

基于条件神经过程的星上多用户检测算法

刘轶伦¹, 金 亮², 李佳立², 朱立东¹

(1. 电子科技大学通信抗干扰技术国家级重点实验室, 四川 成都 611731;

2. 航天恒星科技有限公司, 北京 100095)

摘要: 全球全天候无缝覆盖的特性使得卫星通信成为6G潜在的重要组成部分, 而实现卫星智能化的一个重要前提是卫星具有星上处理能力。多用户检测是无线通信中抑制多址干扰的经典方法, 如最小均方误差、高斯过程回归等算法, 由于检测过程中需要逆矩阵, 算法复杂度通常为立方级, 难以直接应用到处理能力受限的卫星平台。条件神经过程结合神经网络低复杂度和高斯过程小样本的特性, 利用神经网络将高斯过程参数化, 避免求逆矩阵, 从而降低计算复杂度。研究条件神经过程在多用户检测中的应用, 仿真结果表明, 在降低复杂度的同时, 条件神经过程还极大地提升了多用户检测的误码率性能。

关键词: 卫星通信; 多用户检测; 高斯过程; 条件神经过程; 低复杂度

中图分类号: TP393

文献标识码: A

doi: 10.11959/j.issn.2096-8930.2021044

On-board Multi-User Detection Algorithm Based on Conditional Neural Process

LIU Yilun¹, JIN Liang², LI Jiali², ZHU Lidong¹

1. National Key Laboratory of Science and Technology of Communications, University of Electronic Science and Technology of China, Chengdu 611731, China

2. Space Star Technology Co., Ltd., Beijing 100095, China

Abstract: With the characteristics of all-terrain, all-weather and seamless coverage, satellite communications have become a potentially important part of 6G. An important prerequisite for achieving satellite intelligence is that the satellite have on-board processing capabilities. Multi-user detection (MUD) is a classic method of suppressing multiple access interference (MAI) in wireless communication, such as MMSE, Gaussian process regression (GPR) and other algorithms. Due to the inverse matrix required in the detection process, the algorithm complexity is usually cubic, and it is difficult to directly apply to satellite platforms because of its limited processing capabilities. The conditional neural process combined the characteristics of the low complexity of the neural network and the data-efficient of the Gaussian process. The neural network was used to parameterized the Gaussian process to avoided the inversion of the matrix, thereby reduced the computational complexity. The application of conditional neural process in MUD was studied. The simulation results showed that, while reduced complexity, conditional neural process also greatly improved the performance of bit error rate (BER).

Keywords: satellite communication, multi-user detection, Gaussian process, conditional neural process, low complexity

1 引言

天地一体化信息网络^[1-3]是实现全球互联互通、随遇接入的关键基础设施, 业务范围包括了互联网^[4]、物

联网、航空、船舶专网等多种类型, 其中, 卫星作为天地一体化信息网络的天基节点, 覆盖范围远大于地面基站, 承担着用户接入、转发、路由等功能。根据通信卫

收稿日期: 2021-09-09; **修回日期:** 2021-11-05

基金项目: 国家重点研发计划项目 (No.2019YFB1803102); 国家自然科学基金面上项目 (No.61871422)

Foundation Items: National Key R&D Program of China (No.2019YFB1803102), National Natural Science Foundation of China (No.61871422)

星平台能力,可分为透明转发和星上处理两种体制。透明转发体制中卫星仅作为转发器,所有接入、管理功能均在地面完成,此体制实现简单但会导致噪声固化,并且难以实现网状组网;星上处理体制则是在卫星上完成调制解调、编码译码等步骤,并可进行星间路由,更适用于构建智能的天地一体化信息网络。

由于频率、时隙资源有限,不同用户可能会叠加在相同频段、时隙上传输从而形成多址干扰,严重影响系统容量和通信质量,因此,抑制多址干扰是无线多用户通信中的核心问题。由于卫星覆盖范围大、用户数量和业务种类更多,多址干扰抑制在卫星通信中更加重要。常用方法为多用户检测技术。然而,由于卫星的处理能力远不如地面基站,传统多用户检测器的复杂度较高,无法直接应用于星上处理。为了克服上述问题,本文提出了一种用于星上的多用户检测算法,具有低复杂度特性和很好的误码率(Bit Error Rate, BER)性能。

