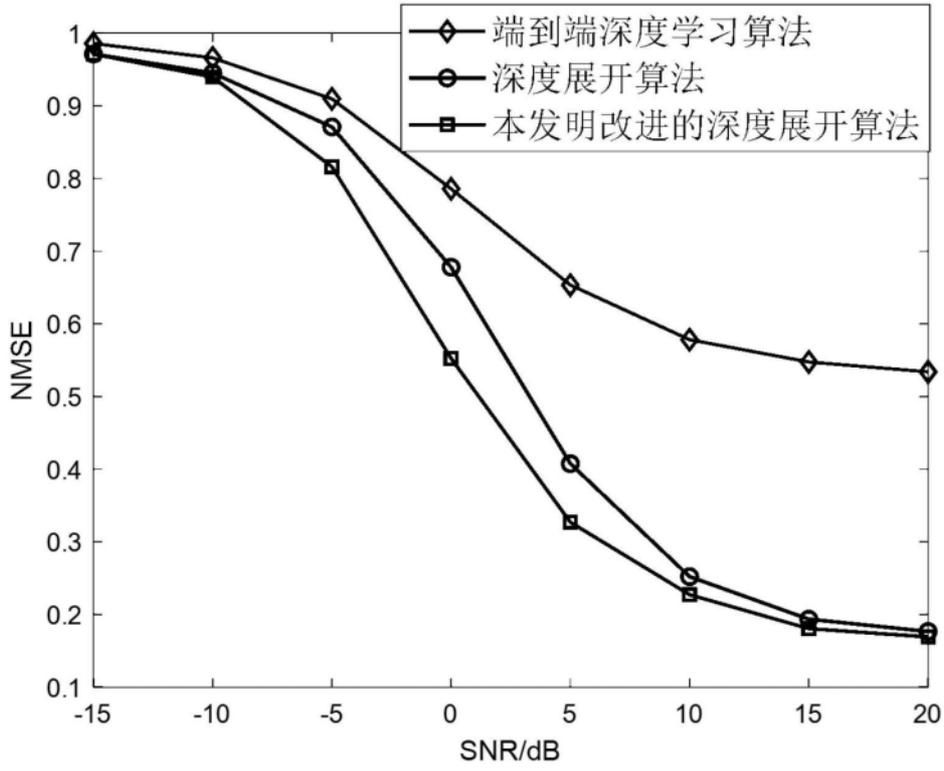


图 4(a)

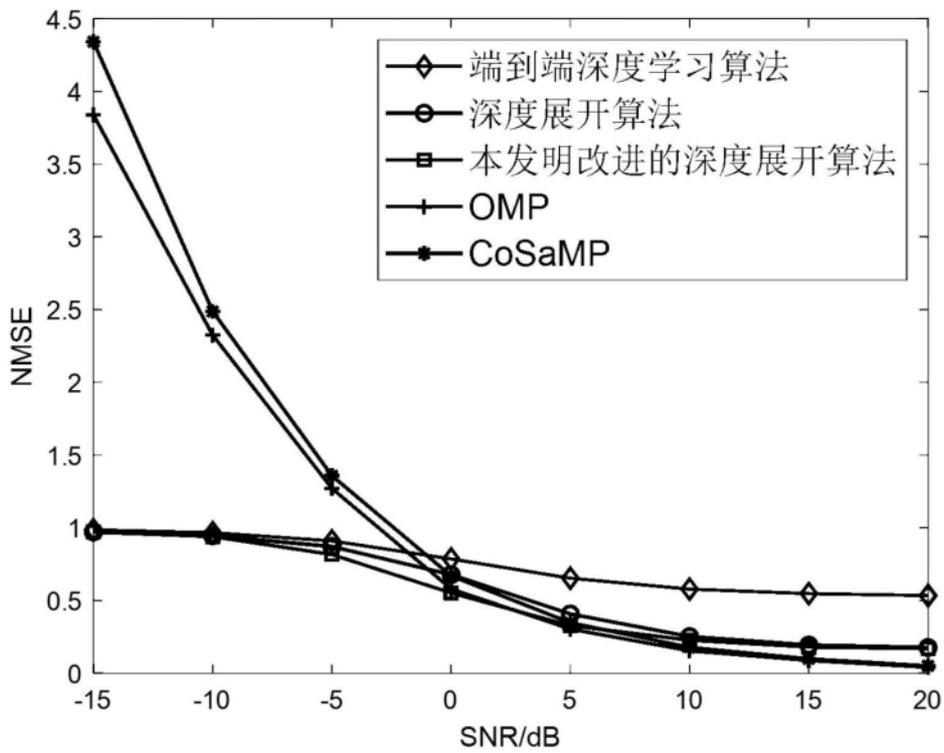


图 4(b)

图4