



研究与开发

基于信道状态智能预测的星地自适应调制编码技术研究

季铄, 孙耀华, 彭木根

(北京邮电大学网络与交换技术全国重点实验室, 北京 100876)

摘要: 在手机直连低轨卫星场景中, 针对自适应调制编码技术依赖的信道质量指示信息非实时反馈的问题, 提出一种基于深层回声状态网络的信道状态预测模型, 并根据该预测模型提出一种调制编码方式智能选择机制, 即发送端基于信道预测结果选择适应当前信道的调制编码方式。仿真验证表明, 基于信道预测的自适应调制编码可以在一定程度上提升链路的误码性能。

关键词: 低轨卫星通信; 信道状态预测; 自适应调制编码

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024214

Research on satellite-ground adaptive modulation and coding techniques based on intelligent prediction of channel state

JI Shuo, SUN Yaohua, PENG Mugen

State Key Laboratory of Networking and Switching Technology, Beijing University of Posts and Telecommunications, Beijing 100876, China

Abstract: In the scenario of direct mobile phone connection to low-earth orbit satellites, to address the issue of non-real-time feedback of channel quality indication information that adaptive modulation and coding techniques rely on, a channel state prediction model based on deep echo state network was proposed. Furthermore, an intelligent selection mechanism for modulation and coding schemes was introduced based on the prediction model, wherein the transmitter selects the modulation and coding scheme suited for the current channel conditions based on the channel prediction results. Simulation validation has demonstrated that adaptive modulation and coding based on channel prediction can improve the bit error performance of the link to a certain extent.

Key words: low-earth orbit satellite communication, channel state prediction, adaptive modulation and coding

0 引言

卫星通信系统拥有通信覆盖能力强、受地理及自然条件影响小等优势^[1], 可作为地面通信网

络的有力补充, 可以预见, 其将在下一代移动通信中扮演重要角色^[2-3]。根据轨道高度不同, 通信卫星分为低轨卫星、中轨卫星以及高轨卫星, 其中低轨卫星在通信时延与信号质量方面比另外



两种卫星更有优势,能够形成覆盖全球的密集组网星座^[4-5]。目前,国内外多家卫星公司正进行低轨卫星通信星座的研究与部署,包括星链(Starlink)、OneWeb等。

依托低轨卫星的手机直连卫星通信,面向6G建立全球范围空地一体化全覆盖通信网络,成为近年来的业界焦点^[6-8]。华为与苹果公司通过在手机中集成特定的卫星通信芯片,实现短报文发送功能;Lynk Global、AST SpaceMobile等公司计划对地面移动通信协议进行增强以提供手机直连卫星服务,目前正着手进行在轨测试^[9-11]。与此同时,第三代合作伙伴计划(3rd Generation Partnership Project, 3GPP)自Release 16起开始重点关注非地面网络(non-terrestrial network, NTN)的研究和标准化工作^[12],通过对地面移动通信体制进行适应性改进增强,以支持手机直连卫星通信。

作为一种链路自适应技术,自适应调制编码(adaptive modulation and coding, AMC)对保障手机直连卫星通信传输性能至关重要。具体地,以NTN卫星透明转发架构为例,手机终端通过参考信号进行信道估计,并将所得信道质量指示(channel quality indication, CQI)通过卫星反馈至地面基站,地面基站据此自适应调整调制编码方案(modulation and coding scheme, MCS)^[13]。相较地面通信场景,手机直连卫星通信往返时延较长,且无线信道相干时间小于信号传播时延^[14],导致发送端获得的CQI反馈信息存在过期现象,直接影响通信的误码率和频谱效率,因此,有必要在发送端进行信道状态预测^[15]。

通常信道状态预测问题被具化为时间序列预测,但传统的时间序列预测模型如自回归、移动平均模型^[16-18]只能捕获线性关系,限制了在复杂卫星通信环境中的应用。相比之下,机器学习具备高度的灵活性和高适应性,能更有效地处理非

线性预测问题^[19-20]。文献[21]介绍了一种利用深度神经网络进行信道预测的方法,该方法首先对需要预测的信道状态信息进行Z变换,随后输入深度神经网络中进行预测,但该算法在接收端移动或存在较大噪声时预测性能下降。文献[22]提出一种新的预测算法,该算法结合了卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN),首先通过CNN提取信道特征,然后利用RNN作为特征预测网络对特征进一步预测,实验表明,该方法有效提升了信道预测的准确性。回声状态网络(echo state network, ESN)是一种轻量化的循环神经网络^[23],因其实用性强、概念简单、易于实现等优点,近年来被广泛应用于多个领域,包括工业能源指标预测、动脉血压预测等,且在這些应用中均展现出良好的性能^[24]。