2 相关工作

多用户检测器按照检测性能可分为最优检测器和次优多用户检测器^[5]。参考文献[6]证明了最大似然序列检测(Max Likelihood Sequence Detection, MLSD)器为渐进最优检测器,然而其计算复杂度为指数级,仅具有理论意义并无实际应用价值。为了将算法复杂度降低至工程上可实现的程度,研究人员广泛地研究了各类次优多用户检测器,按照是否需要先验信息可分为非盲型和盲型检测器。其中,典型的非盲型检测器为干扰对消型检测器,如串行干扰对消^[7](Successive Interference Cancellation, SIC)、并行干扰消除^[8](Parallel Interference Cancellation, PIC)。干扰对消型检测器结构简单,复杂度低,性能优异,但处理时延长且需已知干扰用户的数量、扩频码等先验信息。盲型次优多用户检测器通过导频辅助得到检测器的权重向量,无须已知上述先验信息,从而更加适用于实际通信系统。

最小均方误差(Minimum the Mean Square Error, MMSE)估计多用户检测器^[9]通过最小化与导频的均方误差得到MMSE准则下的最优权重向量,同时计算复杂度降低至 $O(N^3)$,其中, N 是训练序列样本数。MMSE估计是一种线性检测方法,在处理非线性系统的多用户检测问题上误码率性能较差,如直接序列扩频码分多址(Direct-Sequence Code-Division Multiple Access, DS-CDMA)系统。高斯过程回归(Gaussian Process Regression, GPR)是贝叶斯学习的一种,广泛应用在机器学习^[10]、信号处理^[11]等领域。参考文献[12]首次将GPR应用到多用户检测中,并指出GPR本质

上是一种非线性检测器。通过预先假设模型的概率分布,GPR无须已知模型的精确参数,而是通过调整概率分布参数表示模型的基本性质,因此所需训练样本数量少、收敛速度快,在同等复杂度下误码率性能优于MMSE估计检测器。

然而,MMSE估计和GPR检测算法都需要求逆矩阵,复杂度依旧较高,难以直接部署在星上。稀疏谱高斯过程回归^[13](Sparse Spectrum Gaussian Process Regression, SSGPR)假设训练集的所有抽样满足平稳的高斯过程,通过在频谱中抽出一些样本取均值近似核函数的蒙特卡洛方法使计算复杂度降低至 $O(NM^2)$,其中, M 是基函数数量且 $M \ll N$ 。参考文献[14]将SSGPR作为多用户检测器应用到DS-CDMA系统中,但仿真表明此方法相比于GPR检测器BER性能有所下降。参考文献[15]将快速傅里叶变换、对数行列式和随机梯度下降用于GPR检测,利用快速傅里叶变换将正定协方差矩阵从时空域变为频域,利用Parseval定理和卷积定理的约束条件进行恒等变换;并使用随机梯度求解超参数,提出了用于多用户检测的快速高斯过程回归(Fast Gaussian Process Regression, FGPR)算法,其复杂度达到 $O(M \log N)$,并且较GPR检测BER性能损失很小。

为了进一步降低GPR的复杂度,参考文献[16-17]研究了利用神经网络降低GPR的方法。典型的是参考文献[16]提出的条件神经过程(Conditional Neural Process, CNP)。CNP用多层神经网络拟合GPR算法过程中的矩阵求逆,并与GPR的代价函数相同,通过随机梯度下降完成训练,从而使CNP的训练和运行均为线性复杂度。同时,CNP兼具神经网络低复杂度和高斯过程回归小样本数量的特性,对导频长度要求低。受上述工作启发,本文提出了基于CNP的多用户检测算法,同时借助神经网络的训练集的张量形式,直接训练高维的接收信号,使基于CNP的多址干扰抑制算法远优于传统GPR算法,接近单用户系统的BER性能。

