arXiv:2603.04764v1 [eess.SP] 5 Mar 2026

基于深度学习的保形贝叶斯滤波器实现 MIMO信道预测

Dongwon Kim，*IEEE* 学生会员，Jinu Gong 和 Joonhyuk Kang，*IEEE* 会员

摘要——**信道预测已成为在信道老化情况下获取准确信道状态信息（CSI）的有效方案。现有方法存在固有局限：传统的基于卡尔曼滤波器（KF）的方法容易受到模型失配的影响，而基于深度学习（DL）的方法则会产生过度自信的预测。为解决这些问题，我们提出了一种基于深度学习（DL）的共形贝叶斯滤波器（DCBF），将基于深度学习的预测、保形分位数回归（CQR）和贝叶斯滤波相结合。该框架能够以有原则的方式融合校准先验和观测值，从而生成具有校准不确定性的可靠信道预测。仿真结果表明，DCBF 显著提升了基于深度学习的预测性能，并优于基于卡尔曼滤波器的方法。**

索引词—**MIMO信道预测、保形预测、不确定性量化、贝叶斯滤波**

I. 引言

多ULTIPLE-input输入多输出（MIMO）系统是现代无线通信网络的基石，可通过空间复用和分集增益显著提升频谱效率 [1], [2]。要实现这些优势，必须准确获取信道状态信息（CSI），从而有效进行波束成形和预编码，以最大化系统性能。然而，及时获取 CSI 仍是一项重大挑战。天线数量不断增加，带来了巨大的导频开销；与此同时，用户移动性会导致信道老化，使估计的信道迅速过时 [3]。为解决这些问题，信道预测已成为一种颇具前景的方案。由于无线信道具有准平稳散射环境 [4], 所带来的时间相关性，因此可以根据过去的观测值预测未来信道状态。

传统的信道预测通常依赖统计方法，将衰落信道近似为自回归（AR）过程，并在线性模型假设下应用卡尔曼滤波（KF），而这一假设在实际中往往并不成立。此外，KF 的计算复杂度随天线数量呈立方增长，带来显著的计算开销，从而限制了其在 MIMO 系统中用于低时延预测的应用。

随着深度学习（DL）的显著进步，基于 DL 的信道预测方法已在 MIMO 系统中得到广泛探索 [7], [8]。凭借深度神经网络（DNN）强大的表征能力，DL 模型能够从大规模数据集中有效学习复杂的信道特性。例如，卷积神经网络（CNN）已被用于利用频谱相关性进行信道重构 [9], ，而长短期记忆（LSTM）网络则能够捕捉连续信道实现之间的时间依赖关系 [10]。近期，研究者将基于 Transformer 的架构引入信道预测 [11],，利用自注意力机制建模长程依赖关系，进一步提高预测精度。尽管取得了这些进展，大多数基于 DL 的信道预测框架仍只提供点估计，往往导致过度自信且不可靠的预测。

与先前工作不同，我们的方法将可靠的不确定性量化融入基于 DL 的信道预测，从而实现经过统计验证的预测，并减轻传统基于 DL 的预测器固有的过度自信问题。为实现经过校准的不确定性量化，我们采用保形分位数回归（CQR），利用校准数据调整预测器输出的原始分位数，使调整后的分位数满足有保证的覆盖性质。近期，多项保形预测（CP）研究已应用于无线网络系统中的资源分配 [12], 、预测[13],和波束成形选择 [14]。

在本研究中，我们基于基于深度学习的信道预测器构建了一种深度保形贝叶斯滤波器（DCBF）。所提出的框架包括三个步骤。首先，我们将DNN模型用作分位数预测器，以估计未来信道的分位数。其次，我们采用保形分位数回归（CQR）对分位数进行校准，从而得到经过良好校准的预测分布。最后，贝叶斯滤波将经过校准的预测分布与含噪观测相结合，以递归方式细化信道预测。在各种信道模型上的仿真结果表明，与基于卡尔曼滤波（KF）和基于深度学习的信道预测器相比，所提出的DCBF实现了更优的性能。

本文其余部分安排如下。第二节阐述信道预测问题。第三节介绍 DCBF 框架。第四节将所提方法与其他基线方法进行性能评估。最后，第五节总结全文。

Dongwon Kim 和 Joonhyuk Kang 任职于韩国科学技术院（KAIST）电气工程学院，地址：韩国大田 34141（电子邮箱：davinci5694@kaist.ac.kr；jhkang@ee.kaist.ac.kr）。Jinu Gong 任职于汉城大学应用人工智能系，地址：韩国首尔（电子邮箱：jinugong@hansung.kr）。本研究部分由韩国政府（科学技术信息通信部）资助的信息通信技术规划评估院（IITP）—信息技术研究中心（ITRC）项目支持（IITP-2025-RS-2020-II201787，资助比例：50%）；另有部分由韩国政府（科学技术信息通信部）资助的信息通信技术规划评估院（IITP）6G·云研究与教育开放枢纽项目支持（IITP-2025-RS-2024-00428780，资助比例：25%）。此外，本研究还获得汉城大学对 Jinu Gong 的经费支持（资助比例：25%）。