本文提出了一种基于回声状态网络的信道预测模型,并根据所提模型提出了基于信道预测的MCS智能选择机制,即基站根据信道预测结果提前切换适应当前信道的调制编码方式,以对抗星地传输存在的高反馈时延。此外,本文搭建了基于5G NTN协议的链路级仿真平台,并验证了所提信道预测模型的准确性,以及基于信道预测的MCS智能选择机制的有效性。

1 基于回声状态网络的信道状态预测

1.1 回声状态网络算法原理

ESN是一种递归神经网络,由输入层、储备池和输出层3部分构成,其结构如图1所示。ESN各层之间通过神经元相连,每个连接拥有一个权重,所有连接构成对应的权值矩阵。输入信号 $u(n)$ 经过输入权矩阵 W^{in} 进入储备池,储备池用于提取输入序列特征,并随机布置神经元,神经元通过内部连接权矩阵 W 相连,储备池的输出构成网络内部状态向量 $x(n)$,该向量由输出连接权矩阵 W^{out} 送入输出层。输入连接

权矩阵 W^{in} 与内部连接权矩阵 W 仅在网络初始化阶段随机生成, 并不会在后续训练过程进行调整, 训练阶段仅调整输出连接权矩阵 W^{out} , 从而有效减少了 ESN 的训练开销, 使得 ESN 更加适用于实际场景。




图1 ESN结构示意图

ESN 结构中包含的输入层、储备池以及输出层, 分别具有 M 、 N 、 L 个神经元, 在 n 时刻的输入单元、内部状态和输出单元可以由式 (1) ~ 式 (3) 表示。

$$\mathbf{u}(n)=[u_1(n), u_2(n), \dots, u_M(n)]^T \quad (1)$$

$$\mathbf{x}(n)=[x_1(n), x_2(n), \dots, x_N(n)]^T \quad (2)$$

$$\mathbf{y}(n)=[y_1(n), y_2(n), \dots, y_L(n)]^T \quad (3)$$

在 $n+1$ 时刻, 外部输入为 $u(n+1)$, 储备池内部状态更新方程如式 (4) 所示, 网络输出方程如式 (5) 所示。

$$\mathbf{x}(n+1)=(1-\alpha)\mathbf{x}(n)+\alpha f(W^{\text{in}}\mathbf{u}(n+1)+W\mathbf{x}(n)) \quad (4)$$

$$\mathbf{y}(n+1)=f^{\text{out}}(W^{\text{out}}\mathbf{x}(n+1)) \quad (5)$$

其中, $f(\cdot)$ 与 $f^{\text{out}}(\cdot)$ 分别表示储备池与输出层的激活函数, 通常 $f(\cdot)$ 为非线性函数, 如 $\tanh$ 与 sigmoid 函数, $f^{\text{out}}(\cdot)$ 为恒等函数, α 为泄露率, 表示储备池内部状态的更新速度。

训练过程可以看作输出连接权矩阵 W^{out} 调整的过程, W^{out} 求解完成代表网络训练结束, 通常采用岭回归对 W^{out} 进行求解, 如式 (6) 所示。

$$W^{\text{out}}=\mathbf{Y}^{\text{target}}\mathbf{X}^T(\mathbf{X}\mathbf{X}^T+\gamma\mathbf{I})^{-1} \quad (6)$$

其中, $\mathbf{Y}^{\text{target}}$ 为目标值输出矩阵, $\mathbf{X}$ 为储备池输出, γ 和 $\mathbf{I}$ 分别为正则化系数和单位矩阵。

1.2 深层回声状态网络算法原理

深层回声状态网络 (deep echo state network, DeepESN) 是 ESN 的扩展, 引入了深度学习中层叠结构的概念, 提高了处理复杂时间序列的能力。DeepESN 结构示意图如图 2 所示, DeepESN 由多个储备池层叠组成, 第一层储备池的输入为外部序列, 随后每一层储备池的输出作为下一层储备池的输入, 并且各储备层之间的状态信息传输没有时延^[25]。与 ESN 类似, 输入层至第一层储备池之间通过输入连接权矩阵 W^{in} 连接,




图2 DeepESN结构示意图



每一层内部状态矩阵由 $W^{(i)}$ 表示, 并且最后一层储备池通过 W^{out} 连接至输出层。设储备池总层数为 N_L , 则 DeepESN 的内部状态更新方程如下所示。

$$\begin{cases} \mathbf{x}^{(i)}(n) = (1 - \alpha^{(i)})\mathbf{x}^{(i)}(n-1) + \\ \alpha^{(i)} f(W^{\text{in}} \mathbf{u}(n) + W^{(i)} \mathbf{x}^{(i)}(n-1)), i=1 \\ \mathbf{x}^{(i)}(n) = (1 - \alpha^{(i)})\mathbf{x}^{(i)}(n-1) + \\ \alpha^{(i)} f(W^{(i)} \mathbf{x}^{(i-1)}(n) + W^{(i)} \mathbf{x}^{(i)}(n-1)), i>1 \end{cases} \quad (7)$$