3 系统模型

3.1 DS-CDMA多用户检测模型

考虑一个理想同步的DS-CDMA系统,假设共有 K 个用户,扩频序列周期长度为 M ,第 k 个用户的扩频序列为 $\mathbf{s}_k = [s_{k,1}, \dots, s_{k,M}]^T$, $s_{k,i} \in \{-1, +1\}$, $k=1,2,\dots,K$, $i=1,2,\dots,M$ 。令 $\mathbf{b}_i(k)$ 表示在时刻 t 第 k 个用户传输比特组成的向量,则接收信号 $\mathbf{x}_t$ 的矩阵形式表示如下

$$\mathbf{x}_t = \mathbf{S} \mathbf{A} \mathbf{b}_t + \mathbf{n}_t \quad (1)$$

其中, $\mathbf{S} = [\mathbf{s}_1, \dots, \mathbf{s}_K]^T$ 是 $M \times K$ 维矩阵,第 k 列对应第 k 个用户的扩频序列。 $\mathbf{A}$ 是 $K \times K$ 维的对角矩阵,其中第 k 个对角线元素表示第 k 个用户的幅度。 $\mathbf{b}_t = [b_t(1), b_t(2), \dots, b_t(K)]^T$, $\mathbf{n}_t$ 为

实数域零均值高斯随机向量, 协方差为 $\mathbb{E}[n_i n_i^T] = \sigma^2 I$, σ^2 为高斯噪声的功率谱密度。

不失一般性, 假设第 k 个用户为目标用户, 则对于接收端解扩得到 $\hat{b}_i(k)$ 的过程可表示为

$$\hat{b}_i(k) = \text{sign}(\omega_k^T \mathbf{x}_i) \quad (2)$$

其中, $\text{sign}(v) = \begin{cases} 1, & v > 0 \\ -1, & v \leq 0 \end{cases}$, ω_k 表示为第 k 个用户接收机的本地序列 (也称权重向量)。若直接使用第 k 个用户的扩频序列作为 ω_k , 等于将其他用户干扰视为噪声, 难以有效抑制多址干扰, 因此通过导频估计合适的 ω_k 。

3.2 MMSE估计检测算法

MMSE准则目的是通过最小化与导频的均方误差得到估计 $\hat{\omega}_k$

$$\hat{\omega}_k = \arg \min_{\omega_k} \mathbb{E} \left[(b_i(k) - \omega_k^T \mathbf{x}_i)^2 \right] = \mathbf{R}_{xx}^{-1} \mathbf{R}_{xb} \quad (3)$$

其中, $\mathbf{R}_{xx} = \mathbb{E}[\mathbf{x}_i \mathbf{x}_i^T]$ 为接收信号的自相关, $\mathbf{R}_{xb} = \mathbb{E}[\mathbf{x}_i b_i(k)]$ 为接收信号和导频信号的互相关。那么, MMSE估计检测算法先通过式(3)求得权重向量 $\hat{\omega}_k$, 再将 $\hat{\omega}_k$ 代入式(2)完成接收信号的解扩。

3.3 高斯过程回归算法

假设共传输 N 比特导频, 令 $\mathbb{D} = \{\mathbf{x}_i, b_i(k)\}_{i=1}^N$, 其中 $\mathbf{x}_i \in \mathcal{R}^d$ 为导频对应的接收信号, $b_i(k)$ 为第 k 个用户传输的导频比特。令 $\mathbf{b}(k) = [b_1(k), b_2(k), \dots, b_N(k)]^T$, 高斯过程的线性回归模型可表示为

$$\mathbf{b}(k) = \Phi^T \omega + \mathbf{n}, \quad \mathbf{n} \sim \mathcal{N}(\mathbf{0}, \sigma_n^2 \mathbf{I}_N) \quad (4)$$

其中, $\Phi = [\phi(\mathbf{x}_1), \dots, \phi(\mathbf{x}_N)]$, $\phi(\cdot)$ 表示基函数。 σ_n^2 为样本高斯噪声的方差, $\mathbf{I}_N$ 为 N 阶单位对角矩阵。

记 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T$, 则已知 $\mathbf{X}$ 和 ω 时, $\mathbf{b}(k)$ 的条件概率分布服从

$$p(\mathbf{b}(k) | \mathbf{X}, \omega) = \mathcal{N}(\mathbf{b}(k) | \Phi^T \omega, \sigma_n^2 \mathbf{I}_N) \quad (5)$$

假设 ω 为一个零均值, 分布服从 $\mathcal{N}(\omega | \mathbf{0}, \sigma_\omega^2 \mathbf{I})$ 的高斯随机变量。由贝叶斯准则可知, ω 的后验概率分布等于

$$p(\omega | \mathbf{b}(k), \mathbf{X}) = \frac{p(\omega) p(\mathbf{b}(k) | \mathbf{X}, \omega)}{p(\mathbf{b}(k) | \mathbf{X})} \quad (6)$$

