

基于 LSTM 的时钟抖动概率预测模型

程 铭

南京邮电大学通信与信息工程学院 江苏南京

【摘要】针对电力电子化电力系统中时钟抖动实时估计的工程需求，本文构建了一种基于长短期记忆网络（LSTM）的概率预测模型。模型采用双头结构，均值头输出抖动的点估计，方差头用于不确定性量化。在损失函数中引入对数校准项，并采用 MSE 预训练、弱校准联合训练和方差头单独校准的三阶段递进策略。将白噪声方差作为不可训练的工程先验注入方差头，使噪声引入的固有不确定性与模型估计的认知不确定性得以分离。在仿真数据集上，模型预测均方误差为 $7.12 \times 10^{-8} \text{ s}^2$ ，标准化残差标准差为 1.105，不同信号频率（1~9 Hz）下方差中位数稳定在 $4.87 \times 10^{-8} \text{ s}^2$ 附近。与标准 LSTM 和卡尔曼滤波的对比实验表明，本文模型在预测精度接近标准 LSTM 的条件下，额外提供了经校准的方差输出，在平稳、缓慢变化和突变非平稳测试数据上均保持了良好的泛化能力和不确定性量化水平。

【关键词】时钟抖动；长短期记忆网络；概率预测；工程先验注入；对数校准损失

【基金项目】国家自然科学基金青年项目（62301282）

【收稿日期】2026 年 5 月 15 日

【出刊日期】2026 年 6 月 20 日

【DOI】10.12208/j.jeea.20260012

An LSTM-based probabilistic prediction model for clock jitter

Ming Cheng

School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications,
Nanjing, Jiangsu

【Abstract】 Driven by the real-time clock jitter estimation demands in power-electronics-dominated power systems, we use the long short-term memory (LSTM) network to develop a probabilistic prediction model that provides conditional jitter estimates and their associated uncertainty simultaneously. The model uses a dual-head architecture, where a mean head predicts the conditional jitter estimate and a variance head quantifies the prediction uncertainty. We introduce a logarithmic calibration term into the loss function and adopt a three-stage training strategy: pre-training with mean squared error, jointly optimizing with a weakly calibrated loss, and fine-tuning of the variance head separately. We further inject the white noise variance into the variance head as a non-trainable engineering prior. On simulated datasets, the model achieves a mean squared error of $7.12 \times 10^{-8} \text{ s}^2$, a normalized residual standard deviation of 1.105, and a stable median variance around $4.87 \times 10^{-8} \text{ s}^2$ across signal frequencies of 1~9 Hz. Comparisons with standard LSTM and a Kalman filter show that the proposed model can maintain point prediction accuracy close to that of the standard LSTM and deliver well-calibrated variance outputs. It shows strong generalization and reliable uncertainty quantification on stationary, slowly varying, and abruptly changing non-stationary test data.

【Keywords】 Clock jitter; Long short-term memory network; Probabilistic prediction; Engineering prior injection; Logarithmic calibration loss

引言

采样时钟的时序稳定性直接影响模数转换的质量，高精度时钟是现代电子信息系统性能保障^[1,2]。时钟源相位噪声、电源纹波、温度漂移及器件老化等物理因素，会使实际采样时刻偏离理想等间隔位置，产生时钟抖

动^[3]。该抖动带来的采样时刻偏差，将导致信号波形失真、相位测量误差以及系统间同步精度下降，严重时直接影响通信误码率、定位精度及雷达目标识别能力。信号频率和带宽的不断提升，使采样时钟抖动成为制约系统动态范围和信噪比的关键瓶颈，其影响波及通信、

导航、探测及精密测量等关键领域^[4,5]。

电力电子化电力系统^[6,7]的快动态特性使数字控制器的采样与触发时序精度成为制约系统性能的关键因素之一。高精度采样同步是柔性直流输电换流阀实现子模块均压与谐波抑制的基础，纳秒级的时钟抖动即可导致开关时刻偏移，引发桥臂电压不平衡；在非理想弱电网及谐波畸变条件下，新能源并网逆变器依赖精准时序以保障锁相精度与并网稳定性，时钟抖动将加剧相位估计误差；高频电力电子设备的数字控制延时补偿受限于采样与执行时刻的确定性，时钟抖动将削弱模型预测控制算法的动态品质。电力电子化电力系统中的时钟抖动预测需在纳秒至微秒的尺度上，实时输出可靠且校准良好的时钟抖动信息，以支撑控制器的精准时序决策。