DeepESN 的网络输出方程如式 (8) 所示, 由式 (8) 可知, 网络输出结果与每层储备池的内部状态都有关, 每层储备池的内部状态都用作输出层的输入。

$$\mathbf{y}(n) = f^{\text{out}}(W^{\text{out}}[\mathbf{x}^{(1)}(n); \mathbf{x}^{(2)}(n); \dots; \mathbf{x}^{(N_L)}(n)]) \quad (8)$$

考虑 DeepESN 中的较高层与外部输入接触较少, 如果较低层储备池没有有效地捕捉和传递关键信息, 可能会导致信息在传递过程中丢失, 使得网络的学习能力下降。为克服该问题, 进一步为每个储备池单独提供外部输入, 此时 DeepESN 变体结构的网络输出方程与式 (8) 一致, 内部状态更新方程如式 (9) 所示。

$$\begin{cases} \mathbf{x}^{(i)}(n) = (1 - \alpha^{(i)})\mathbf{x}^{(i)}(n-1) + \\ \alpha^{(i)} f(W^{\text{in}} \mathbf{u}(n) + W^{(i)} \mathbf{x}^{(i)}(n-1)), i=1 \\ \mathbf{x}^{(i)}(n) = (1 - \alpha^{(i)})\mathbf{x}^{(i)}(n-1) + \\ \alpha^{(i)} f(W^{(i)}[\mathbf{u}(n); \mathbf{x}^{(i-1)}(n)] + W^{(i)} \mathbf{x}^{(i)}(n-1)), i>1 \end{cases} \quad (9)$$

1.3 基于深层回声状态网络的信道状态预测模型

文献[26]表明, 储备池的参数设置对其性能以及整个 ESN 的预测能力有显著影响, 而在传统 ESN 中, 储备池通常是随机生成的, 且储备池参数的选取往往在预设参数范围内进行尝试, 或基于经验进行选择, 该方法存在较大的不确定性。因此, 本文采用遗传算法对储备池参数的选择进行优化, 遗传算法优化储备池参数流程如图 3 所示, 具体步骤如下。

步骤 1 明确优化目标, 选择最佳储备池参数包括储备池规模 N 、泄露率 α 以及储备池稀疏

程度 SD 来最大化 DeepESN 的预测性能。

步骤 2 采用实数编码方式, 用规定范围内的实数表示个体的基因值, 具体编码方式如式 (10) 所示, $\mathbf{x}$ 中的元素值分别表示储备池规模、泄露率和储备池稀疏程度。

$$\mathbf{x} = [x_1, x_2, x_3] \quad (10)$$

步骤 3 对于种群中的每个个体, 利用对应参数配置储备池, 并基于训练集预测结果评估其性能。定义均方根误差 (root mean square error, RMSE) 为适应度函数并为每个个体打分, 保留优秀个体。

步骤 4 对选择的个体进行随机配对并使用交叉操作生成后代, 对新生成的后代进行变异操作, 以引入新的遗传变异, 增加种群的多样性。

步骤 5 重复步骤 2~4, 直至满足最优个体的适应度函数值达到阈值, 或种群的最优个体适应度函数值无法继续优化, 此时获得最佳储备池参数。

步骤 6 根据步骤 5 中获得的最佳储备池参数构建 DeepESN 预测模型, 对模型进行训练并利用测试集得到预测结果, 比较实际值与预测值, 评估模型的预测性能。

将本文所提基于遗传算法的储备池参数优化进行时间复杂度分析。本文共 3 个储备池参数需要优化, 分别是储备池规模、泄露率以及储备池稀疏程度。首先针对这 3 个参数初始化种群, 将每个个体初始化为常数复杂度, 因此总时间复杂度为 $O(n)$ 。对每个个体进行适应度评估, 假设适应度的时间复杂度为 $O(F)$, 则评估个体适应度的时间复杂度为 $O(nF)$ 。随后对个体进行选择, 如果考虑最坏情况, 每次选择都需要遍历整个种群来找到合适的个体, 此时选择过程的时间复杂度为 $O(n^2)$ 。对个体进行交叉以及变异操作, 由于单个个体交叉编译是常数复杂度, 因此, 交叉变异的时间复杂度为 $O(n)$ 。最终基于遗传算法的参数优化时间复杂度为 $O(n(n+F))$ 。