由式(6)可知, 边际似然函数 $p(\mathbf{b}(k) | \mathbf{X})$ 与 ω 无关, 因此可将 ω 的后验概率分布重写为^[8]

$$\begin{aligned} p(\omega | \mathbf{b}(k), \mathbf{X}) &\propto \exp \left(-\frac{1}{2\sigma_n^2} (\mathbf{b}(k) - \Phi^T \omega)^T (\mathbf{b}(k) - \Phi^T \omega) \right) \exp \left(-\frac{1}{2\sigma_\omega^2} \omega^T \omega \right) \\ &\propto \exp \left(-\frac{1}{2} (\omega - \bar{\omega})^T \left(\frac{1}{\sigma_n^2} \Phi \Phi^T + \frac{1}{\sigma_\omega^2} \mathbf{I} \right) (\omega - \bar{\omega}) \right) \end{aligned} \quad (7)$$

其中, $\bar{\omega} = \frac{1}{\sigma_n^2} \left(\frac{1}{\sigma_n^2} \Phi \Phi^T + \frac{1}{\sigma_\omega^2} \mathbf{I} \right)^{-1} \Phi \mathbf{b}(k)$, 则 ω 的后验概率分布可表示为

$$p(\omega | \mathbf{b}(k), \mathbf{X}) = \mathcal{N} \left(\omega | \bar{\omega}, \left(\frac{1}{\sigma_n^2} \Phi \Phi^T + \frac{1}{\sigma_\omega^2} \mathbf{I} \right)^{-1} \right) \quad (8)$$

其中, $\mathbf{B} = \frac{1}{\sigma_n^2} \Phi \Phi^T + \frac{1}{\sigma_\omega^2} \mathbf{I}$, 则 ω 的最大后验概率估计可计算为

$$\begin{aligned} \hat{\omega}_{\text{MAP}} &= \arg \max_{\omega} \log p(\omega | \mathbf{b}(k), \mathbf{X}) \\ &= \arg \min_{\omega} \left\{ \frac{1}{2} (\omega - \bar{\omega})^T \left(\frac{1}{\sigma_n^2} \Phi \Phi^T + \frac{1}{\sigma_\omega^2} \mathbf{I} \right) (\omega - \bar{\omega}) \right\} \end{aligned} \quad (9)$$

通过求得 $\hat{\omega}_{\text{MAP}}$, 对于数据对应的接收信号 $\mathbf{X}_{\text{data}}$, 估计值 $\hat{b}(k)$ 可表示为

$$\begin{aligned} p(\hat{b}(k) | \mathbf{b}(k), \mathbf{X}, \mathbf{x}_{\text{data}}) &= \mathcal{N} \left(\hat{b}(k) | \phi(\mathbf{x}_{\text{data}})^T \Phi (\Phi^T \Phi + \lambda \mathbf{I})^{-1} \mathbf{b}(k), \right. \\ &\quad \left. \phi(\mathbf{x}_{\text{data}})^T \Phi (\Phi^T \Phi + \lambda \mathbf{I})^{-1} \Phi^T \phi(\mathbf{x}_{\text{data}}) \right) \end{aligned} \quad (10)$$

式(10)分布的均值即为估计值

$$\hat{b}(k) = \phi(\mathbf{x}_{\text{data}})^T \Phi (\Phi^T \Phi + \lambda \mathbf{I})^{-1} \mathbf{b}(k) = \mathbf{k}^T \mathbf{C}^{-1} \mathbf{b}(k) \quad (11)$$

其中, $\mathbf{C}_{ij} = \mathbf{k}(\mathbf{x}_i, \mathbf{x}_j) + \lambda \delta_{ij}$, $\mathbf{k} = [k(\mathbf{x}_{\text{data}}, \mathbf{x}_1), \dots, k(\mathbf{x}_{\text{data}}, \mathbf{x}_N)]^T$, $k(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$ 是核函数, $\lambda = \sigma_n^2 / \sigma_\omega^2$ 。显然, 得到估计值必须确定所使用的核函数。令核函数的超参数为 $\theta = [\theta_1, \theta_2, \lambda]$, 所采用的核函数类型为高斯核函数, 可表示为

$$k(\mathbf{x}_i, \mathbf{x}_j) = \theta_1 \exp \left(-\theta_2 \|\mathbf{x}_i - \mathbf{x}_j\|^2 \right) \quad (12)$$