目前，时钟抖动估计与补偿方法可分为基于反馈跟踪的传统方法和基于数据驱动的智能方法两大类。在传统方法中，锁相环（PLL）通过鉴相器、环路滤波器和压控振荡器构成的闭环系统，实时跟踪输入时钟的相位变化，抑制高频抖动^[8]。然而，PLL 对低频漂移的抑制能力有限，且其带宽选择存在跟踪速度与噪声抑制的固有矛盾。在高精度同步相量测量等场景中，卡尔曼滤波及其非线性扩展（EKF、UKF）利用信号模型约束下递推估计时钟状态^[9,10]。这类方法一般先建立时钟动力学模型（如随机游走或 AR 过程），再结合正弦波采样观测进行在线估计，但其性能严重依赖预设的动力学模型和固定过程噪声协方差。真实时钟环境往往非平稳，漂移的强度和特性随时间变化，传统补偿方法难以自适应这种动态、非线性的抖动演变。

近年来，神经网络和深度学习技术推动的数据驱动时序建模在诸多领域展现出优于传统统计模型的潜力^[11]。长短期记忆网络（LSTM）使用门控机制缓解了 RNN 的梯度消失，能捕获长跨度时间序列中的关键特征。研究表明，其在捕捉时钟抖动的慢变、长相关特性方面优于传统统计模型，并已成功应用于海浪预报^[12]、医疗检测^[13]等任务。已有研究将 LSTM 引入时钟同步处理领域^[14-16]。文献[14]结合 EKF 与 LSTM，由 LSTM 学习时钟动态并输出自适应状态转移先验，从而提升了授时/守时精度。文献[15]提出了一种基于 LSTM 的多卫星导航系统卫星钟差预报方法，用岭回归中位数绝对偏差法探测粗差，再结合自回归实现长时间预报，预报和定位精度显著提升。文献[16]为 5G 时间敏感网络设计了 LSTM 时钟误差预测机制，既能精准刻画同步误差整体变化趋势，又能有效识别和捕捉同步异常

时刻。然而，现有 LSTM 时钟预测大多只输出确定性点估计，缺少对预测不确定性的量化。实际应用中，不确定性信息对自适应滤波和系统健康监测至关重要。概率预测通过输出预测分布来量化不确定性，为下游决策提供更丰富的信息。深度学习的概率预测研究取得了显著进展^[17]。但目前的时钟抖动估计预测方法，要么缺少不确定性输出，要么输出方差未经严格校准，难以直接满足工程中可靠性评估的需求。

针对上述挑战，本文研究如何在无需高精度、高成本硬件时钟条件下，实时获取经严格校准的时钟抖动概率分布，以供控制器动态调节增益或切换控制策略。具体而言，构建 LSTM 双头概率预测模型，均值头输出下一时刻抖动的条件期望作为前馈估计，方差头给出预测方差衡量置信度。在模型训练过程中，引入对数校准损失和递进训练策略，在保证点估计精度的前提下实现方差可靠校准。

1 系统模型与问题建模

时钟源相位噪声、电源纹波、温度漂移及器件老化等因素，使实际采样时刻偏离理想等间隔位置，表现为随机偏移。

1.1 时钟抖动信号模型

待采样理想信号为正弦信号 $s(t) = A \sin(2\pi ft + \varphi)$ ，幅度、频率和初始相位分别为 A 、 f 和 φ 。设理想采样周期为 T_s ，第 k 理想采样时刻为 kT_s ，实际采样时刻为 $kT_s + \tau_k$ ，其中， τ_k 为时钟抖动。相应地，观测信号为：

$$y_k = A \sin(2\pi f(kT_s + \tau_k) + \varphi) + v_k \quad (1.1)$$

其中， $v_k \sim \mathcal{N}(0, \sigma_v^2)$ 为测量噪声。

时钟抖动一般包含缓慢演变的低频漂移和不可预测的宽带白噪声，故本文采用混合模型，将时钟抖动 τ_k 表示为：

$$\tau_k = \tau_k^d + \tau_k^w \quad (1.2)$$

其中， $\tau_k^w \sim \mathcal{N}(0, \sigma_w^2)$ 为均值为 0、功率为 σ_w^2 的白噪声； τ_k^d 为低频漂移。低频漂移 τ_k^d 用二阶自回归（AR（2））描述：

$$\tau_{k+1}^d = 2r \cos(2\pi f_0 T_s) \tau_k^d - r^2 \tau_k^d + w_k \quad (1.3)$$

其中， r 为极点半径，用以控制相关时间长度； f_0 为 AR（2）过程的特征频率，使功率谱密度在近直流处形成一个极低频的峰值，以保证与真实的时钟低频相位噪声特性一致； $w_k \sim \mathcal{N}(0, \sigma_d^2)$ 为强度为 σ_w 的驱动噪声。