本节利用遗传算法对深层回声状态网络储备




图3 遗传算法优化储备池参数流程

池规模等参数的选取进行了优化, 从理论层面提升了深层回声状态网络的时间序列预测性能。根据前文介绍, 信道状态预测问题通常被具化为时间序列预测问题, 若使用星地信道状态数据集对预测模型进行训练, 则可以利用该预测模型实现星地信道预测。

2 基于信道状态预测的MCS智能选择机制与实验数据集构建

2.1 基于信道状态预测的MCS智能选择机制

在5G协议中, 有3张CQI-MCS索引表, 对应于不同的应用场景, 每一张表有29种MCS, 但协议中规定CQI反馈信息由4 bit进行承载, 因此实

际应用中通常只会选取16个MCS。考虑卫星通信场景的通信质量弱于地面, 采用3GPP TS 38.214规定的最高阶64QAM的CQI与MCS对应表。不同CQI对应MCS与码率见表1。MCS的切换门限由误块率 (block error rate, BLER)、信号与干扰加噪声比 (signal to interference plus noise ratio, SINR) 确定, 3GPP规定在自适应调制编码技术中, 数据信道的目标BLER为0.1, 即基站以某种调制编码方式进行传输, 统计终端的BLER<0.1时, 基站会调整调制编码方式至更高阶, 因此可以利用表1所示的每种MCS绘制对应的SINR-BLER曲线, 以BLER=0.1为基准得到每种MCS的切换门限。



表1 不同CQI对应MCS与码率

CQI索引	调制方式	码率×1 024
0	—	—
1	QPSK	78
2	QPSK	120
3	QPSK	193
4	QPSK	308
5	QPSK	449
6	QPSK	602
7	16QAM	378
8	16QAM	490
9	16QAM	616
10	64QAM	466
11	64QAM	567
12	64QAM	666
13	64QAM	772
14	64QAM	873
15	64QAM	948

手机直连低轨卫星通信场景的AMC技术原理如图4所示。考虑手机终端的天线增益和发射功率均较小,通常采用低阶调制方式,MCS切换不明显,本文主要考虑下行链路的AMC技术。在透明转发架构下,地面基站发出的数据通过卫星转发给地面手机终端,手机终端通过信道估计获得SINR,并根据SINR的值确定CQI,随后通过卫星将CQI反馈至地面基站,地面基站据此决定在下次传输中是否调整MCS。但经前文介绍,AMC技术面临星地传输时延高等导致的CQI过期问题,为解决该问题,本文提出一种基于信道状态预测的MCS智能选择机制,根据前文所提基于回声状态网络的信道预测模型,首先构建一个DeepESN预测模型并利用遗传算法对该DeepESN的储备池参数进行优化,随后利用卫星信道状态数据集对优化后的预测模型进行训练,最后将训练好的预测模型应用于发送端,并进行

信道状态预测,从而避免反馈时延与信道估计误差的影响,在发送端提前调整最适应当前信道的调制编码方式。




图4 手机直连低轨卫星场景的AMC技术原理

2.2 数据集获取与处理

实验所用信道状态数据集为卫星公司在实际场景中由地面终端实测所得,SNR数据集获取场景如图5所示,从地面终端刚接入卫星开始算起,经过卫星过顶并逐渐远离用户,直至卫星波束无法再覆盖地面终端,这段时间卫星波束始终对准地面终端,保证获得最大的天线增益,测试数据为卫星波束覆盖用户这段时间的接收SNR,卫星数据集测试参数见表2。根据前文介绍,信道状态预测问题通常转变为时间序列预测问题,而在AMC技术中,MCS的切换由CQI或SINR决定,因此在手机直连低轨卫星通信场景中,可以将信道状态预测转换为接收端SINR序列预测。由表2可知,在SNR数据集获取过程中,发送端与接收端均采用单天线,在仅考虑单用户面对单任务环境时,忽略天线等硬件带来的干扰,可以近似认为当前链路的SNR与SINR等效,最终将信道状态预测转化为SNR序列预测。




图5 SNR数据集获取场景

表2 卫星数据集测试参数

参数名称	参数值
轨道高度/km	508
卫星侧EIRP/dBW	40
终端天线增益/dBi	0
发送天线/接收天线	1/1
用户下行链路中频/GHz	18

卫星波束覆盖地面用户总时长为400 s, 地面终端每隔1 s采集一次SNR, 总数据量为400, 数据总量较小, 可能会导致训练模型泛化性差, 使训练过程和结果具有较高的随机性和不稳定性, 最终影响预测结果。首先对SNR数据集进行扩充操作, 在每两个采集点中插入9个点, 以此将整个数据集扩充为4 000个有效值, 得到每100 ms更新一次的数据集, 考虑每隔1 s进行一次SNR采样, 并且两个采样值之间的差距在 10^{-1} 数量级, 由于插值区间较小, 即使是非线性函数, 在该区间内也可近似为线性, 因此本文采用线性插值对数据集进行扩充。但是, 仍无法将扩充后的SNR数据集直接用于测试, 这是因为测试中下行链路中频为18 GHz, 而手机直连卫星场景中下行链路中频大约在2 GHz, 如果手机直连低轨卫星场景与数据集获取场景参数一致, 仅考虑频段不同, 那么两种情况下导致接收端SNR不同的因素包括自由空间传播损耗 L_F 、大气吸收损耗 L_a , 以及降雨、云、雾引起的衰减 L_c 等, 接下来对几种衰减进行分析。