超参数的最优解可通过式(13)计算

$$\begin{aligned} \theta^* &= \arg \min_{\theta} p(\mathbf{b}(k) | \mathbf{X}, \theta) \\ &= \arg \min_{\theta} \frac{1}{\sqrt{|2\pi \mathbf{C}|}} \exp \left(-\frac{1}{2} \mathbf{b}(k)^T \mathbf{C}^{-1} \mathbf{b}(k) \right) \end{aligned} \quad (13)$$

由式(13)可知, 在训练得到 θ^* 过程中需要求 $\mathbf{C}^{-1}$, 由于 $\mathbf{C}$ 为 N 阶方阵, 此时训练复杂度将达到 $O(N^3)$ 。

4 基于条件神经过程的多用户检测算法

4.1 条件神经过程

由上述分析可知, 高斯过程回归包括两个阶段: 训练阶段和预测阶段。同样地, 条件神经过程 (CNP) 利用神经网络的编码器-聚合器-译码器结构还原这两个阶段, 如图1所示。使用译码器预测输出值, 即假设式(10)中的均值函数可由一个表征向量 $\mathbf{r}$ 和一个神经网络的组合表示

$$\zeta = g_\theta(\mathbf{x}, \mathbf{r}) := \phi(\mathbf{x})^T \Phi (\Phi^T \Phi + \lambda \mathbf{I})^{-1} \mathbf{b}(k) \quad (14)$$




图1 条件神经过程算法示意

其中, g 为神经网络, θ 为神经网络的参数。表征向量 $\mathbf{r}$ 为训练超参数阶段所得到的表征。

GPR 训练超参数的过程 (如式(13)所示) 由编码器神经网络所替代

$$\mathbf{r}_i = h_{\theta}(\mathbf{x}_i, b_i(k)) \quad \forall (\mathbf{x}_i, b_i(k)) \in \{\mathbf{X}, \mathbf{b}(k)\} \quad (15)$$

其中, $\mathbf{r}_i$ 为单个训练样本得到的表征向量, 通过求均值得到表征向量 $\mathbf{r}$

$$\mathbf{r} = \frac{1}{N} \sum_{i=1}^N \mathbf{r}_i \quad (16)$$

表征向量 $\mathbf{r}$ 的作用在于挖掘发送信号 $\mathbf{b}(k)$ 与经过多址信道和 AWGN 信道后接收信号 $\mathbf{x}(k)$ 之间的概率分布特征, 例如高斯过程的均值变化、方差变化等, 并将此特征输入译码器估计数据比特。

4.2 训练过程

对于训练集 $\mathbb{D} = \{\mathbf{x}_i, b_i(k)\}_{i=1}^N$, 训练过程中条件神经过程的结构如下

$$\text{编码器: } \mathbf{r}_i = h(\mathbf{x}_i, b_i(k)) \quad \forall (\mathbf{x}_i, b_i(k)) \in \{\mathbf{X}, \mathbf{b}(k)\}$$

$$\text{聚合器: } \mathbf{r} = \frac{1}{N} \sum_{i=1}^N \mathbf{r}_i \quad (17)$$

$$\text{译码器: } \zeta_i = g_{\theta}(\mathbf{x}_i, \mathbf{r}) \quad \forall \mathbf{x}_i \in \mathbf{X}$$

其中, 输出 $\zeta_i = \mathcal{N}(\mu_i, \sigma_i^2)$, 表示高斯分布的均值和方差。 h , g 为多层感知机 (Multi-Layer Perception, MLP), 在数据维度低的通信信号场景下性能较好。通过梯度下降训练, CNP 的损失函数为

$$\mathcal{L}(\theta) = -E_{\mathbf{b}(k) \sim P} \left[E_M \left[\log p_{\theta} \left(\{\mathbf{x}_i\}_{i=1}^N \mid \mathbb{D}_M, \{\mathbf{x}_i\}_{i=1}^N \right) \right] \right] \quad (18)$$

其中, p_{θ} 是 $\mathbf{x}_i$ 的概率密度函数, $\mathbb{D}_M$ 是 $\mathbb{D}$ 的子集, 由 $\mathbb{D}$ 中任选 M 个元素组成, 且 $M \sim \mu(1, N), \mu(1, N)$ 表示在 1 至 N 的均匀分布。训练神经网络时, 每次迭代选择一个子集进行训练, 在下次迭代时放回并继续随机选取子集训练, 以避免训练出的模型过度拟合至单个函数, 从而尽可能地学习函数的分布。

