基于深度学习的预测波束成形设计

Juping Zhang、Gan Zheng，*IEEE*会士，Yangyishi Zhang、Ioannis Krikidis，*IEEE*会士，以及 Kai-Kit Wong，*IEEE*会士

arXiv:2302.01035v1 [cs.IT] 2 Feb 2023

摘要—本文研究在多用户多输入单输出下行链路中，仅依据历史信道数据、而不使用当前信道信息来预测发射波束成形的深度学习技术。这将显著降低信道估计开销并提高频谱效率，尤其是在高速移动的车载通信场景中。具体而言，我们提出一种联合学习框架，将信道预测与功率优化相结合，并直接生成发射波束成形预测结果。此外，我们提出在长短期记忆循环神经网络中使用注意力机制，以提高信道预测的准确性。基于简单自回归过程模型和更逼真的3GPP空间信道模型进行的仿真结果表明，与传统信道估计方法以及先单独预测信道、再优化波束成形的方法相比，我们提出的预测波束成形方案能够显著提高有效频谱效率。

索引词—**信道预测、波束成形、深度学习。**

I. 引言

及时、准确的信道状态信息（CSI）对于通过设计波束成形等最优传输策略，充分发挥多用户多天线系统的潜力至关重要，但在实践中获取这类信息颇具挑战。传统上，基站（BS）通过用户反馈，或利用信道互易性，根据上行导频进行信道估计来获取下行链路CSI。这两种方法都会带来显著的开销、额外误差和时延，因此，基站处的CSI在波束成形设计时往往已经过时，在高移动性场景下尤其如此，例如无人机和车联万物通信场景。

一种更高效的信道获取方法是利用时间相关性，根据历史CSI数据预测信道。关于信道预测，已有大量研究。早期研究假设已知准确的信道模型，例如自回归（AR）过程，或长期信道统计特性，并通常采用卡尔曼滤波 [1] 估计AR系数。然而，实际信道可能无法用解析模型描述，也可能具有非平稳性，从而降低基于模型的预测方法的性能。

近年来，基于深度学习的信道预测因能够在无需预先了解信道模型的情况下从数据中学习信道状态信息（CSI），而受到广泛关注。从单天线系统出发， [2] 提出了一种高效的长短期记忆（LSTM）网络——一种循环神经网络（RNN），用于非平稳变化信道中的CSI预测与自适应。进一步地， [3], 基于RNN的信道预测，设计了一种可降低导频开销的数据驱动接收机架构。[4] 的工作首先设计并开展测量活动，收集IEEE 802.11p传输的IQ采样，并从各种真实世界的车载环境中提取CSI。随后采用LSTM方法预测未来的CSI和接收信号电平，并通过基于轨迹的评估进行了验证。 [5] 将基于深度学习的信道预测扩展至大规模多输入多输出（MIMO）系统，从而提升了低速和高速移动场景下的信道预测质量。 [6],采用空间信道模型（SCM），对大规模MIMO系统中的向量卡尔曼滤波（VKF）预测器和基于深度学习的预测器进行了比较研究，结果表明，与过时信道相比，两者在信道预测精度和数据速率方面均能取得显著增益。在信道预测之后，波束成形优化也得到了研究。 [7] 采用深度学习方法，在无人机（UAV）因随机阵风而发生固有抖动的情况下，预测无人机与用户设备之间的角度，使UAV和用户设备能够提前准备发射和接收波束。 [8]在车联网中提出了一种通用的无监督深度学习预测波束成形设计，该方法能够隐式学习历史信道的特征，并直接预测下一时隙所采用的波束成形矩阵。所提方法不仅能保证所需的感知性能，还能实现令人满意的和速率。 [9], 研究了车联网中的雷达通信一体化（DFRC）系统的预测波束成形，并提出了一种基于因子图的新型消息传递算法，用于估计车辆的运动参数，随后根据预测角度设计波束成形器，以便建立通信链路。