首先考虑通信链路距离导致的自由空间传播损耗, 这是整个衰减损耗中主要的一种, 自由空

间传播损耗表达式如下。

$$L_F = (4\pi d/\lambda)^2 = (4\pi df/c)^2 \quad (11)$$

其中, d 为传播距离, λ 为信号波长, 信号衰减的单位为dB, 考虑卫星通信场景中信号是在相对理想的自由空间传输的, 因此波长等于光速与信号频率之比。

接下来考虑大气吸收, 信号由卫星传输至地面终端时, 信号受大气层的影响导致衰减, 在实际工程中可近似由式(12)计算得到。

$$L_a = 0.042 \cdot e^{0.069 \cdot 1/f / \sin(e\ell)} \quad (12)$$

其中, $e\ell$ 表示仰角, 当仰角为30°时, C频段大气衰减大约为0.1 dB, 而Ka频段的大气衰减大约为0.35 dB。

最后考虑云雾吸收衰减, 云雾吸收衰减由式(13)计算得到。

$$L_c = L\gamma_c \quad (13)$$

其中, L 表示云雾厚度, γ_c 表示单位云雾厚度的信号衰减, $\gamma_c = KM$, M 为云雾水分子质量浓度, 为 $0.2 \sim 0.5 \text{ g/m}^3$, $K = 1.2 \times 10^{-3} \times f^{1.9}$, 单位为 $(\text{dB/km})/(\text{g/m}^3)$, 即 $\text{dB} \cdot \text{m}^3/(\text{km} \cdot \text{g})$ 。

考虑上述原因中通信频率对信号衰减程度影响, 本文根据通信频段对扩充后的SNR数据集进一步转化, 生成适配2 GHz通信频段的SNR数据集, 并采用此数据集进行网络训练。

3 实验结果与分析

3.1 储备池参数对DeepESN的预测性能影响

将数据集转化为适用于手机直连场景下的SNR数据集后, 按照不同的训练集样本个数进行分组, 训练集样本个数分别为500、600、700, 不同训练集样本数的预测结果对比如图6所示, 其中所提方案为利用遗传算法进行储备池参数优化的DeepESN, 而对比方案为参数随机选取的DeepESN。图6中首先可以看到随着训练集样本数增加, 两种DeepESN预测性能都有提升, 这是




图6 不同训练集样本数的预测结果对比

因为在训练样本数较少时, 预测模型没有足够的数据量捕获时间序列的内部特征, 随着训练样本数增加, 预测模型获得了更全面的数据, 以此更加精准地学习和预测时间序列, 在训练样本数为500时, 虽然两种预测结果与原始序列的整体变化趋势比较接近, 但可明显观察到在500~3 000这部分序列的预测值与实际值差别较大, 预测性能不好, 当训练样本数增加至700时, 可以看到两种预测结果的变化趋势与预测值都比较贴近实际值, 这说明随着训练长度增加, 模型对时间序列的学习更加全面, 提升了预测性能。

在不同的训练长度情况下, 经过遗传算法优化的DeepESN预测性能都优于随机DeepESN,

这是因为本文的遗传算法对储备池参数中的储备池规模 N 、泄露率 α 以及储备池稀疏程度SD进行了优化。其中, 储备池规模 N 影响储备池内部的神经元数目, 可能导致出现过拟合或欠拟合, 泄露率 α 控制网络状态更新速度, 代表网络对当前新输入的敏感程度, 储备池稀疏程度SD表示储备池中连接神经元占总神经元的比例, 决定模型的非线性逼近能力, 经遗传算法优化后可选出最大化模型预测性能的储备池参数, 相较于通过尝试或经验选取的参数, 拥有更强的预测性能。在训练集样本数600时可观察到, 未进行参数优化的DeepESN预测结果与真实结果相差较大, 这是因为储备池参数选取具有不确定性, 最终影响网络的预测性能。