4.3 复杂度分析

根据式(17)和式(18), 由于 MLP 的计算复杂度是

$O(N)$, 而条件神经过程的核心是神经网络, 并且通过编码器和译码器替代了高斯过程回归中的训练和预测过程, 从而避免了矩阵求逆, 因此条件神经过程计算复杂度也是 $O(N)$ 。

5 仿真结果

5.1 SNR对BER的影响

仿真参数设置: 周期为 31 的 Gold 序列, 8 个用户, 高斯白噪声信道, 用户符号为基带信号, 调制方式为 BPSK, 训练序列长度为 100 个符号。图 2 为不同算法在不同 SNR 条件下的 BER 性能比较。




图2 不同算法在不同SNR条件下的BER性能比较

由图2可知, 条件神经过程性能最为优越, 接近单用户性能极限。此时MMSE估计与高斯过程回归算法的BER性能还未达到0.1。图2中, 在使用周期为31比特的Gold序列, 8个用户的条件下, 所提出的新型多址干扰抑制算法性能优于传统方法近10 dB, 接近了单用户的性能。

5.2 神经网络结构与迭代次数对BER的影响

现在考虑神经网络结构对BER性能的影响。条件神经过程的结构是编码器、聚合器、译码器, 其中编码器和译码器均是神经网络, 它们的神经网络结构是不同的, 因为译码器主要进行解码, 若编码性能足够好, 解码的压力就会小得多。在此只考虑编码器神经网络的层数以及每一层神经元的个数对BER性能的影响。使用 $CNP(m, n, p)$ 描述条件神经过程, m 是编码器的层数, n 是译码器的层数, p 是每一层神经元的个数。

仿真参数设置: 周期为 31 的 Gold 序列, 8 个用户, 高斯白噪声信道, 用户符号为基带信号, 训练序列长度为

100个符号,调制方式为BPSK, SNR=-4 dB。考虑CNP (4,3,64)、CNP (4,3,32)、CNP (4,3,20)、CNP (3,3,20)共4种情况。

不同层数、神经元个数时的BER曲线如图3所示。由图3可知,编码器为4层时,每一层的神经元个数越多,达到BER稳定状态所需迭代次数就越少;64个神经元与32个神经元,最终的BER性能是一致的,而20个神经元迭代8 000次也未达到32个神经元的性能。这是因为输入的数据是31维,神经元个数过少,不利于高维空间的信号处理。另外,每一层20个神经元时,编码器只有3层神经网络难以收敛,与4层时的CNP相比性能也差。




图3 不同层数、神经元个数时的BER曲线

5.3 导频数与迭代次数对BER的影响




图4 不同样本数下BER性能迭代次数的关系

本文仿真了不同导频(训练样本)数对BER性能的影响。仿真参数设置:周期为31的Gold序列,8个用户,高斯白噪声信道,用户符号为基带信号,调制方式为BPSK,训练序列长度为100个符号, SNR=-4 dB, CNP (4,3,64)。

不同样本数量下BER性能迭代次数的关系如图4所示。由图4可知,训练样本数量越多,迭代收敛所需的次数越少。但从最终BER性能来看,训练样本数量为100个与训练样本数量为60个时BER性能几乎一致,这表明在实际导频序列设计时,使用适当的符号数量即可。训练样本数量为20个和10个时,性能差距较小,但样本数量为10个, BER性能会出现抖动,因此训练样本数量不宜过少。

6 结束语

条件神经过程结合了神经网络和高斯过程回归的优点,具备小样本的特性和线性计算复杂度,具有很大的灵活性和可拓展性,适用于星上的低复杂度需求。通过仿真验证了基于条件神经过程的多址干扰抑制算法的可行性,其在降低高斯过程复杂度的同时显著提升了多址干扰抑制的效果,具有良好的应用前景。

参考文献:

- [1] 翟立君, 潘沐铭, 汪春霆. 卫星5G技术的发展和展望[J]. 天地一体化信息网络, 2021, 2(1): 1-9.
ZHAI L J, PAN S M, WANG C T. Development and prospect of satellite 5G technology[J]. Space-Integrated-Ground Information Networks, 2021, 2(1): 1-9.
- [2] 孙晨华, 庞策. 低轨卫星互联网体系和技术体制研究发展路线思考[J]. 无线电通信技术, 2021, 47(5): 521-527.
SUN C H, PANG C. Thoughts on the research and development route of the LEO satellite Internet system and technology system[J]. Radio Communications Technology, 2021, 47(5): 521-527.
- [3] 吴巍. 天地一体化信息网络发展综述[J]. 天地一体化信息网络, 2020, 1(1): 1-16.
WU W. Survey on the development of space-integrated-ground information network[J]. Space-Integrated-Ground Information Networks. 2020,1(1):1-16.
- [4] 张更新, 王运峰, 丁晓进, 等. 卫星互联网若干关键技术研究[J]. 通信学报, 2021, 42(8): 1-14.
ZHANG G X, WANG Y F, DING X J, et al. Research on several key technologies of satellite Internet[J]. Journal on Communications. 2021,42(8):1-14.
- [5] 李井源. 卫星CDMA通信系统多用户检测与信干比估计算法研究[D]. 长沙: 国防科技大学, 2006.

- LI J Y. Study of the multiuser detection and signal to interference ratio estimation in satellite CDMA systems[D]. Changsha: National University of Defense Technology. 2006.
- [6] VERDU S. Minimum probability of error for asynchronous Gaussian multiple-access channels[J]. IEEE Transactions on Information Theory, 1986,32(1): 85-96.
- [7] SALA J, VILLARES J, REY F. Asymptotic and finite user PER analysis of successive interference cancellation for DS-CDMA[J]. IEEE Communications Letters, 2011, 15(11): 1145-1147.
- [8] DIVSALAR D, SIMON M K, RAPHAELI D. Improved parallel interference cancellation for CDMA[J]. IEEE Transactions on Communications, 1998, 46(2): 258-268.
- [9] HALUNGA S V, VIZIREANU N. Performance evaluation for conventional and MMSE multiuser detection algorithms in imperfect reception conditions[J]. Digital Signal Processing, 2010, 20(1): 166-178.
- [10] RASMUSSEN C E, WILLIAMS C K I. Gaussian processes for machine learning[M]. Cambridge: The MIT Press, 2005.
- [11] PEREZ-CRUZ F, VAN V S, MURILLO-FUENTES J J, et al. Gaussian processes for nonlinear signal processing: an overview of recent advances[J]. IEEE Signal Processing Magazine, 2013, 30(4): 40-50.
- [12] MURILLO F J J, PEREZ C F. Gaussian process regressors for multiuser detection in DS-CDMA systems[J]. IEEE Transactions on Communications, 2009, 57(8): 2339-2347.
- [13] LAZARO G M, QUINONERO C J, RASMUSSEN C E, et al. Sparse spectrum gaussian process regression[J]. Journal of Machine Learning Research, 2010, 11:1865-1881.
- [14] WANG S W, GU H L. Multiuser detection with sparse spectrum Gaussian process regression[J]. IEEE Communications Letters, 2012, 16(2): 164-167.
- [15] BUI D, LEE S. Fast Gaussian process regression for multiuser detection in DS-CDMA[J]. IEEE Communications Letters, 2017, 21(2): 406-409.
- [16] GARNELO M, ROSENBAUM D, MADDISON C J, et al. Conditional neural processes[C]// 35th International Conference on Machine Learning. [S.L.:s.n.], 2018.
- [17] GARNELO M, SCHWARZ J, ROSENBAUM D, et al. Neural processes[EB]. 2018.
- [18] KIM H, MNIH A, SCHWARZ J, et al. Attentive neural processes[Z]. 2019.
- [19] RUGINI L, BANELLI P, CACOPARDI S. A full-rank regularization technique for MMSE detection in multiuser CDMA systems[J]. IEEE Communications Letters, 2005, 9(1): 34-36.

[作者简介]



刘轶伦（1996—），男，电子科技大学博士生，主要研究方向为卫星通信传输与组网。

金亮（1986—），男，航天恒星科技有限公司高级工程师，主要从事高低轨卫星通信地面系统研究工作。

李佳立（1988—），男，航天恒星科技有限公司中级工程师，主要研究方向为卫星通信系统网络设计。

朱立东（1968—），男，博士，电子科技大学教授，博士生导师，主要研究方向为卫星通信传输与组网、天地一体化信息网络。