本研究部分由CELTIC-Next项目C2019/2- 5人工智能赋能的大规模多输入多输出（AIMM）、欧洲区域发展基金和塞浦路斯共和国通过研究与创新基金会资助，项目编号为INFRASTRUCTURES/1216/0017（IRIDA）；另获英国工程与自然科学研究理事会（EPSRC）项目EP/T015985/1资助。J. Zhang和K.-K. Wong任职于英国伦敦WC1E 6BT伦敦大学学院电子与电气工程系（电子邮箱： {juping.zhang,kai-kit.wong}@ucl.ac.uk）。G. Zheng任职于英国考文垂CV4 7AL华威大学工程学院（电子邮箱: gan.zheng@warwick.ac.uk）。Y. Zhang任职于英国电信，地址为英国伊普斯维奇Martlesham Heath的Adastral Park，邮编IP5 3RE（电子邮箱: yangyishi.zhang@bt.com）。I. Krikidis任职于塞浦路斯尼科西亚1678号塞浦路斯大学电气与计算机工程系（电子邮箱：krikidis@ucy.ac.cy）。为实现开放获取，作者已为由此产生的作者接受稿版本申请知识共享署名（CC BY）许可。

以建立通信链路。

不同于上述仅关注信道预测或借助雷达辅助的工作，我们提出了一种深度学习框架，以历史CSI数据为输入，直接预测未来信道的波束成形方案，从而最大化多用户多天线系统的和速率性能。该框架包含一个基于LSTM的信道预测模块和一个功率优化模块，后者通过混合监督-无监督学习重建波束成形向量。此外，我们提出在长短期记忆网络中使用注意力机制，从而正确反映不同相干间隔内历史信道对信道预测的影响，进而提升波束成形预测性能。

本文其余部分安排如下。第二节介绍系统模型和问题建模。第三节介绍用于预测波束成形的所提深度学习框架。第四节给出仿真结果，以验证所提方法；第五节总结全文。

符号说明：所有粗体字母均表示向量（小写）或矩阵（大写）。上标 $(\cdot)^{\dagger}$ 和 $(\cdot)^{-1}$ 分别表示共轭转置和矩阵求逆。vec(·) 表示矩阵的向量运算。单位矩阵用$\mathbf{I}$表示。 $\|\mathbf{z}\|$ 表示复向量$\mathbf{z}$的 L_2 范数。

II. 系统模型与问题建模

A. 系统模型

我们考虑一个多输入单输出（MISO）下行链路系统，其中配备 N_t 根天线的基站为 K 个采用单用户检测的单天线用户提供服务。设 s_k 为发送给用户 k 的单位功率发射信号，基站的总发射功率为 P_T。发射数据符号 s_k 通过波束成形向量 $\mathbf{w}_k \in \mathbb{C}^{N_t \times 1}$ 映射到天线阵列单元上。用户 k 处的接收信号可表示为

$$y_k = \mathbf{h}_k^{\dagger}\mathbf{w}_k s_k + \sum_{j \neq k} \mathbf{h}_k^{\dagger}\mathbf{w}_j s_j + n_k, \tag{1}$$

其中，$\mathbf{h}_k \in \mathbb{C}^{N_t \times 1}$ 为基站与用户 k 之间的信道，第二项表示干扰，n_k 表示均值为零、方差为 σ_k^2 的加性白高斯噪声（AWGN）分量。因此，用于衡量第 k 个用户数据检测质量的信干噪比（SINR）为

$$\Gamma_k = \frac{|\mathbf{h}_k^{\dagger}\mathbf{w}_k|^2}{\sum_{j \neq k} |\mathbf{h}_k^{\dagger}\mathbf{w}_j|^2 + \sigma_k^2}. \tag{2}$$

我们选择和速率作为需要最大化的系统性能指标，所得问题表示为

$$\max_{\{\mathbf{w}_k\}} R \triangleq \sum_{k=1}^{K} \log(1+\Gamma_k), \text{s.t.} \sum_{k=1}^{K} \|\mathbf{w}_k\|^2 \leq P_T. \tag{3}$$

式（3）中的和速率优化问题是非凸的，寻找其次优解的标准方法是使用加权最小均方误差（WMMSE）算法 [10]，前提是可获得信道状态信息（ CSI ） $\{\mathbf{h}_k\}$，而这通常依赖于基于导频的信道估计，并会引入大量开销。

B. 问题建模

本文采用一种混合信道估计与预测方案来解决问题 (3)：先估计一定数量信道的信道状态信息（CSI），然后利用这些信息预测部分未来信道的 CSI。具体而言，我们假设时间范围划分为若干帧，每帧包含 $N+P$ 个相干间隔；在每帧中，前 N 个相干间隔的 CSI 已知，而其余 P 个相干间隔的 CSI 将在不进行估计的情况下直接预测。