1.2 抖动估计概率模型

抖动观测序列 $\{z_k\}$ 可通过采样时钟偏移的直接测量, 或利用前置滤波器对采样信号进行后验估计得到。无论来源如何, 观测值都是真实抖动 τ_k 与观测噪声 $e_k \sim \mathcal{N}(0, \sigma_e^2)$ 的叠加:

$$z_k = \tau_k + e_k \quad (1.4)$$

需指出的是, 真实抖动序列在实际系统中通常无法直接获得, 仅在离线标定或半实物仿真环境中可通过高精度参考时钟或高分辨率时间数字转换器获取。仅在模型训练阶段使用真实抖动序列作为监督标签, 在线推理阶段仅需输入可实时获取的含噪观测序列, 无需真实抖动标签。

实际采样系统需实时补偿时钟抖动。取观测窗口长度为 w , 并记在 k 时刻观测向量为 $\mathbf{z}_k = [z_{k-L}, z_{k-L+1}, \dots, z_{k-1}]^T$ 。根据 $\mathbf{z}_k$ 给出下一时刻的真实抖动 τ_{k+1} 的最优估计及其可信度。因此, 建立如下条件概率模型:

$$\mathbb{P}(\tau_k | \mathbf{z}_k) = \mathcal{N}(\mu_k, \sigma_k^2) \quad (1.5)$$

其中, 条件均值 μ_k 表示基于历史观测对 k 时刻抖动的

最优一步预测; 条件方差 σ_k^2 则量化该预测的不确定性。

定义标准化残差为:

$$\Delta_k = \frac{\tau_k - \mu_k}{\sigma_k} \quad (1.6)$$

其均值体现了抖动预测准确性, 当 $\bar{\Delta} = \frac{1}{N} \sum_{k=1}^N \Delta_k \approx 0$ 时, μ_k 的预测无偏; 其标准差则衡量方差的可信度, 当 $\sigma_{\Delta} = \frac{1}{N-1} \sum_{k=1}^N (\Delta_k - \bar{\Delta})^2 \approx 1$ 时, 表明模型对自身不确定性的评估与实际相匹配。若概率模型与真实抖动分布一致时, 则 Δ_k 服从标准正态分布 $\mathcal{N}(0, 1)$ 。

2 LSTM 双头概率估计模型

时钟抖动序列中, 漂移分量与历史值强相关, 表现出明显的时间依赖性。LSTM 因此适合作为概率估计的基础网络。但多数 LSTM 预测模型只能输出确定性点估计, 缺少对不确定性的表征。而在实际抖动补偿中, 不确定性量化往往是关键需求。受此驱动, 我们在 LSTM 末端扩展出双头结构, 同步输出预测均值和方差。

2.1 双头网络结构




图1 LSTM 双头预测模型示意图

如图 1 所示, 模型由输入层、特征提取层和双头输出层三部分组成。

(1) 输入层: 取滑动窗口内的 w 个历史抖动观测值, 构成向量 $\mathbf{z}_k \in \mathbb{R}^w$, 经维度重塑为 $\mathbb{R}^{L \times 1}$ 的张量后, 送入特征提取层。

(2) 特征提取层: 采用两层 LSTM 组成, 每层包含 M 个隐藏单元。层间引入概率为 p 的随机失活以缓解过拟合。序列沿时间轴正向经过两层 LSTM 后, 仅保留最后一个时间步的隐藏状态 $\mathbf{h} \in \mathbb{R}^M$, 作为整个窗口的时序特征编码, 传递给双头输出层。这一设计使网络能够从含有噪声的历史观测中提取对预测有用的漂移动态信息, 同时抑制无关的随机波动。

(3) 双头输出层: 将隐藏状态 $\mathbf{h}$ 分别送入两个独立的全连接头 (均值头和方差头)。均值头输出下一时刻真实抖动的点估计:

$$\mu_k = \mathbf{W}_{\mu} \mathbf{h} + b_{\mu} \quad (2.1)$$

其中, $\mathbf{W}_{\mu}$ 为均值头的权值矩阵, b_{μ} 为均值头偏置。方差头输出预测方差:

$$\sigma_k^2 = \text{softplus}(\mathbf{W}_{\sigma} \mathbf{h} + b_{\sigma}) + \sigma_w^2 + \varepsilon \quad (2.2)$$

其中, $\mathbf{W}_{\sigma}$ 为方差头的权值矩阵, b_{σ} 为方差头偏置, $\text{softplus}(x) = \ln(1 + e^x)$ 为激活函数, σ_w^2 为直接注入网络输出端的硬件白噪声先验, ε 为数值稳定小量。

式 (2.2) 将预测方差拆分为两部分: `softplus` 输出项量化由漂移预测误差带来的认知不确定性, 白噪声基方差则表示由硬件随机扰动决定的偶然不确定性。将白噪声作为不可训练的常值直接注入模型, 使网络无需从零开始学习极小的基方差, 训练更稳定。同时, 方差的输出下限明确对应系统的噪声水平, 增强了模型的工程可解释性。