将本文所提利用遗传算法进行储备池参数优化的 DeepESN 与基于自回归的传统时间序列预测方法进行对比,在训练集样本个数为 700 时本文所提方案与自回归预测方案结果对比如图 7 所示。由图 7 可知,相比于传统的基于自回归的预测方案,本文所提方案大大提升了预测准确性。这是因为自回归模型采用线性时间序列预测方法,根据过去时间的数据预测未来时间的数据,并且自回归模型的参数都是固定的,无法捕获手机直连低轨卫星场景中的非线性 SNR 关系,而本文所提方案基于循环神经网络,并通过遗传算法最大限度提升了预测性能,最终得到较为准确的预测结果。




图7 本文所提方案与自回归预测方案结果对比

3.2 基于 5G NTN 链路级仿真的性能结果评估

前文通过仿真实验验证了本文所提信道状态预测模型的优秀性能,为了继续验证基于该信道状态预测的 MCS 智能选择机制对通信性能的影响,本文搭建了基于 5G NTN 的链路级仿真平台,该仿真平台可以通过配置文件对基本参数进行配置和修改,便于进行不同场景的仿真,链路级仿真参数见表 3。

表3 链路级仿真参数

参数名称	参数值
编码方式	LDPC
下行链路波形	OFDM
子载波间隔/kHz	15
用户带宽/MHz	10
信道模型	NTN-TDL-D 信道

整个链路级仿真平台流程示意图如图 8 所示,仿真平台编写了多个模块函数,实现了端到端通信的一系列功能,包括初始参数设置、传输块产生、信道估计与 CQI 反馈等。在参数设置部分,平台根据 3GPP 协议设置如帧结构类型、带块与子载波间隔、载波频率、卫星轨道高度等参数,相当于对具体应用场景进行参数初始化。在传输块产生部分,发送端根据应用场景的初始化参数,判断传输码块大小以及本次传输是否需要切换 MCS。本文引入了信道状态预测,在信道状态预测部分,发送端根据训练好的网络提前对 MCS 进行选择并用于传输,经过正交频分复用 (orthogonal frequency division multiplexing, OFDM) 调制、信道传输以及接收端解调制码等操作后,得到最终的统计结果。




图8 链路级仿真平台流程示意图


为评估基于信道预测的 MCS 智能选择机制对链路性能的影响,本文选取链路误码率以及频谱效率作为相关指标。由前文实验结果分析可知,本文所提信道预测模型的预测性能较好,将该预测模型的信道状态预测结果代入链路级仿真平台,并与未采用信道状态预测的含反馈时延链




路以及采用基于自回归信道状态预测的链路进行对比, 得到链路性能结果如图9所示。

观察误码率曲线对比可以看出, 无论是否采用信道预测, 在0~170 s, 链路误码率是上下波动的变化趋势, 这是因为在这段时间SNR逐渐升高, 超过MCS的切换门限, 使得MCS从低阶切换至高阶, 高阶MCS对信噪比要求更高, 这导致链路误码率短暂上升, 误码率曲线出现波动。在170~200 s, 链路误码率趋于稳定, 因为此时SNR基本稳定在最高值, MCS切换至最高阶, 误码率变化不大。在200~400 s, 误码率再次呈现上下波动的趋势, 与前170 s误码率波动原因一样, 此时SNR逐渐下降, 高阶MCS切换至低阶MCS, 切换的过程使得误码率发生波动。同时可以观察到, 在0~260 s, 本文所


提信道预测方案与基于自回归的信道状态方案在误码率上相差不大甚至略高于后者, 这是因为这段时间基于自回归的预测方案预测SNR要低于实际SNR, 使得发送端采用更低阶的MCS进行数据传输, 在这种情况下基于自回归的信道预测方案误码率更低。由图9(c)中可知, 在260 s之后, 基于自回归的信道预测链路误码率变为 10^{-2} 数量级, 并且通过局部放大图可以看到, 此时其余两种链路的误码率处于 10^{-4} 数量级, 这是因为在260 s之后基于自回归的信道状态预测SNR高于实际SNR, 使得发送端采用信道无法支持高阶的MCS, 系统误码性能迅速恶化。采用本文所提信道状态预测方案在全时段提高了链路的误码性能, 这是因为实际链路中存在较大的通信时延, 在透明转发架构下, 通信时延的构成主




(a) 采用信道预测与含反馈时延的链路误码率对比 (卫星波束覆盖地面终端的0~100 s)



(b) 采用信道预测与含反馈时延的链路频谱效率对比 (卫星波束覆盖地面终端的0~100 s)



(c) 采用信道预测与含反馈时延的链路误码率对比 (卫星波束覆盖地面终端的100~200 s)



(d) 采用信道预测与含反馈时延的链路频谱效率对比 (卫星波束覆盖地面终端的100~200 s)

图9 采用信道状态预测与未采用信道状态预测链路性能对比




图9 采用信道状态预测与未采用信道状态预测链路性能对比(续)