已知 CSI 估计表示为

$$\hat{\mathbf{h}}_k(n) = \mathbf{h}_k(n) + \mathbf{e}_k(n), \forall n = 1, \cdots, N, \tag{4}$$

其中，$\mathbf{h}_k(n)$ 是用户 k 在第 n 个相干间隔内的真实 CSI，$\mathbf{e}_k(n)$ 是信道估计误差，服从均值为零、方差矩阵为$\sigma_{e,k}^2\mathbf{I}$ 的复高斯分布。我们假设采用最小二乘信道估计，因此 $\sigma_{e,k}^2$ 取决于导频发射功率。

CSI 预测表示为

$$\tilde{\mathbf{h}}_k(N+m) = \mathbb{M}(\{\hat{\mathbf{h}}_k(n)\}, \forall n = 1, \cdots, N), \forall m = 1, \cdots, P, \tag{5}$$

其中，$\mathbb{M}(\cdot)$ 表示从已知信道估计到信道预测的映射。

采用混合方案时，我们的目标是通过预测这些P 未知信道在给定 N 已知信道下的波束成形解，直接求解问题 (3)。

III. 预测波束成形解

A. 通用框架

我们提出的基于深度学习的波束成形方案预测框架如下面的图 1 所示。

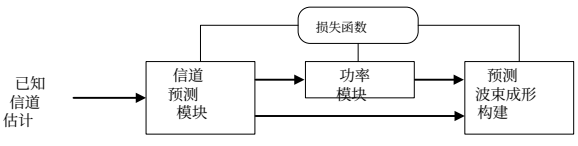

图 1. 所提出的预测波束成形框架。

所提出的框架包括三个关键模块。第一个模块是用于信道预测的神经网络（NN），它实现了从输入的已知信道估计 $\mathbf{h}_k(n)$ $n = 1, \cdots, N$到预测信道 $\tilde{\mathbf{h}}_k(N+m)$ $m = 1, \cdots, P$的映射 $\mathbb{M}(\cdot)$。采用监督学习，其对应的损失函数为

$$L_H = \frac{1}{2LK} \sum_{l=1}^{L} \sum_{k=1}^{K} \sum_{m=1}^{P} \left(\|\mathbf{h}_k(N+m)^{(l)} - \tilde{\mathbf{h}}_k(N+m)^{(l)}\|^2 \right), \tag{6}$$

其中， L 表示批次数量，上标 (l) 表示批次的索引。信道预测模块的详细内容将在下一小节中介绍。

第二个模块是一个用于预测功率向量的神经网络，以便促进波束成形方案的预测。利用预测信道，可以通过监督学习直接推断波束成形方案，但高维波束成形会使训练更具挑战性，并降低推断准确率。相反，对于和速率最大化问题，我们利用波束成形方案的以下参数化结构：

$$\tilde{\mathbf{w}}_k = \sqrt{p_k}\frac{\left(\mathbf{I}+\sum_{j=1}^{K}\frac{q_j}{\sigma_j^2}\tilde{\mathbf{h}}_j\tilde{\mathbf{h}}_j^{\dagger}\right)^{-1}\tilde{\mathbf{h}}_k}{\|\left(\mathbf{I}+\sum_{j=1}^{K}\frac{q_j}{\sigma_j^2}\tilde{\mathbf{h}}_j\tilde{\mathbf{h}}_j^{\dagger}\right)^{-1}\tilde{\mathbf{h}}_k\|}, \tag{7}$$

其中 $\{\mathbf{q}\}$ 和 $\{\mathbf{p}\}$ 分别为上行链路和下行链路功率向量，其总功率均为 P_T。该结构改编自完美信道状态信息下的结果 [11]。可以看出，一旦获得信道预测，我们就可以利用神经网络通过监督学习预测功率向量 $\{\mathbf{q}\}$和 $\{\mathbf{p}\}$，然后使用式（7）重构波束成形方案。标注数据可通过加权最小均方误差算法获得 [10]。为简单起见，我们在功率模块中使用全连接层，具体内容见第四节。假设相应的损失函数为

$$L_P = \frac{1}{2LK}\sum_{l=1}^{L}\sum_{m=1}^{P}\left(\|\mathbf{q}^{(N+m,l)}-\tilde{\mathbf{q}}^{(N+m,l)}\|^2\right) \tag{8}$$

$$+ \left(\|\mathbf{p}^{(N+m,l)}-\tilde{\mathbf{p}}^{(N+m,l)}\|^2\right), \tag{9}$$