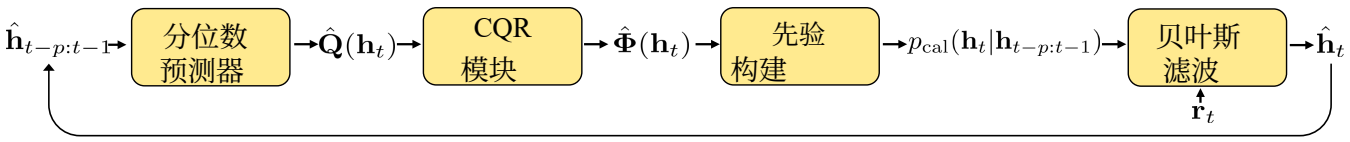

图 1. 共形贝叶斯滤波框架：(i) 通过基于深度学习的信道分位数预测器进行预测；(ii) 通过保形分位数回归进行校准；(iii) 利用校准分位数构建先验分布；(iv) 通过贝叶斯滤波融合预测信息与测量信息。

II. 系统模型

我们考虑一个单小区多输入多输出系统，其中基站（BS）配备 M 根天线，每个 K 个用户设备（UE）配备 N 根天线。假设采用正交频分多址（OFDMA），以消除用户间干扰。因此，在不失一般性的前提下，信道预测聚焦于单个 UE。基站在时隙 t 接收到的来自第 k 个 UE 的信号表示为

$$\mathbf{r}_{t,k} = \sqrt{\rho}\mathbf{H}_{t,k}\mathbf{s}_{t,k} + \mathbf{w}_{t,k}, \tag{1}$$

其中，$\mathbf{H}_{t,k} \in \mathbb{C}^{M\times N}$ 表示基站与第 k 个用户设备之间的信道矩阵，ρ 表示发射功率，$\mathbf{s}_{t,k} \in \mathbb{R}^{N\times 1}$ 表示发射信号，$\mathbf{w}_{t,k} \sim \mathcal{CN}(\mathbf{0}_M, \sigma_w^2\mathbf{I}_M)$ 表示复加性高斯白噪声（AWGN）。为简洁起见，省略用户索引 k。

信道预测问题基于p先前的接收信号 $\{\mathbf{r}^{t-p+1},\dots,\mathbf{r}_t\}$（其中 $p \geq 1$）进行建模，可表示为

$$\min \ ||\mathbf{H}_{t+1} - \hat{\mathbf{H}}_{t+1}||^2, \tag{2}$$

$$\text{subject to}\, \hat{\mathbf{H}}_{t+1} = f(\mathbf{r}_{t-p+1},\dots,\mathbf{r}_t), \tag{3}$$

其中，$\hat{}\mathbf{H}_{t+1}$ 表示第（$t+1$）个时隙的预测信道，$f(\cdot)$ 表示任意信道预测函数。此外，我们将信道矩阵$\mathbf{H}_t$ 向量化为$\mathbf{h}_t \in \mathbb{R}^{L\times 1}$，其中 $L = 2MN$。

III. 基于共形贝叶斯滤波器的信道预测

本节介绍基于深度学习的信道预测框架，该框架将保形分位数回归模块与贝叶斯滤波相结合，以进行序贯细化，如图 1 所示。该框架由三个主要部分组成：(i) 基于深度学习的信道分位数预测器，利用深度神经网络估计未来信道的分位数；(ii) 保形分位数回归模块，用于调整预测分位数以确保覆盖保证；(iii) 贝叶斯滤波，利用接收信号中的测量信息与校准分位数。

A. 深度分位数信道预测器

整个数据集被划分为四个互不相交的子集，分别记为 $\mathcal{I}_1, \mathcal{I}_2, \mathcal{I}_3, \mathcal{I}_4$，对应训练集、验证集、校准集和测试集。利用训练集 $\mathcal{I}_1$，设计由 θ 参数化的深度神经网络信道预测器 $f_\theta(\cdot)$，以预测未来信道分布$\mathbf{Q}(\mathbf{h}_t)$的多个分位数。不同于为每个分位数水平分别训练一个神经网络，单个神经网络会联合输出一个分位数向量，如下所示：

$$\hat{\mathbf{Q}}(\mathbf{h}_t) = \hat{f}_\theta(\hat{\mathbf{h}}_{t-p:t-1}) \in \mathbb{R}^{L\times G}, \tag{4}$$