2.2 损失函数设计

双头网络将预测建模为条件高斯分布 $\mathcal{N}(\mu_k, \sigma_k^2)$, 训练目标为最大化观测数据似然。自然地, 可选用负对数似然 (Negative Log-Likelihood, NLL) 作为损失函数, 使用梯度下降联合优化均值头和方差头。但直接使用 NLL 会带来对高估方差的惩罚不足、对数空间梯度不均等问题。为此, 本节进一步引入对数校准项。

设当前批次包含 N 个训练样本, 第 i 个样本的标签为 τ_i , 模型输出为 μ_i 和 σ_i^2 , 预测残差为 $r_i = \tau_i - \mu_i$ 。在独立同分布假设下, 批次 NLL 损失为:

$$\mathcal{L}_{\text{NLL}} = \frac{1}{N} \sum_{i=1}^N \left[\frac{1}{2} \left(\frac{r_i^2}{\sigma_i^2} + \ln \sigma_i^2 \right) \right] \quad (2.3)$$

其中, 第一项 r_i^2/σ_i^2 为标准化残差的平方, 驱动均值头缩小预测误差, 同时要求方差头输出与误差量级相匹配的 σ_i^2 ; 第二项 $\ln \sigma_i^2$ 为方差的对数惩罚, 防止 σ_i^2 无限膨胀。在零均值高斯残差假设下, 理论最优解为 $\sigma_i^2 = r_i^2$ 。

然而, 大量研究和本文前期实验表明, 当残差分布具有重尾或存在离群点时, NLL 倾向于输出偏大的方差以平摊少数大残差的贡献, 导致方差被系统高估, 概率校准恶化。为抑制 NLL 的高估倾向, 在损失中引入校准项, 以惩罚 σ_i^2 偏离 r_i^2 的程度。在训练过程中, σ_i^2 与 r_i^2 跨越多个数量级, 因此, 本文采用对数校准项 $\lambda(\ln \sigma_i^2 - \ln r_i^2)^2$, 其中 λ 为权重用以保证校准项提供与 NLL 项匹配的有效梯度。

总损失函数为:

$$\mathcal{L}_{\text{calib}} = \frac{1}{N} \sum_{i=1}^N \left[\frac{1}{2} \left(\frac{r_i^2}{\sigma_i^2} + \ln \sigma_i^2 \right) + \lambda (\ln \sigma_i^2 - \ln r_i^2)^2 \right] \quad (2.4)$$

2.3 损失函数解耦

式 (2.4) 中, 对数校准项会通过 r_i^2 将梯度传回均值头。若不加约束, 校准项会迫使方差 σ_i^2 逼近 r_i^2 , 而 r_i^2 的变化又直接影响 μ_i 的更新, 造成均值头与方差头的优化高度耦合, 引起训练震荡并损害点预测精度。

为解耦校准项与均值头, 本文在计算校准项时阻

断 r_i^2 的梯度, 将其视为常数。式 (2.4) 中校准项梯度仅通过 σ_i^2 流动, 不再影响均值头 μ_i 。记截断后残差的平方为 $\tilde{r}_i^2 = \text{detach}(r_i^2)$, 则实际损失函数变为:

$$\mathcal{L}_{\text{eff}} = \frac{1}{N} \sum_{i=1}^N \left[\frac{1}{2} \left(\frac{r_i^2}{\sigma_i^2} + \ln \sigma_i^2 \right) + \lambda (\ln \sigma_i^2 - \ln \tilde{r}_i^2)^2 \right] \quad (2.5)$$

反向传播时, $\partial \tilde{r}_i^2 / \partial \mu_i = 0$ 。最终, 均值头由 NLL 项单独优化, 方差头则由 NLL 项与校准项共同优化。

2.4 三阶段训练策略

直接用式 (2.5) 进行端对端训练并不容易。训练初期残差较大且不稳定, 同时优化均值和方差容易导致两者相互干扰, 甚至引起损失震荡。此外, 方差头偏置初始值若设置不当, 优化会陷入梯度饱和区, 使方差难以有效压低。为实现精准抖动估计与方差校准, 本文设计三阶段递进训练流程。

阶段一: MSE 预训练。此阶段只关心抖动估计精度, 暂不考虑概率输出。具体做法是冻结方差头的全部参数, 用均方误差 (MSE) 损失函数 $\mathcal{L}_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N r_i^2$ 优化 LSTM 特征提取层和均值头。

阶段二: 弱校准联合训练。此阶段在保护抖动估计条件下引入方差。具体做法是加载阶段一的最佳模型, 解冻所有参数, 用式 (2.5) 联合训练 LSTM、均值头和方差头。由于对校准项中的残差平方执行梯度截断, 该部分梯度不传回均值头。将早停条件设置为验证 MSE 以保证抖动估计的精度。