其中， $\tilde{}\mathbf{q}$ 和 $\tilde{}\mathbf{p}$是功率神经网络的输出。

下一个模块将利用预测信道和功率，通过式（7）构造预测波束成形方案。为了提升最大化和速率的最终性能，我们还考虑将式（3）中的和速率表达式$R(\{h_k, \tilde{}\mathbf{w}_k\})$纳入损失函数，以训练整体神经网络。因此，整体损失函数可表示为以下加权和：

$$L = L_H + L_P - bR(\{\tilde{h}_k, \tilde{\mathbf{w}}_k\}), \tag{10}$$

其中， b 是一个正系数。损失函数（10）的创新设计体现了这样一个事实：我们提出的方案是一个联合学习框架，它融合了信道预测和功率优化，同时直接生成发射波束成形的预测。本节其余部分将介绍信道预测模块的开发。

B. 基于注意力机制的长短期记忆网络信道预测

信道预测是利用历史CSI数据与未来CSI之间的时间相关性，根据历史CSI数据预测未来的CSI。循环神经网络是一种非常适合预测时间序列数据的机器学习技术 [12]。然而，标准循环神经网络在反向传播过程中存在梯度消失和梯度爆炸的问题，这使得预测较长的时间序列颇具挑战。长短期记忆网络是最成功的循环神经网络变体之一，可用于预测相关时间序列数据，并能解决梯度消失和梯度爆炸的问题 [12]，因此本文采用长短期记忆网络来预测具有时间相关性的信道。

长短期记忆网络由一个能够长期存储数据的记忆单元组成。信息流入和流出该单元由三个门控制。具体而言，遗忘门决定前一单元状态中的哪些信息需要保留，以及哪些不再有用的信息应被移除；输入门决定哪些信息应进入单元状态；输出门则决定并控制输出。

现有的大多数信道预测研究都采用简单的 LTSM，仅将其最后一个隐藏状态输入全连接层，以生成预测信道。本文通过引入注意力机制提出了一种改进方案，使算法能够关注不同的历史信道。具体而言，注意力方案会对较近的信道赋予更高的权重，以改进对未来信道的预测。这是合理的，因为并非所有历史 CSI数据对未来信道的影响都相同，未来信道主要受较近信道的影响。所提出的注意力方案的优势在于，权重可通过训练进行优化，无需人工预先设定。

本文通过引入注意力机制提出了一种改进方案，使算法能够关注不同的历史信道。具体而言，注意力方案会对较近的信道赋予更高的权重，以改进对未来信道的预测。这是合理的，因为并非所有历史 CSI数据对未来信道的影响都相同，未来信道主要受较近信道的影响。注意力机制在语言翻译和手写词语识别等序列到序列任务中取得了显著成功 [13]，，但尚未用于信道预测。

图 2 描绘了所提出的采用长短期记忆网络和注意力机制的信道预测模块。该模块包含 N 个时间步，每个时间步对应一个相干间隔内已知的信道估计。为了充分利用历史数据，我们创建了一个注意力层，将其置于长短期记忆网络与全连接层之间。该层为每个时间步 n 的隐藏状态输出分配权重 c_n，其中 $\sum_{n=1}^{N} c_n = 1$，然后将原始隐藏状态的加权和合并为长短期记忆网络的输出状态。这使得不同相干间隔内信道估计的重要性能够得到准确表征。随后，将新的输出状态输入全连接层，以生成预测信道。与将权重 $\{c_n\}$ 视为超参数不同，该方案的一项显著优势是将这些权重纳入整体神经网络训练，因此无需手动调整。