其中，$\hat{}\mathbf{h}_{t-p:t-1} = [\hat{}\mathbf{h}_{t-p}^{\mathrm{T}}、\dots\dots、\hat{}\mathbf{h}_{t-1}^{\mathrm{T}}]^{\mathrm{T}}$ 表示过去 p个时隙中估计信道$\mathbf{h}_t$ 的拼接向量，G 表示分位数水平的数量。输出$\hat{}\mathbf{Q}(\mathbf{h}_t)$表示未来信道$\mathbf{h}_t$的预测分位数，其中每个条目$\hat{}q_{l,\tau}(\mathbf{h}_t)$对应第 l个天线信道链路的第 τ个分位数。深度神经网络信道预测器 θ 的参数通过最小化聚合分位数回归损失进行优化。对于分位数水平 τ 和第 l根天线，针球损失定义为

$$\begin{aligned}&\rho_\tau(\mathbf{h}_t[l], \hat{q}_{l,\tau}(\mathbf{h}_t))\\ &= \tau(\mathbf{h}_t[l] - \hat{q}_{l,\tau}(\mathbf{h}_t))\mathbb{1}(\hat{q}_{l,\tau}(\mathbf{h}_t) \leq \mathbf{h}_t[l])\\ &+ (1-\tau)(\hat{q}_{l,\tau}(\mathbf{h}_t) - \mathbf{h}_t[l])\mathbb{1}(\hat{q}_{l,\tau}(\mathbf{h}_t) > \mathbf{h}_t[l]),\end{aligned} \tag{5}$$

其中 $\mathbb{1}(\cdot)$表示指示函数。在所有天线链路和分位数水平上聚合的总体损失由下式给出
by

$$L(\theta) = \frac{1}{|\mathcal{I}_1|LG}\sum_{t=1}^{|\mathcal{I}_1|}\sum_{l=1}^{L}\sum_{j=1}^{G}\rho_{\tau_j}(\mathbf{h}_t[l], \hat{q}_{l,\tau_j}(\mathbf{h}_t)), \tag{6}$$

其中 $|\mathcal{I}_1|$ 是训练样本的总数。针球损失根据分位数水平 τ 对高估和低估施加非对称惩罚，使训练得到的预测器能够逼近所需的分位数。

B. 共形分位数回归

在本小节中，我们说明如何应用保形分位数回归来校准式(4)中的分位数输出。利用校准数据集 $\mathcal{I}_3$，计算一致性分数，以调整$\hat{}$原始分位数预测$\mathbf{Q}(\mathbf{h}_t)$。对于每个校准集样本 $t \in \mathcal{I}_3$、分位数水平τ_j以及每条天线链路 l，一致性分数定义为

$$e_{l,\tau_j}^{(t)} = \mathbf{h}_t[l] - \hat{q}_{l,\tau_j}(\mathbf{h}_t) : t \in \mathcal{I}_3, \tag{7}$$

它度量预测的第τ_j分位数$\hat{}q_{l,\tau_j}(\mathbf{h}_t)$与真实未来信道$\mathbf{h}_t[l]$之间的差异。保形分位数回归对原始分位数估计的调整如下

$$\hat{\phi}_{l,\tau_j}(\mathbf{h}_t) = \hat{q}_{l,\tau_j}(\mathbf{h}_t) + \hat{\gamma},\ \hat{\gamma} = \mathrm{Quantile}_{\tau_j}(e_{l,\tau_j}^{(t)}, \mathcal{I}_3), \tag{8}$$

其中，$\mathrm{Quantile}_{\tau_j}(\cdot,\cdot)$ 表示校准分数 $e_l^{(t)}, {}^{\tau_j}$ 的 τ_j 分位经验分位数。在校准集和测试集的样本均从同一未知分布中抽取这一独立同分布（i.i.d.）抽样假设下，调整后的分位数

满足边际覆盖保证

$$\Pr\left[\mathbf{h}_t[l] \le \hat{\phi}_{l,\tau_j}(\mathbf{h}_t)\right] \ge \tau_j, \tag{9}$$

如 [15] 中所述。换言之，调整后的分位数$\phi_{l,\ \tau_j}(\mathbf{h}_t)$ 达到目标分位数水平 τ_j，确保真实信道值不高于该值的概率至少为τ_j。