要包括地面基站到卫星、卫星到地面终端的双向链路传播时延,使通信时延远远超过传统地面通信,并且低轨卫星通信作为一种高速通信场景具有较大的多普勒频偏,使得信道相干时间较小,以上问题会导致

CQI过期,从而影响链路误码性能,而采用信道状态预测可以有效避免时延以及信道估计误差带来的CQI过期问题,从而提升链路误码性能。

观测频谱效率曲线可以看出,在前170 s,整



体频谱效率呈现上升趋势,因为此时SNR上升,同时低阶MCS切换至高阶MCS,能够在相同的带宽条件下传输更多的数据,从而提升频谱效率。在中间时刻,由于已切换至最高阶MCS,不能无限提升数据传输效率,因此这段时间频谱效率趋于稳定。同理,在后半段时间,切换至低阶MCS,使得链路频谱效率下降。基于自回归的信道预测方案链路频谱效率在0~260 s与其余两种方案数值接近,但是在260 s之后频谱效率低于另两种方案,这是因为频谱效率的计算是用每秒传输正确比特数与传输带宽相除得到的,在前260 s虽然基于自回归的信道预测方案误码率更低,但此时链路误码率处在 $10^{-4} \sim 10^{-3}$,正确传输的比特数差距不大,因此频谱效率接近,但在260 s后,基于自回归的信道状态预测误码性能迅速恶化,使得频谱效率低于其他两种方案。虽然本文所提信道预测方案提升了链路误码性能,但频谱效率提升幅度有限。

4 结束语

本文首先探讨了低轨卫星通信的优势,介绍了部分正在研究并部署的低轨卫星通信星座,随后介绍近年来手机直连卫星的发展现状,并深入分析在实际应用中遇到的关键挑战,即AMC在动态变化的卫星通信环境中的局限性。为了克服这一挑战,本文引入了信道状态预测的概念,并将问题转化为时间序列预测,采用DeepESN进行信道状态预测,并利用遗传算法对DeepESN的储备池规模、泄露率以及稀疏程度进行优化,最终证明进行参数优化的DeepESN预测性能更好。随后将参数优化的DeepESN应用于链路仿真平台中,进行信道状态预测对通信性能影响的评估。结果表明,信道状态预测可以提升链路的误码性能,大大提升通信的可靠性,但是对频谱效率的提升有限。总体而言,本文为解决手机直连卫星通信中的自适应调制编码问题提供了一种创新的优化思路,

为下一代移动通信系统的设计和优化提供了参考。

后续工作将进一步考虑对手机直连低轨卫星场景下的MCS切换进行优化,可以采用其他机器学习技术对MCS表进行重新设计,舍弃其中不合理的部分,或对查表法进行优化,根据其他指标对MCS进行智能选择。此外,考虑在大带宽、大子载波间隔的场景下进行仿真,使模型更贴近现实,最后考虑优化通信体制,如设计新的物理层通信波形以提升链路性能。

参考文献:

- [1] EVANS B, WERNER M, LUTZ E, et al. Integration of satellite and terrestrial systems in future multimedia communications[J]. IEEE Wireless Communications, 2005, 12(5): 72-80.
- [2] SUN Y H, PENG M G, ZHANG S J, et al. Integrated satellite-terrestrial networks: architectures, key techniques, and experimental progress[J]. IEEE Network, 2022, 36(6): 191-198.
- [3] 彭木根,张世杰,许宏涛,等.低轨卫星通信遥感融合:架构、技术与试验[J].电信科学,2022,38(1):13-24.
PENG M G, ZHANG S J, XU H T, et al. Communication and remote sensing integrated LEO satellites: architecture, technologies and experiment[J]. Telecommunications Science, 2022, 38(1): 13-24.
- [4] 王艳峰,谷林海,刘鸿鹏.低轨卫星移动通信现状与未来发展[J].通信技术,2020,53(10):2447-2453.
WANG Y F, GU L H, LIU H P. Status quo and future development of LEO satellite mobile communication[J]. Communications Technology, 2020, 53(10): 2447-2453.
- [5] ZHU J F, SUN Y H, PENG M G. Beam management in low earth orbit satellite networks with random traffic arrival and time-varying topology[J]. IEEE Transactions on Vehicular Technology, 2024, PP(99): 1-16.
- [6] 孙耀华,彭木根.面向手机直连的低轨卫星通信:关键技术、发展现状与未来展望[J].电信科学,2023,39(2):25-36.
SUN Y H, PENG M G. Low earth orbit satellite communication supporting direct connection with mobile phones: key technologies, recent progress and future directions[J]. Telecommunications Science, 2023, 39(2): 25-36.
- [7] 孙耀华,许宏涛,彭木根.手机直连低轨卫星通信:架构、关键技术和未来展望[J].移动通信,2024,48(1):103-110.
SUN Y H, XU H T, PENG M G. Direct-to-mobile low earth orbit satellite communication: architecture, key technologies, and future perspective[J]. Mobile Communications, 2024, 48(1): 103-110.