C. 有效和速率

在本小节中，我们将有效和速率 R_E 定义为并对其进行分析，该性能指标综合考虑了和

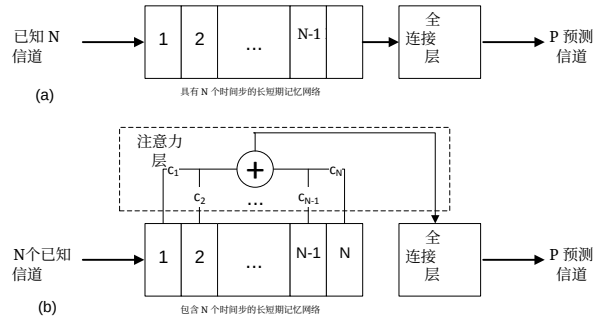

图 2. (a) 不带注意力机制的长短期记忆网络传统信道预测；(b) 使用带注意力层的长短期记忆网络的所提信道预测方法。

估计信道速率和预测信道速率，可表示为

$$R_E = \frac{(1-\alpha)N}{N+P} R_e + \frac{P}{N+P} R_p, \tag{11}$$

其中， α 表示相干间隔内信道估计开销所占的比例，因此满足 $\alpha < 1$； R_e表示估计信道的平均和速率，在信道状态信息完美的情况下，可使用现有的神经网络方法（如 [14] ）获得；而 R_p 表示预测信道的平均和速率，可通过所提预测波束成形方法获得。请注意，与传统的基于信道估计的优化方法相比，所提方法将信道估计开销降低了 αP。直观而言，信道估计造成的信令开销会降低有效和速率，因此选择较大的 N 可能有益。然而，信道预测的质量也取决于已知信道估计的数量。因此，有效和速率通常不会随着 N 和 P 单调变化，实际应用中需要在低开销与高质量预测之间取得平衡。

IV. 数值结果

A. 仿真设置

本节给出数值结果，以验证并评估所提出的基于深度学习的预测波束成形方案的性能。除非另有说明，我们考虑一个由 $N_t = 4$ 根发射天线和 $K = 3$个用户组成的多输入单输出下行链路。发射信噪比（SNR） P_T 和信道估计误差的方差为$\sigma_{e,\,k}^2 = 1/P_T,\ \forall k$。信道估计开销设为 $\alpha = 0.1$。除非另有说明，我们假设有 $N = 20$已知CSI数据可用，且 P_T 为20 dB。在我们的仿真中，分别使用 [10]中的加权最小均方误差算法生成30,000个训练标签和1,000个测试样本。对于长短期记忆网络层，我们使用 $2N_tKN$ 个单元；功率神经网络则使用三个全连接层，每层包含 $30N_tK$ 个神经元，并采用ReLU激活函数。(10)中的 b 取值为0.001。我们使用Python和Keras，在TensorFlow中训练所提出的深度学习模型。所有仿真结果均由一台配备Intel i7-7700 CPU和NVIDIA Titan Xp GPU的计算机生成。下文定义的归一化均方误差（NMSE）用作信道预测的性能指标：

$$\text{NMSE} = \mathbb{E}\left[\frac{\|\mathbf{H} - \tilde{\mathbf{H}}\|^2}{\|\mathbf{H}\|^2}\right]. \tag{12}$$

考虑以下基准方案进行比较：

- 不使用注意力机制的预测波束成形。除信道预测模块不采用注意力机制外，该方案与所提方法相同。

- 分离优化，即使用基于长短期记忆网络、带有注意力机制的所提方法进行信道预测，并采用迫零（ZF）波束成形优化预测信道和已知信道的和速率。

- 信道估计后接ZF波束成形。这是一种具有导频开销的传统估计方案，不使用信道预测。由于时延，这种方案可能并非始终可行。

- 卡尔曼滤波。该方案使用卡尔曼滤波进行信道预测，并使用 ZF 优化和速率。

B. 信道模型

我们考虑两种不同的信道动态建模场景。

- 第一种场景是一阶自回归过程。假设将所有用户的信道收集为$\mathbf{H}$。在此场景中，信道的时间演化表示为

$$\text{vec}(\mathbf{H}_n) = \beta \text{vec}(\mathbf{H}_{n-1}) + \mathbf{u}_n, \tag{13}$$

其中， $\beta = \mathcal{J}_0(2\pi f_D T_s)$、 $\mathcal{J}_0(\cdot)$是第一类零阶贝塞尔函数， f_D 是最大多普勒频移， T_s 是采样时长。$\mathbf{u}_n$ 是零均值高斯激励噪声，其协方差矩阵为 $\sigma_u^2\mathbf{I}$，其中 $\sigma_u^2 = 1 - \beta^2$。复合项 $f_D T_s$表示归一化多普勒速率。在仿真中，我们选择 $f_D T_s = 0.005$，因此 $\beta = 0.9998$，这对应于频率为 2 GHz、采样时长为 1 ms 时 2.7 km/h 的低用户速度。对于卡尔曼滤波，我们使用式（4）中的测量数据以及式（13）中预测阶数为一的 AR模型来估计信道 $\{\mathbf{h}_n\}, 1 \le n \le N$。而在没有测量数据的情况下预测信道时，则使用简单的状态演化：$\mathbf{h}_{N+m} = \beta \mathbf{h}^{N+m-1}, 1 \le m \le P$。请注意，在设计卡尔曼滤波时，我们假设已知式（13）中的模型及其参数 β ；而对于所提出的预测方法，模型和参数均不可用，该方法将直接从数据中学习。