对原始分位数进行校准后，校准后的分位数向量 $\mathbf{\Phi}(\mathbf{h}_t) = [\phi_{1,\tau_j}(\mathbf{h}_t) \ldots, \phi_{L,\tau_j}(\mathbf{h}_t)]$ 构成校准先验分布 $p_{\text{cal}}(\mathbf{h}_t|\mathbf{h}^{t-p:t-1})$。具体而言，第 l 维未来信道的先验分布被建模为相邻校准分位数之间区间上的分段均匀分布：

$$p_{\text{cal}}(\mathbf{h}_t[l] \mid \mathbf{h}_{t-p:t-1}[l]) = \begin{cases} \frac{\tau_1-\tau_0}{\hat{\phi}_{l,\tau_1}(\mathbf{h}_t)-\hat{\phi}_{l,\tau_0}(\mathbf{h}_t)}, \text{if } \mathbf{h}_t[l]\in[\hat{\phi}_{l,\tau_0}(\mathbf{h}_t), \hat{\phi}_{l,\tau_1}(\mathbf{h}_t)] \\ \frac{\tau_2-\tau_1}{\hat{\phi}_{l,\tau_2}(\mathbf{h}_t)-\hat{\phi}_{l,\tau_1}(\mathbf{h}_t)}, \text{if } \mathbf{h}_t[l]\in[\hat{\phi}_{l,\tau_1}(\mathbf{h}_t), \hat{\phi}_{l,\tau_2}(\mathbf{h}_t)] \\ \quad\vdots \\ \frac{\tau_{G+1}-\tau_G}{\hat{\phi}_{l,\tau_{G+1}}(\mathbf{h}_t)-\hat{\phi}_{l,\tau_G}(\mathbf{h}_t)}, \text{if } \mathbf{h}_t[l]\in[\hat{\phi}_{l,\tau_G}(\mathbf{h}_t), \hat{\phi}_{l,\tau_{G+1}}(\mathbf{h}_t)] \\ 0, \text{ otherwise,} \end{cases} \tag{10}$$

其中，τ_{G+1} 和 τ_0 分别对应 1 和 0。这种构造为相邻分位数之间的每个区间分配 $\tau_g - \tau_{g-1}$ 的概率质量，从而确保校准先验分布在所有分位数水平上均符合目标覆盖率。为简化实现，与边界分位数水平相对应的预测信道值 $\phi_{l,\ \tau_0}(\mathbf{h}_t)$ 和 $\phi_{l,\ \tau_{G+1}}(\mathbf{h}_t)$ 被设为训练集中观测到的信道值的最小值和最大值。

C. 通过重要性采样进行后验均值估计

给定第 t个时隙的接收信号 $\mathbf{r}_t$ ，目标是估计信道 $\mathbf{h}_t$ 的后验均值，该均值综合了经过校准的深度分位数信道预测器提供的信道 $\mathbf{h}_t$ 先验知识，以及接收信号 $\mathbf{r}_t$中的观测信息。第 l条天线链路的后验均值 $\hat{}\mathbf{h}_t[l]$表示为

$$\mathbb{E}_{p(\mathbf{h}_t[l]|\mathbf{r}_t[l])}[\mathbf{h}_t[l]]. \tag{11}$$

根据贝叶斯定理，后验分布表示为

$$p(\mathbf{h}_t[l] \mid \mathbf{r}_t[l]) = \frac{p(\mathbf{r}_t[l] \mid \mathbf{h}_t[l])\, p(\mathbf{h}_t[l])}{p(\mathbf{r}_t[l])}, \tag{12}$$

其中先验分布 $p(\mathbf{h}_t[l])$可由校准分布 $p_{\text{cal}}(\mathbf{h}_t[l]|\mathbf{h}_{t-p:t-1}[l])$得到。将$p(\mathbf{h}_t[l])$替换为 $p_{\text{cal}}(\mathbf{h}_t[l]|\mathbf{h}_{t-p:t-1}[l])$并代入式(12)，后验均值变为

$$\mathbb{E}_{p(\mathbf{h}_t[l]|\mathbf{r}_t[l])}[\mathbf{h}_t[l]] = \frac{1}{p(\mathbf{r}_t[l])} \int \mathbf{h}_t[l]\, p(\mathbf{r}_t[l] \mid \mathbf{h}_t[l]) \times p_{\text{cal}}(\mathbf{h}_t[l]|\mathbf{h}_{t-p:t-1}[l])\, \mathrm{d}\mathbf{h}_t[l]. \tag{13}$$