- [8] YUAN S, SUN Y H, PENG M G, et al. Joint beam direction control and radio resource allocation in dynamic multi-beam LEO satellite networks[J]. IEEE Transactions on Vehicular Technology, 2024, 73(6): 8222-8237.
- [9] TOMASSO K C. Wide area network access management computer: US20160191566[P]. 2016-06-30.
- [10] SPEIDEL T R, BUVARP A, LIU J. Receiver-based computation of transmitter parameters and state for communications beyond design ranges of a cellular network protocol: US20220038849[P]. 2022-02-03.
- [11] SPEIDEL T R, MILLER C E. Method for interference minimization and optimization of orbital mobile cellular services: US20220368411[P]. 2022-11-17.
- [12] 3GPP. Solutions for NR to support non-terrestrial networks (NTN): TR 38.821 v16.0.0[S]. 2019.
- [13] RICO-ALVARIÑO A, ARNAU J, MOSQUERA C. Link adaptation in mobile satellite links: schemes for different degrees of CSI knowledge[J]. International Journal of Satellite Communications and Networking, 2016, 34(5): 679-694.
- [14] ZHU J F, SUN Y H, PENG M G. Timing advance estimation in low earth orbit satellite networks[J]. IEEE Transactions on Vehicular Technology, 2024, 73(3): 4366-4382.
- [15] QU Z C, ZHANG G X, CAO H T, et al. LEO satellite constellation for Internet of Things[J]. IEEE Access, 2017(5): 18391-18401.
- [16] 陈甄, 张毅, 肖琨. 自适应系统中基于场景的信噪比预测算法[J]. 通信技术, 2014, 47(3): 247-252.
CHEN Z, ZHANG Y, XIAO K. Scenario-based SNR prediction method in adaptive system[J]. Communications Technology, 2014, 47(3): 247-252.
- [17] GUNNARSSON F, BLOM J, GUSTAFSSON F. Power control in cellular systems subject to constraints and time delays[C]//Proceedings of the IEEE GLOBECOM 1998. Piscataway: IEEE Press, 2002: 3645-3650.
- [18] PAPAGIANNAKI K, TAFT N, ZHANG Z L, et al. Long-term forecasting of Internet backbone traffic: observations and initial models[C]//Proceedings of the IEEE INFOCOM 2003. Twenty-second Annual Joint Conference of the IEEE Computer and Communications Societies. Piscataway: IEEE Press, 2003: 1178-1188.
- [19] KHASHEI M, BIJARI M. Fuzzy artificial neural network (p, d, q) model for incomplete financial time series forecasting[J]. Journal of Intelligent & Fuzzy Systems, 2014, 26(2): 831-845.
- [20] WANG J, TANG J, XU Z Y, et al. Spatiotemporal modeling and prediction in cellular networks: a big data enabled deep learning approach[C]//Proceedings of the IEEE INFOCOM 2017 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2017: 1-9.
- [21] DING T B, HIROSE A. Fading channel prediction based on combination of complex-valued neural networks and chirp Z-transform[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(9): 1686-1695.
- [22] YUAN J D, NGO H Q, MATTHAIU M. Machine learning-based channel prediction in massive MIMO with channel aging[J]. IEEE Transactions on Wireless Communications, 2020, 19(5): 2960-2973.
- [23] JAEGER H. Reservoir riddles: suggestions for echo state network research[C]//Proceedings of the Proceedings of 2005 IEEE International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2005: 1460-1462.
- [24] SUN C X, SONG M X, CAI D R, et al. A systematic review of echo state networks from design to application[J]. IEEE Transactions on Artificial Intelligence, 2024, 5(1): 23-37.
- [25] GALLICCHIO C, MICHELI A. Deep echo state network (DeepESN): a brief survey[J]. arXiv preprint arXiv: 1712.04323, 2017.
- [26] 彭宇, 王建民, 彭喜元. 储备池计算概述[J]. 电子学报, 2011, 39(10): 2387-2396.
PENG Y, WANG J M, PENG X Y. Survey on reservoir computing[J]. Acta Electronica Sinica, 2011, 39(10): 2387-2396.

[作者简介]



季铄 (2000-), 男, 北京邮电大学网络与交换技术全国重点实验室硕士生, 主要研究方向为低轨卫星通信。



孙耀华 (1992-), 男, 博士, 北京邮电大学副教授, 主要研究方向为低轨卫星通信和无线接入网络智能化。



彭木根 (1978-), 男, 博士, 北京邮电大学教授, 主要研究方向为空间信息通信、通感算一体化、雾无线接入网络等。