阶段三: 方差头单独校准。此阶段单独校准方差头。具体做法是冻结 LSTM 和均值头, 仅保留方差头可训练。在此阶段, 加载阶段二最优模型, 手动设置方差头偏置 b_σ 使 `softplus` 输出脱离梯度饱和区。由于此时方差远小于残差平方, 损失函数将产生强梯度使方差迅速回归合理水平。训练以验证集标准化残差标准差进入预设区间为终止条件。

图 2 给出了离线训练与在线推理流程。在离线训练阶段, 利用高精度参考时钟和时间数字转换器获得真实抖动序列作为训练标签, 将系统在正常运行时记录的含噪抖动观测序列作为模型输入, 并保存完成训练的模型参数。在线推理阶段中, 仅接收来自系统前端的含噪抖动观测, 实时输出下一时刻抖动的估计均值与方差。

3 实验设计

3.1 数据集

本文通过仿真生成了时钟抖动数据集, 用以验证方法有效性, 并检验方法在理想训练条件下的性能上

限。其中，以模型生成的理想真实抖动序列充当离线标定阶段的标签，模拟实际系统中通过高精度参考时钟获得的真实值标签。数据按照 1.1 节模型生成，并按 7:1.5:1.5 划分训练集、验证集和测试集。数据集关键参数由表 1 列出。

为检验模型在非平稳条件下的泛化能力，生成慢变和突变非平稳抖动序列作为测试数据集。每个数据集均包含 500 条长度为 2000 的序列。

慢变非平稳数据集：模拟时钟源因温度周期性波动或器件缓慢老化导致的参数慢变。AR(2) 过程的极点半径 r 和驱动噪声标准差 σ_d 随时间正弦调制：

$$r(k) = 0.988 + 0.010 \sin(2\pi k/T_m)$$

$$\sigma_d(k) = 1.25 \times 10^{-4} + 7.5 \times 10^{-5} \sin(2\pi k/T_m + \pi/4)$$

调制周期 T_m 与序列长度一致。变化范围为 $r \in [0.978, 0.998]$ 和 $\sigma_d \in [5 \times 10^{-5}, 2 \times 10^{-4}]$ ，在平稳训练集的参数分布范围内。其余参数与平稳数据集一致。

突变非平稳数据集：模拟时钟源因机械冲击或模式切换导致的参数瞬时突变。序列在中点（ $k=1000$ ）处发生参数阶跃。突变前（ $0 \leq k < 1000$ ）， $r = 0.99$ ， $\sigma_d = 1 \times 10^{-4}$ s；突变后（ $1000 \leq k < 2000$ ）， $r = 0.98$ ， $\sigma_d = 2 \times 10^{-4}$ s。突变前后的参数均落在平稳训练集的参数分布范围内，测试模型对动态特性瞬时切换的适应能力。其余参数与平稳数据集一致。

3.2 训练配置

训练时，输入为抖动观测序列 $\{z_k\}$ ，标签为真实抖动序列 $\{\tau_k\}$ 。LSTM 模型网络结构与训练阶段参数设置分别如表 2 和表 3 所示。




图 2 离线训练与在线推理示意图

表 1 数据集参数设置

参数	取值范围	参数	取值范围
序列总数 N	3000	漂移极点半径 r	$\mathcal{U}(0.98, 0.998)$
序列长度 L	2000	AR(2) 特征频率 f_0	2Hz
采样周期 T_s	1ms	漂移驱动噪声标准差 σ_d	$\mathcal{U}(5 \times 10^{-5}, 2 \times 10^{-4})$ s
信号频率 f	$\{1, 3, 5, 7, 10\}$ Hz	白噪声标准差 σ_w	5×10^{-6} s
信号幅度 A	1	观测噪声标准差 σ_v	0.05
初始相位 φ	$\mathcal{U}(0, 2\pi)$		

表 2 LSTM 模型参数设置

参数项	取值
窗口长度 W	50
LSTM 层数	2
隐藏单元数 M	128
随机失活概率 p	0.2
优化器	Adam
梯度裁剪阈值	1.0

表 3 训练阶段超参数设置

参数项	阶段一	阶段二	阶段三
损失函数	MSE	式 (2.5), $\lambda = 0.05$	式 (2.5)
学习率	10^{-3}	10^{-4}	10^{-4}
参数状态	冻结方差头	全部可训练	冻结均值头
偏置 b_σ	-16	-16 (继承)	-20 (手动设定)
早停条件	MSE 最低	MSE 连续 20 轮未降	$r_i \in [0.8, 1.2]$