算法1 基于深度共形贝叶斯滤波器的信道预测（DCBF）

输入： 数据集 $\mathcal{I}_1, \mathcal{I}_2, \mathcal{I}_3, \mathcal{I}_4$，分位数水平 $\{\tau_j\}_{j=1}^{G}$，历史长度 p，样本数 S

对于 $t = p+1, \ldots, T$**执行**
  先验的分位数 基于深度学习的信道预测器进行$\mathbf{Q}(\mathbf{h}_t)$ 预测-道预测器 $\hat{f}_\theta(\cdot)$
  对于 $l = 1, \ldots, L$ **do**
    获得校准分位数 $\hat{\phi}_{l,\ \tau}(\mathbf{h}_t)$，如公式 (8) 所示
    构造预测先验分布 $p_{\text{cal}}(\mathbf{h}_t[l] \mid \mathbf{h}_{t-p:t-1}[l])$，如公式 (10) 所示
    按以下方式获得后验均值 $\mathbb{E}_{p(\mathbf{h}_t[l]|\mathbf{r}_t[l])}[\mathbf{h}_t[l]]$ 式（14）
    预测下一时隙信道 使用基于 DL 的信道预测器$\mathbf{h}_{t+1}$ - 信道预测器 $\hat{f}_\theta(\cdot)$，其中输入为过去的信道历史 $\hat{\mathbf{h}}_{t-p+1:t}[l]$
  结束 for
结束 for

输出： 返回 the 集合 of 预测的 信道 $\{\hat{\mathbf{h}}_t\}_{t=p+2}^{T+1}$

由于式(13)中的积分通常难以计算，我们采用重要性采样，利用抽样 $\{\mathbf{h}_t^{(i)}[l]\}_{i=1}^{S}$ 独立同分布$\sim$ $p_{\text{cal}}(\mathbf{h}_t[l]|\mathbf{h}_{t-p:t-1}[l])$来近似该积分。相应地，后验均值由样本的加权平均近似为

$$\mathbb{E}_{p(\mathbf{h}_t[l]|\mathbf{r}_t[l])}[\mathbf{h}_t[l]] \approx \sum_{i=1}^{S} \gamma_i \mathbf{h}_t^{(i)}[l], \tag{14}$$

其中，归一化重要性权重 γ_i 定义为

$$\gamma_i = \frac{p(\mathbf{r}_t[l] \mid \mathbf{h}_t^{(i)}[l])}{\sum_{j=1}^{S} p(\mathbf{r}_t[l] \mid \mathbf{h}_t^{(j)}[l])}. \tag{15}$$

此外，重要性权重 γ_i 通过计算每个样本的似然而得。对于样本$\mathbf{h}_t^{(i)}[l]$，观测到的接收信号的似然表示为

$$p(\mathbf{r}_t[l]|\mathbf{h}_t[l]) \sim \mathcal{N}(\sqrt{\rho}\mathbf{h}_t[l], \sigma_w^2/2), \tag{16}$$

其中，每条天线链路 l 上的接收信号服从均值为 $\sqrt{\rho}\mathbf{h}_t[l]$、方差为$\sigma_w^2/2$的高斯分布。后验均值表示经过细化的信道估计，随后用作基于深度学习的信道预测器 $f_\theta(\cdot)$的输入。基于该输入，根据公式（10）推导未来信道的预测分布。未来信道值取预测分布的均值；由于先验分布被建模为分段均匀分布，因此可以直接计算该均值。

总之，后验均值被计算为经校准先验样本的似然加权平均值，并作为时隙 t处的精细化信道估计。随后将该后验均值输入基于深度学习的信道预测器$\hat{}f_\theta(\cdot)$，用于未来信道预测，并且该过程按算法1所述递归应用以预测信道。

表 I 仿真参数

参数	值	参数	值
用户速度	5，20 千米/小时	信道历史长度 p	3
热噪声	−174 分贝毫瓦/赫兹	多层感知机隐藏层大小	2
带宽	10 兆赫	MLP隐藏层维度	64
载波频率	3.59 GHz	GRU隐藏层大小	2
符号间隔	2 ms	GRU隐藏层维度	128
预测间隔	2 ms	训练轮次	50

IV. 仿真结果

在本节中，我们将所提出的方法与若干基线方法进行比较，包括 [16],中的过时信道估计、基于卡尔曼滤波的预测器，以及分别采用多层感知机（MLP）和门控循环单元（GRU）实现的基于深度学习的预测器。预测准确度使用归一化均方误差（NMSE）指标进行衡量，其定义为

$$\mathrm{NMSE} = \mathbb{E}\left[\frac{\|\hat{\mathbf{h}}_{t+1} - \mathbf{h}_{t+1}\|_2^2}{\|\mathbf{h}_{t+1}\|_2^2}\right]. \tag{17}$$