- 第二种场景是 3GPP 城市微蜂窝空间信道模型，它代表了更真实但更具挑战性的信道环境 [15]。我们采用[15] 中的默认空间信道模型参数，但 NumBsElements 为 N_t，NumMsElements 为 1，NumPaths 设置为 1。

C. 结果

我们首先考虑 AR模型的第一种场景。图 3(a) 展示了信道预测的归一化均方误差随预测信道数量 P 的变化结果。总体而言，待预测的信道越多，归一化均方误差就越高。可以看出，我们提出的采用注意力机制的信道预测方法优于不采用注意力机制的方法，而且两者的归一化均方误差都远低于传统信道估计方案。需要注意的是，这是因为我们提出的预测方法利用了信道的时间相关性，而传统信道估计并未利用这一点，只是使用导频来估计当前信道。随着预测信道数量增加，预测性能不可避免地会下降，最终不如传统信道估计。下文中，我们假设所提出的方案始终采用注意力机制。在所有考虑的方案中，卡尔曼滤波取得了最低的归一化均方误差，这是因为它利用了模型信息和已知参数，而这些信息和参数对于所提出的预测方法并不可用。最初的 N 信道估计结果的准确度会影响后续的信道预测性能，因此图 3(b) 展示了当 $P = 20$时，估计信道的训练信噪比与预测信道归一化均方误差之间的关系。可以看出，随着信噪比升高，传统信道估计的归一化均方误差持续降低；而对于预测方法，当信噪比超过某一阈值后，归一化均方误差趋于饱和。这是因为无论信道估计多么准确，信道预测性能都会受到预测信道数量的限制。

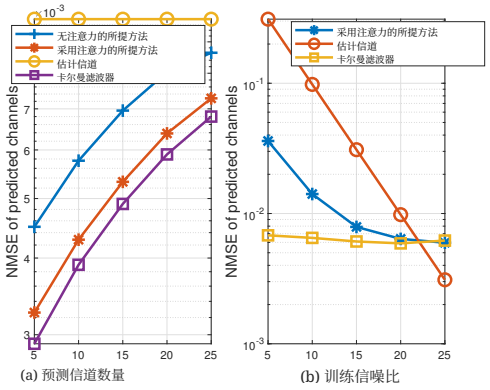

图 3. 预测信道的归一化均方误差与预测信道数量的关系；以及 (b) 信噪比，$P = 20$。

接下来，我们分别在图 4(a) 和图 4(b) 中绘制和速率及有效和速率，并将其归一化为加权最小均方误差解所达到的和速率，以预测信道数量为横轴。从图 4(a) 可以看出，我们提出的方案达到了最高和速率，而采用传统信道估计时的和速率最低。先预测信道、再使用 ZF波束成形的分离方案，其和速率略低于卡尔曼滤波。图 4(b) 中有效和速率呈现出相同的趋势。由于计入了信道估计开销，可达到的有效和速率低于图 4(a) 中的和速率。

对于我们所提出的方案，随着预测信道数量的增加，和速率性能呈现平台效应。根据第III.C节中的分析，这是因为更多未来信道会降低预测精度，进而降低有效和速率。

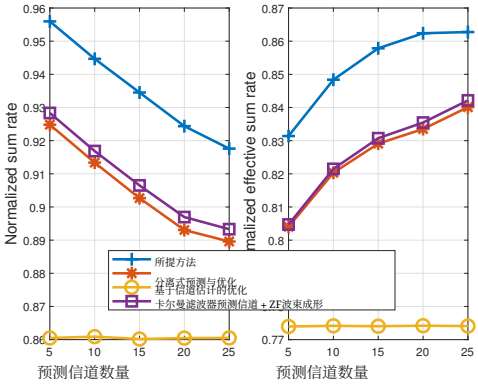

图 4. 归一化和速率随预测信道数量的变化结果。

接下来，我们考察用户速度对归一化和速率的影响，结果如图 5 所示。正如预期，随着用户移动性增加，所有方案的和速率都会下降。卡尔曼滤波在低速时表现良好，但在用户移动性较高时，无法很好地跟踪信道动态的变化。所提方法的有效和速率远高于卡尔曼滤波器和独立方案。理论上，在用户移动性较高时，信道估计方法明显优于其他方法，但实际上可能无法及时获得信道估计。

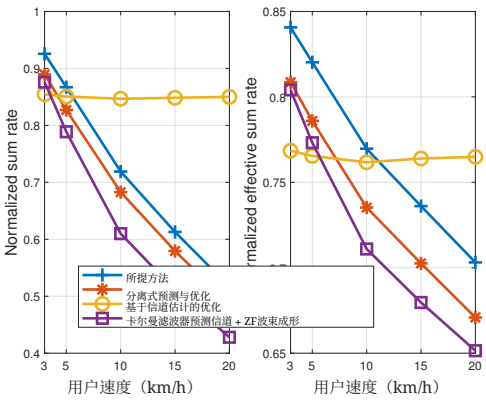

图 5. 归一化和速率随用户速度的变化结果。

接下来，我们考虑城市微蜂窝SCM模型的第二种场景。归一化和速率和有效和速率的结果如图6所示。比较中未纳入卡尔曼滤波，因为我们在仿真中发现其性能并不理想，这可能是因为信道动态过于复杂，卡尔曼滤波难以进行预测。从图6(a)可以看出，随着预测信道数量增加，分离优化的和速率迅速下降，甚至远低于传统的基于信道估计的优化。我们提出的方案

仍然能够达到最高和速率，不过随着预测信道数量增加，其与传统方案之间的性能差距逐渐缩小。这凸显了对预测波束成形进行端到端学习的重要性。图6(b)展示了有效和速率的结果。正如预期，我们提出的方案性能更优；而当预测信道数量较多时，分离方案的性能不如基于估计的优化。我们提出的方案和分离方案的和速率均呈现先升后降的趋势。这进一步验证了我们在第III.C节中的分析：降低开销与获得高质量信道预测之间需要取得平衡。例如，对于我们提出的方案和分离方案，预测信道数量的最优值分别为10和5。

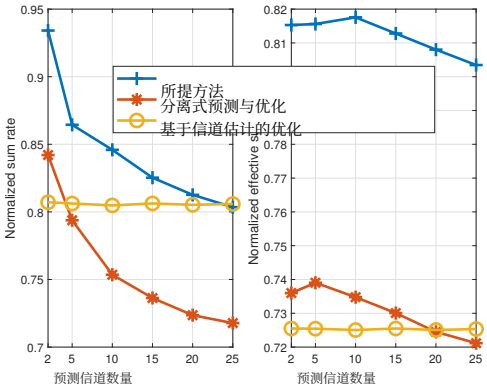

图6. 归一化和速率随预测SCM信道数量的变化结果。

最后，我们在图 7 中评估给定总帧长为 $N + P = 40$ 时预测信道数量 P 的影响。对于如何选择最优的 N 和 P，目前没有定量标准。直观而言，当 N 较大时，我们可获得更多信道信息，从而更准确地预测未来信道，但这也会带来更高的开销，进而降低有效和速率。针对特定场景，可以通过实证研究找到良好的折中方案。如图 7 所示，对于 AR模型，信道相对容易预测，即使已知信道数量较少（N），所提出的算法也能预测大量未来信道（P =30 个）。而对于 SCM模型，跟踪信道演化更具挑战性，因此只预测少量未来信道（$P = 10$ 个），以实现较高的有效和速率。

V. 结论

本文研究了多用户MISO下行链路中采用深度学习方法进行的预测波束成形。我们提出了一种通用框架，利用历史信道测量数据预测波束成形方案，以最大化和速率。我们设计了一种带有注意力层的长短期记忆网络，以提升信道预测性能。仿真结果表明，与传统的基于信道估计的优化，以及先单独进行预测、再进行优化的方案。

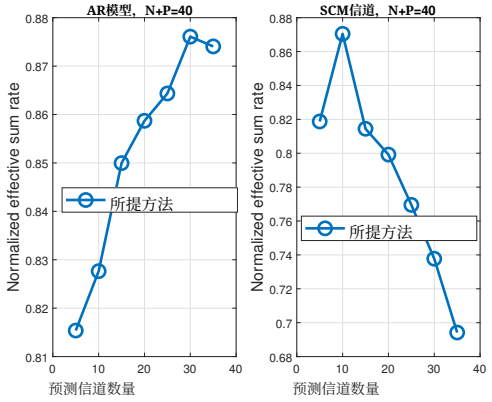

图 7. 固定帧长为 $N + P = 40$ 时，预测信道数量对归一化和速率的影响。

参考文献

[1] A. Duel-Hallen, S. Hu 和 H. Hallen, 《衰落信号的长程预测》, *IEEE*信号处理杂志, 第17卷, 第3期, 第62-75页, 2000年5月。[2] Y. Zhu、X. Dong 和 T. Lu, 《用于无线信道预测的自适应无参数循环神经结构》, *IEEE Trans. Com- mun.*, 第67卷, 第11期, 第8086-8096页, 2019年11月。[3] S. R. Mattu、L. N. Theagarajan 和 A. Chockalingam, 《深度信道预测: 用于时变衰落信道接收机设计的深度神经网络框架》, *IEEE Trans. Veh. Technol.*, 第71卷, 第6期, 第6439-6453页, 2022年6月。[4] J. Joo、M. C. Park、D. S. Han 和 V. Pejovic, 《基于深度学习的真实车载通信信道预测》, *IEEE Ac- cess*, 第7卷, 第27846-27858页, 2019年。[5] J. Yuan、H. Q. Ngo 和 M. Matthaiou, 《大规模MIMO中基于机器学习的信道预测与信道老化》, *IEEE Trans. Wireless Commun.*, 第19卷, 第5期, 第2960-2973页, 2020年5月。[6] H. Kim 等, 《大规模MIMO信道预测: 卡尔曼滤波与机器学习的比较》, *IEEE Trans. Commun.*, 第69卷, 第1期, 第518-528页, 2021年1月。[7] W. Yuan、C. Liu、F. Liu、S. Li 和 D. W. K. Ng, 《用于无人机通信的基于学习的预测波束成形及抖动处理》, *IEEE Wireless Commun. Lett.*, 第9卷, 第11期, 第1970-1974页, 2020年11月。[8] C. Liu 等, 《用于车联网感知与通信一体化的基于学习的预测波束成形》, *IEEE J. Sel. Areas Commun.*, 第40卷, 第8期, 第2317-2334页, 2022年8月。[9] W. Yuan、F. Liu、C. Masouros、J. Yuan、D. W. K. Ng 和 N. Gonz´alez- Prelcic, 《面向车联网的贝叶斯预测波束成形: 低开销雷达通信一体化方案》, *IEEE Trans. Wireless Commun.*, 第20卷, 第3期, 第1442-1456页, 2021年3月。[10] S. S. Christensen、R. Agarwal、E. D. Carvalho 和 J. M. Cioffi, 《利用加权最小均方误差实现MIMO广播信道波束成形设计中的加权和速率最大化》, *IEEE Trans. Wireless Commun.*, 第7卷, 第12期, 第4792-4799页, 2008年12月。[11] E. Bj¨ornson、M. Bengtsson 和 B. Ottersten, 《最优多用户发射波束成形: 一个具有简单解结构的难题》, *IEEE*信号处理杂志, 第31卷, 第4期, 第142-148页, 2014年7月。[12] I. H. Sarker, 《深度学习: 技术、分类体系、应用与研究方向综述》, *SN Computer Science*, 文章编号: 420（2021）, 2021年8月。[13] A. Vaswani 等, 《注意力就是一切》, *Advances in Neural Information Processing Systems*, 第30卷, 2017年12月。[14] W. Xia、G. Zheng、Y. Zhu、J. Zhang、J. Wang 和 A. P. Petropulu, 《用于MISO下行波束成形优化的深度学习框架》, *IEEE Trans. Commun.*, 第68卷, 第3期, 第1866–1880页, 2020年3月。[15] J. Salo、G. Del Galdo、J. Salmi、P. Ky¨osti、M. Milojevic、D. La-selva 和 C. Schneider, 《3GPP空间信道模型的MATLAB实现（3GPP TR 25.996）》, [在线]。获取地址: http://www.tkk.fi/Units/Radio/scm/, 2005年1月。