4 实验结果与分析

4.1 评估指标

抖动估计精度由均方误差 (MSE) 和平均绝对误差 (MAE) 两项指标衡量, 其定义分别为:

$$T_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (\tau_i - \mu_i)^2 \quad (2.6)$$

$$T_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |\tau_i - \mu_i| \quad (2.7)$$

方差校准质量以标准化残差 r_i 的样本标准差 σ_{r_i} 来评价, 该值越接近 1.0, 预测方差与实际误差水平的匹配度越高。

4.2 对比算法

本文选取标准 LSTM 模型和卡尔曼滤波 (KF) 模型作为对比。

标准 LSTM 模型: 在本文双头 LSTM 的模型基础上, 移除方差头及相关组件, 仅保留均值头, 以均方误差 (MSE) 作为损失函数进行训练。此模型只能输出点估计值, 不具备不确定性量化能力。

KF 模型: 基于 1.1 节 AR (2) 漂移模型构建线性高斯状态空间模型, 采用标准 KF 进行一步预测。状态向量为 $\mathbf{x}_k = [\tau_k^d, \tau_{k-1}^d]^T$, 状态转移矩阵由 AR (2) 系数确定, 观测为总抖动序列 $z_k = \tau_k$ 。KF 的过程噪声方差 σ_d^2 和观测噪声方差 σ_w^2 分别对应 AR (2) 驱动噪声和白噪声的功率, 其中 σ_w^2 为已知常量, r 、 f_0 和 σ_d 通过训练集逐序列估计取中位数获得。测试时, 参数固定不变。

4.3 性能及分析

图 3 为典型测试序列的预测抖动与真实抖动的对比, 图 4 给出了对应的预测残差。直观来看, 预测值与真实值几乎重叠, 模型较好地捕捉了抖动的动态演变过程。抖动预测的 $\pm 2\sigma$ 置信区间较窄, 约 86.9% 真实值落在置信区间内, 表明模型对自身预测不确定性的估计较为合理。残差围绕零值平稳波动, 无明显趋势漂移或异方差, 这在一定程度上验证了预测的无偏性和稳定性。




图 3 预测抖动与真实抖动对比




图 4 抖动预测残差




图 5 抖动预测残差分布

图 5 进一步给出了典型序列标准化残差的分布直方图，同时叠加标准正态分布作为参照。直方图呈对称钟形，峰值贴近零值，说明标准化残差的分布与标准正态分布较为吻合。这反映出模型输出的预测方差与实际残差水平匹配良好，概率校准质量较高。

按信号频率对测试集分组，得到各组 MSE、MAE、方差中位数和标准化残差的标准差如表 4 所示。不同频率下抖动估计保持稳定，其中 MSE 在 5.13×10^{-8} 至 $1.06 \times 10^{-7} \text{ s}^2$ 的窄区间内波动，MAE 维持在 1.77×10^{-4} 至 $1.90 \times 10^{-4} \text{ s}$ 之间。全体测试集的 MSE 和 MAE 与各频率分组结果一致，表明 LSTM 所提取的时序特征主要来源于抖动序列自身的动态规律，模型具有良好的频率泛化能力。其次，方差中位数在各频率下稳定在 $4.87 \times 10^{-8} \text{ s}^2$ 附近，几乎相同。各频

率信号中 AR(2) 漂移参数取自同一分布，抖动的统计特性不随信号频率变化，决定了预测误差的相近水平；白噪声基方差作为固定工程先验注入方差头，为方差输出提供了下限基准，而三阶段训练使方差头偏置收敛于相近的稳态值，因此在不同频率下的方差高度一致。最后，方差校准质量在不同频率下均处于接近 $[0.8, 1.2]$ 的理想区间。其中，1 Hz 信号条件下标准差最接近 1.0 (0.9163)，表明低频条件下方差校准最为精准；7 Hz 信号条件下标准差略高于理想上界，反映出高频信号对应的抖动序列可能含有更强的非线性成分。总体来看，不同频率下的测试结果说明，本文模型在各种信号条件下都能给出高精度的抖动估计和校准良好的方差，表现出较强的泛化能力和工况适应性。


表 4 不同信号频率下的模型性能

频率 (Hz)	MSE (s^2)	MAE (s)	σ_i^2 中位数 (s^2)	残差标准差 σ_{r_i}
1	5.134×10^{-8}	1.766×10^{-4}	4.876×10^{-8}	0.9163
3	7.307×10^{-8}	1.877×10^{-4}	4.878×10^{-8}	1.1694
5	6.313×10^{-8}	1.902×10^{-4}	4.870×10^{-8}	1.0511
7	1.057×10^{-7}	1.888×10^{-4}	4.875×10^{-8}	1.2955
9	6.501×10^{-8}	1.861×10^{-4}	4.872×10^{-8}	1.0744
总体	7.124×10^{-8}	1.858×10^{-4}	4.874×10^{-8}	1.1050