信道模型和深度神经网络架构的总体超参数汇总于表 I 中。假设采用 2×2 MIMO 配置，并考虑城市微蜂窝（UMi）和城市宏蜂窝（UMa）信道模型 [17]。信道数据通过 Sionna [18]生成。训练基于深度学习的预测器时，批量大小设为 64，学习率为 $1e-3$。共生成 10000 个信道样本，并按以下比例划分数据集 $|\mathcal{I}_1| : |\mathcal{I}_2| : |\mathcal{I}_3| : |\mathcal{I}_4| = 7 : 1 : 1 : 1$。预测器分位数设为 τ_1、……、$\tau_G = [0.1, \ldots, 0.9]$，其中$G = 9$。为增强模型在不同发射功率条件下的鲁棒性，训练基于深度学习的预测器时，输入信道向量中加入了随机高斯噪声。为进行公平比较，基于卡尔曼滤波的预测器也使用相同数量的样本来估计自回归参数，与训练基于深度学习的预测器所用的数据集大小保持一致。

在图 2 中，我们报告了信道模型为微蜂窝信道模型、用户速度为 5 km/h 时，归一化均方误差随发射功率变化的情况。随着发射功率增加，所有方法的预测误差均有所降低。在整个发射功率范围内，所提出的 DCBF-MLP 和 DCBF-GRU 方法均优于 KF 基线，获得了约 2–3 dB 的增益，并且所有方法在发射功率为 20 dBm 时趋于收敛。此外，两个 DCBF 变体均提升了各自对应的基于深度学习的预测器的性能。需要注意的是，所提出的 DCBF 框架对多层感知机模型带来了更大的性能提升。这表明 DCBF 能更有效地补偿置信度较低的先验预测。虽然门控循环单元模型本身优于多层感知机模型，但它往往会产生过度自信的预测，从而限制校准和新观测信息在滤波更新中的作用。

图3展示了仿真环境为 UMichannel 信道模型、用户速度为 20 km/h 时，归一化均方误差随发射功率的变化情况。与图 2 相比，整体趋势与 5 km/h 时的情况相似。具体而言，

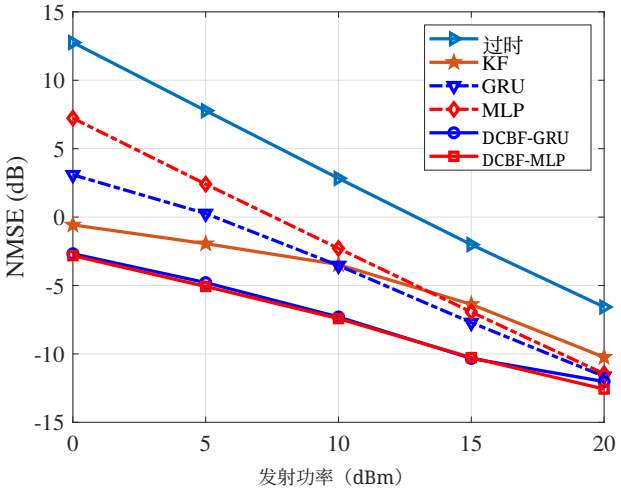

图 2. 在微蜂窝信道模型下、用户速度为 5 km/h 时，过时信道、基于卡尔曼滤波的预测器、门控循环单元预测器（采用和未采用 DCBF 方案）以及基于多层感知机的预测器（采用和未采用 DCBF 方案）的归一化均方误差随发射功率的变化。

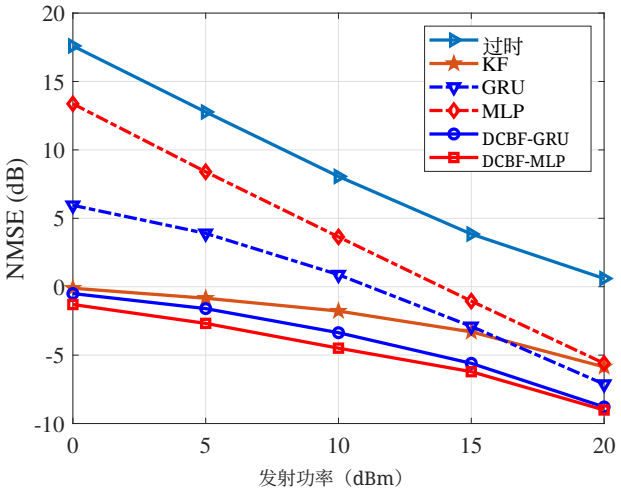

图3. 在微蜂窝信道模型下、用户速度为 20 km/h 时，过时信道、基于卡尔曼滤波的预测器、门控循环单元预测器（采用和未采用 DCBF 方案）以及基于多层感知机的预测器（采用和未采用 DCBF 方案）的归一化均方误差随发射功率的变化。

在发射功率为 10 分贝毫瓦时，DCBF-MLP 相比基于卡尔曼滤波的预测性能提升约 2.8 dB。

图4和图5比较了用户速度为5 km/h和20 km/h时的归一化均方误差（NMSE）性能，其中信道模型为宏蜂窝信道。在这两种信道环境中，性能趋势与微蜂窝信道（UMi）情况相似。在所有发射功率水平下，所提出的DCBF变体始终优于其未经校准的对应方法（门控循环单元（GRU）和多层感知机（MLP）），这表明保形校准有助于为贝叶斯滤波构建更准确的先验。这些结果表明，DCBF在不同移动性条件和信道模型下均保持稳健，其预测准确度优于所有基线方法。

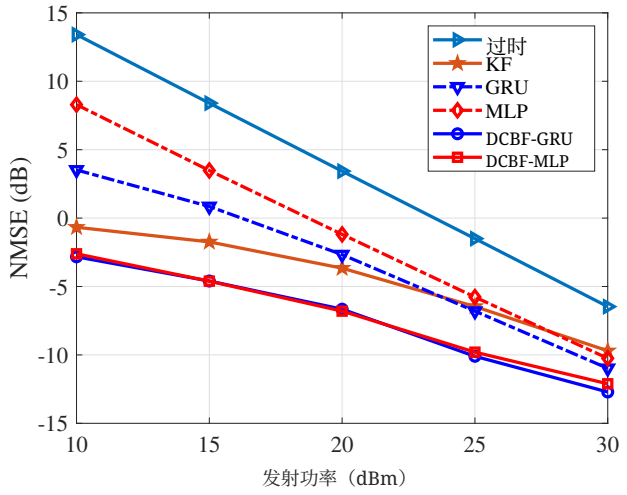

图4. 在用户速度为5 km/h的城市宏蜂窝信道模型下，过时信道、基于卡尔曼滤波的预测器、门控循环单元预测器（采用和未采用DCBF方案）以及基于多层感知机的预测器（采用和未采用DCBF方案）的归一化均方误差随发射功率的变化。

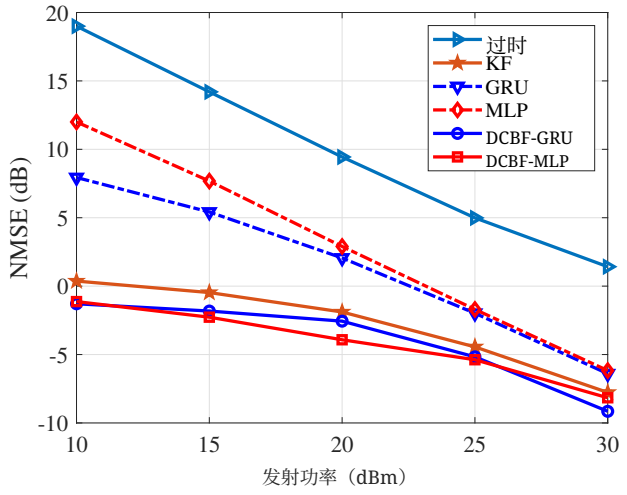

图5. 在用户速度为20 km/h的城市宏蜂窝信道模型下，过时信道、基于卡尔曼滤波的预测器、门控循环单元预测器（采用和未采用DCBF方案）以及基于多层感知机的预测器（采用和未采用DCBF方案）的归一化均方误差随发射功率的变化。

V. 结论

本文提出了一种用于MIMO信道预测的新型DCBF 框架。DCBF 框架融合了基于深度学习的预测器的分位数、保形校准和贝叶斯滤波，从而生成经过校准的预测分布，并以有原则的方式融合先验预测与含噪观测。在各种3GPP信道模型和用户速度下进行的数值评估表明，所提出的方法始终优于基于卡尔曼滤波（KF）的预测器和现有的基于深度学习的方法。未来工作尤其值得关注的是，进一步引入在线保形校准，以更好地适应快速变化的信道统计特性。