图 6 对比了本文所提双头 LSTM 模型与标准 LSTM 模型和 KF 模型对典型平稳、慢变非平稳和突变非平稳抖动的预测误差。标准 LSTM 误差最小，误差曲线围绕零线窄幅波动，无系统性偏差。双头 LSTM 误差略大，但绝大多数真实值落在 $\pm 2\sigma$ 区间内。KF 模型误差波动最大，在缓变和突变条件下尤为明显，且其方差输出严重偏小，标准化残差标准差在 5.5 至 8.2 之间，大量真实值落在置信区间之外。误差波动幅度在慢变序列最大，平稳与突变序列相近，这是由于参数慢变对固定模型和分布外泛化造成的持续性压力。慢变数据中参数随采样步持续偏离训练集的典型值，导致 KF 因固定参数无法跟踪时变动态而出现持续的模型失配，双头 LSTM 的方差头在平稳数据上学习到的不确定性水平也难以完全覆盖这一额外误差。平稳数据各时刻参数不变，突变数据仅在切换点处短暂失配、前后各段仍与训练分布一致，因此两者误差波动均低于缓慢变化情况。

双头 LSTM 模型与标准 LSTM 模型和 KF 模型在平稳、慢变非平稳和突变非平稳数据集测试结果如表 5 所示。两种 LSTM 模型在三类数据集上的


MSE 均保持在 10^{-7} 至 10^{-8} 量级，而 KF 模型的 MSE 高出 1 至 2 个数量级。这是由于 KF 使用从训练集估计的固定参数，与各测试序列的真实参数存在偏差，且无法适应参数的缓变或突变。双头 LSTM 模型训练过程中，方差头对均值头的优化有轻微抑制，导致其 MSE 略高于标准 LSTM 模型，但二者仍处在同一量级。双头 LSTM 模型的残差标准差在平稳数据上为 1.1050，接近理想值 1.0；慢变数据引入了训练集未覆盖的额外不确定性，导致残差标准差升至 1.6122；因突变前后各段仍为平稳动态，模型对各段的预测能力与平稳条件相近，残差标准差恢复至 1.0757。KF 模型的标准化残差标准差在三种数据集上均在 5.5 至 8.2 之间，这是因为其预测协方差仅反映理想模型的噪声传播，未计入参数失配引入的误差，方差被系统性低估。综合来看，标准 LSTM 模型的预测精度最高但不输出方差；KF 模型的预测精度和方差校准质量均不满足工程需求；本文模型的预测精度接近标准 LSTM，并能提供高质量校准的方差，在三类数据上均保持了良好的不确定性量化能力。



(a) 平稳抖动



(b) 慢变非平稳抖动



(c) 突变非平稳抖动

图 6 双头 LSTM 与标准 LSTM 和 KF 在不同抖动场景中误差性能

表 5 三种方法在平稳与非平稳测试集上的性能对比

数据集	模型	MSE (s ²)	MAE (s)	σ_i^2 中位数 (s ²)	残差标准差 σ_{r_i}
平稳	KF	1.986×10^{-6}	5.873×10^{-4}	1.473×10^{-8}	6.4227
	标准 LSTM	3.733×10^{-8}	1.335×10^{-4}	—	—
	双头 LSTM	7.124×10^{-8}	1.858×10^{-4}	4.874×10^{-8}	1.1050
慢变非平稳	KF	1.211×10^{-5}	7.503×10^{-4}	1.479×10^{-8}	8.2017
	标准 LSTM	9.252×10^{-8}	1.541×10^{-4}	—	—
	双头 LSTM	1.600×10^{-7}	2.114×10^{-4}	4.870×10^{-8}	1.6122
突变非平稳	KF	1.081×10^{-6}	5.434×10^{-4}	1.479×10^{-8}	5.5032
	标准 LSTM	3.701×10^{-8}	1.479×10^{-4}	—	—
	双头 LSTM	6.787×10^{-8}	2.031×10^{-4}	4.870×10^{-8}	1.0757

4.4 局限性分析

本文的仿真验证基于 1 kHz 采样率与 1–9 Hz 低频信号，与电力电子化电力系统中常见的 MHz 与 GHz

采样时钟频率存在差距。将本文方法推向高频场景时，主要挑战来自于抖动观测的获取，而非模型本身的预测能力。LSTM 模型训练时的输入和标签均为抖动序

列,其统计特性由时钟源的物理特性决定,与待采样信号的频率无关。无论在低频还是高频,模型的核心任务都是基于历史抖动预测下一时刻抖动,因此,在低频数据上训练得到的模型基本预测能力理论上具备向高频场景迁移的基础。然而,模型的在线推理依赖输入的抖动观测序列。高频信号的高斜率放大了相同抖动量对应的采样电压误差,而短周期则使观测值与抖动之间出现相位卷绕,二者共同增加了从采样值反推抖动的难度。因此,将模型推广到高频的关键在于获得足够质量的抖动观测序列。