参考文献

[1] L. Lu、G. Y. Li、A. L. Swindlehurst、A. Ashikhmin 和 R. Zhang，“大规模 MIMO 概述：优势与挑战”，*IEEE*信号处理专题期刊，第 8 卷，第 5 期，第 742–758 页，2014 年 10 月。[2] C.-X. Wang、X. You、X. Gao、X. Zhu、Z. Li、C. Zhang、H. Wang、Y. Huang、Y. Chen、H. Haas、J. S. Thompson、E. G. Larsson、M. D. Renzo、W. Tong、P. Zhu、X. Shen、H. V. Poor 和 L. Hanzo，“迈向 6G：愿景、需求、关键技术与测试平台”，*IEEE*通信调查与教程，第 25 卷，第 2 期，第 905–974 页，2023 年第二季度。[3] C. Kong、C. Zhong、A. K. Papazafeiropoulos、M. Matthaiou 和 Z. Zhang，“信道老化下大规模 MIMO 系统的和速率与功率缩放”，*IEEE*通信汇刊，第 63 卷，第 12 期，第 4879–4893 页，2015 年 12 月。[4] N. Palleit 和 T. Weber，“非平坦衰落信道的时间预测”，载于*2011 IEEE*声学、语音与信号处理国际会议（*ICASSP*），捷克布拉格，2011 年。[5] C. Min、N. Chang、J. Cha 和 J. Kang，“使用卡尔曼滤波器为 IEEE802.16e 系统进行 MIMO-OFDM 下行信道预测”，载于*2007 IEEE*无线通信与网络会议，中国香港，2007 年。[6] S. Kashyap、C. Moll´en、E. Bj¨ornson 和 E. G. Larsson，“采用卡尔曼信道预测的时分双工大规模 MIMO 性能分析”，载于*2017 IEEE*声学、语音与信号处理国际会议（*ICASSP*），美国新奥尔良，2017 年。[7] W. Jiang 和 H. D. Schotten，“用于衰落信道预测的深度学习”，*IEEE*通信学会开放期刊，第 1 卷，第 320–332 页，2020 年。[8] B. Ko、H. Kim、M. Kim 和 J. Choi，“通过降低训练开销实现大规模 MIMO-OFDM 系统的基于机器学习的信道预测”，载于*2025 IEEE*无线通信与网络会议（*WCNC*），意大利米兰，2025 年。[9] J. Yuan、H. Q. Ngo 和 M. Matthaiou，“信道老化下大规模 MIMO 的基于机器学习的信道预测”，*IEEE*无线通信汇刊，第 19 卷，第 5 期，第 2960–2973 页，2020 年 5 月。[10] I. Helmy、P. Tarafder 和 W. Choi，“用于一比特大规模 MIMO 系统的基于长短期记忆网络-门控循环单元模型的信道预测”，*IEEE*车辆技术汇刊，第 72 卷，第 8 期，第 11 053–11 057 页，2023 年 8 月。[11] H. Jiang、M. Cui、D. W. K. Ng 和 L. Dai，“基于 Transformer 的精准信道预测：让移动性不再成为问题”，*IEEE*通信领域选题期刊，第 40 卷，第 9 期，第 2717–2732 页，2022 年 9 月。[12] D. Kim、M. Zecchin、S. Park、J. Kang 和 O. Simeone，“通过局部在线保形预测实现稳健的贝叶斯优化”，*IEEE*信号处理汇刊，第 73 卷，第 2039–2052 页，2025 年。[13] M. Zecchin、F. Hellstr¨om、S. Park、S. S. Shitz 和 O. Simeone，“协变量偏移下加权保形风险控制的泛化能力与信息性”，载于*2025 IEEE*信息论国际研讨会（*ISIT*）。IEEE，2025 年，第 1–6 页。[14] W. Deng、B. Shi、M. Li 和 O. Simeone，“Scan-best：借助 6 GHz 以下频段进行近场波束选择并提供形式化可靠性保证”，*IEEE*认知通信与网络汇刊，第 12 卷，第 5506–5521 页，2026 年 1 月。[15] Y. Romano、E. Patterson 和 E. Candes，“保形化分位数回归”，载于神经信息处理系统进展，加拿大温哥华，2019 年。[16] H. Kim、S. Kim、H. Lee 和 J. Choi，“大规模 MIMO 信道预测：机器学习与卡尔曼滤波的比较”，载于*2020 IEEE Globecom Workshops*（*GC Wkshps*），中国台北，2020 年。[17] 3GPP，“5G；关于 0.5 至 100 GHz 频段信道模型的研究”，3GPP，TR 38.901，2020 年 11 月，Release 16。[18] J. Hoydis、F. A¨ıt Aoudia、S. Cammerer、M. Nimier-David、N. Binder、G. Marcus 和 A. Keller，“Sionna rt：用于无线电传播建模的可微分射线追踪”，载于*IEEE Globecom Workshops* 论文集（*GC Wkshps*），2023 年 12 月，第 317–321 页。