后续工作将围绕高频推广与硬件实现展开。针对高频场景中存在的观测序列退化,检验模型在非理想输入下的预测稳定性,评估将模型向高频推广的可行性和复杂性。同时,搭建基于 FPGA 的硬件验证平台,通过时间数字转换器采集实际抖动序列,在实测数据上检验模型的预测精度与方差校准水平。

5 结语

针对电力电子化电力系统中时钟抖动实时估计的工程需求,构建了 LSTM 双头概率预测模型。模型以均值头输出下一时刻抖动的条件期望作为前馈估计,以方差头输出经校准的预测方差衡量置信度,为控制器的精准时序决策提供概率依据。将白噪声方差作为工程先验注入方差头,分离了噪声固有的不确定性与模型认知的不确定性。引入对数校准损失解决 NLL 损失系统性高估方差的问题,并采用三阶段递进训练,兼顾了点估计精度与方差校准质量。在平稳、慢变非平稳和突变非平稳测试数据上,将本文双头 LSTM 模型与标准 LSTM 模型和卡尔曼滤波进行了对比。本文模型在预测精度接近标准 LSTM 的条件下,额外提供了经校准的方差输出,三类测试数据上的标准化残差标准差均在较低水平,表现出良好的泛化能力和不确定性量化水平。现有仿真验证基于 1 kHz 采样率与 1-9 Hz 低频信号,后续将预测模型推广到高频信号并在硬件平台实现。

参考文献

- [1] 陈羽,韩腾飞,杨朋 等.通用航空集群的高精度时钟同步算法[J].数据采集与处理,2026,41(01): 89-108.
- [2] 李林伟,吴侃侃,周军 等.星载超宽带无线网络高精度时间同步技术[J].电讯技术,2026,66(03): 430-436.
- [3] IEEE Standard for Jitter and Phase Noise [S]. IEEE Std 2414-2020, 2021: 1-42.
- [4] 朱家顺,周强,徐占洋 等.时钟抖动对射频脉宽调制性能的影响分析[J].太赫兹科学与电子信息学报,2023,21(03): 340-348.
- [5] 胡梅,李晓宇,陈建云.采样噪声对北斗全球信号测距误差的影响分析[J].仪器仪表学报,2019,40(09): 180-188.
- [6] 王海鑫,刘泽霖,郑飞 等.电力电子化电力系统低频振荡:构网型变流器与电网设备交互机理及源-网-荷-储协同抑制综述[J/OL].电力自动化设备,1-15 [2026-06-05].
- [7] 胡家兵,李英彪,郭剑波.电力电子化电力系统跨时间尺度相互作用问题[J].中国科学:技术科学,2026,56(1): 227-244.
- [8] 林欣,王永纲.基于注入锁定的高精度锁相环芯片设计[J].核电子学与探测技术,2026.46(01): 20-26.
- [9] 王恒,王红,刘晓江.基于交替极小化卡尔曼滤波的 PTP 时钟同步参数跟踪方法[J/OL].重庆邮电大学学报(自然科学版),1-10[2026-05-16].
- [10] 许万,余磊涛,夏瑞东.基于无迹卡尔曼滤波的精密时钟同步算法[J].湖北工业大学学报,2024,39(01): 8-11+27.
- [11] 朱文忠,罗鹏阳.深度学习在时序预测中的应用研究综述[J].四川轻化工大学学报(自然科学版),2026,39(02): 69-83.
- [12] 尚凡成,李传庆,詹可 等.改进 LSTM 神经网络在极短期波浪时序预报中的应用[J].上海交通大学学报,2023,57(06): 659-665.
- [13] 卢官明,蔡亚宁,卢峻禾 等.基于 Bi-LSTM 和时序注意力的异常心音检测[J].南京邮电大学学报(自然科学版),2025,45(01): 12-20.
- [14] 徐涛,郭宸宇,赵程.结合 EKF 与 LSTM 神经网络的授时/守时算法[J].全球定位系统,2024,49(05): 126-132.
- [15] 蒋卓豪,葛海波,吴天昊 等.LSTM 模型在 GNSS 卫星钟差预报中的应用[J].导航定位学报,2026,14(02): 10-20.
- [16] 刘青俊,王然,黄震宁 等.基于 LSTM 的 5G-TSN 时钟同步误差预测[J].网络与信息安全学报,2026,12(01): 40-53.
- [17] Abdar, M., Pourpanah, F., Hussain, S., et al. A review of uncertainty quantification in deep learning: Techniques, applications and challenges [J]. Information Fusion, 2021, 76.

版权声明: ©2026 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS