利用在线学习实现低开销空中同步

Dieter Verbruggen、Hazem Sallouha 和 Sofie Pollin电气工程系
（*ESAT*）-*WaveCoRE*鲁汶大学，3000 鲁汶，比利时 电子邮箱：{
dieter.verbruggen, hazem.sallouha,sofie.pollin}@kuleuven.be

arXiv:2303.01084v1 [eess.SP] 2 Mar 2023

摘要—**精准的网络同步是分布式网络和无小区网络中实现相干传输、协作解码和定位等服务的关键。与集中式网络通常只需在用户与基站之间进行同步不同，分布式网络需要在多个协作设备之间维持同步。由于硬件缺陷以及温度等环境因素会影响时钟，这项任务本身就极具挑战性。因此，分布式网络必须频繁进行同步，造成了显著的同步开销。本文提出一种基于在线 LSTM 的模型，用于补偿时钟偏斜和漂移，从而延长同步信号所需的发送间隔，降低同步开销。我们进行了全面的实验，以评估所提模型的性能。基于测量的结果表明，所提模型将设备间重新同步的需求降低了一个数量级，同时以 90% 的概率将设备同步精度维持在至少 10 微秒。**

索引词—**同步、分布式网络、漂移补偿、长短期记忆网络、在线学习**

I. 引言

无线网络的最新进展显现出一个明确趋势：从传统的集中式星形架构转向分布式替代方案，以应对竞争、干扰和共存等挑战。在大多数最新的处理范式中都能看到这一趋势，例如边缘计算 [1], 和联邦学习 [2] ；在组网范式中也同样如此，例如无蜂窝网络 [3], 和众包网络 [4]。要充分发挥这些范式的潜力，精准的网络同步是实现相干传输[5], 、协作解码 [6], 和定位 [7]等关键服务的重要保障。集中式网络可通过有线基础设施或空中传输（OTA）实现高精度同步，且开销可接受；而分布式网络可能因成本和地理限制[7], 而缺乏有线基础设施，现有的 OTA 同步解决方案也难以扩展至分布式网络，因为与集中式网络相比，同步数量显著更多的设备需要付出过高的开销 [4]–[8]。

网络同步的本质是让一组目标设备使用相同的时钟基准运行。然而，由于时钟电路等硬件并不完美，加上温度等环境因素的影响，设备的本地时钟可能会偏离共同的基准。一种解决方案是在网络中的每台设备上配备额外硬件，例如 GPS 驯服振荡器（GPSDO），为各个设备提供精确的时间源 [9]。然而，基于额外硬件的解决方案通常成本高昂，且功耗较大。现代无线系统中另一种广泛采用的同步方法，例如 3GPP LTE（第三代合作伙伴计划长期演进）的标准化方案，是在目标设备与参考接入点之间周期性交换同步导频 [10]。这些导频信号既可以像 LTE 中那样以定向方式使用，也可以像众包网络中那样在分布式网络中机会性地使用 [6]。这种基于导频的同步方法需要付出导频开销。举例来说，在多个参考接入点协同为多台设备提供服务的分布式网络中，基于导频的同步开销会变得十分庞大，显著降低网络的频谱效率 [8]。事实上，分布式网络中同步导频的所需发送频率，取决于设备晶体振荡器的质量以及应用所能容忍的最大时钟偏移。

无线设备中的数字时钟模型可以表示为时间序列过程，即离散随机过程 [11]。准确的时钟模型是实现时钟漂移预测的关键，它通过依靠时钟模型补偿时钟漂移，有望降低同步开销，同时减少所需同步导频的频率 [6,7]。近期的先进研究通过结合自回归模型与卡尔曼滤波器 [11] ，或利用基于长短期记忆网络（LSTM）的循环神经网络（RNN） [7], 对数字时钟进行建模。尽管自回归时钟模型和 LSTM 时钟模型在预测时钟漂移方面都表现出良好的性能，但这些模型都是以离线方式训练的，因此，为了应对时钟漂移的时变特性以及目标环境的变化，需要频繁地进行重新训练 [12]。在线学习通过利用按顺序获得的训练数据来更新和调整已训练模型，为解决全面模型重新训练的需求提供了极具吸引力的方法 [13]。在线学习技术已应用于分布式无线网络的多个领域，例如推断系统状态和

Hazem Sallouha 的研究工作由弗兰德研究基金会（FWO）资助，博士后奖学金编号为 12ZE222N。

执行自适应资源分配 [13]。在线学习方法的出色性能，以及对具有低导频信号开销和低训练开销的同步方法的迫切需求，推动了本文的研究。

A. 相关工作

文献中已有多项研究提出了应对大规模网络中时钟漂移问题的方法：一种是被动利用参考信号，例如 LTE导频或广播式自动相关监视（ADS-B）信号 [14], ；另一种是主动在网络中传播同步信号[15]。这些最先进的方法主要针对成本和计算能力有限的无线传感器网络。虽然有些研究考虑了基于线性规划和多播的补偿方法 [16],，但大多数研究报告都聚焦于温度辅助方法 [16]–[18]。这是因为工作温度与无线设备所用振荡器频率之间存在很强的相关性。

要获得准确的温度-频率模型，需要持续测量振荡器频率，这对于计算能力有限的设备而言颇具挑战。文献 [17], 中的作者采用静态模型，通过二阶或三阶多项式近似温度-频率模型。二阶和三阶多项式的权重根据先验测量值进行估计。Haapala 等人 [19] 提出了一种基于查找表并对已知温度-频率数据对进行插值的动态模型。然而，上述研究针对的是低端时钟振荡器，与本研究所考虑的高端振荡器相比，前者的温度-频率相关性更为显著。

B. 贡献与论文结构

本文提出并通过实验评估了一种方法，该方法基于机会性获取的信号（如 LTE 信号）以及环境相关特征（如温度测量值）来跟踪设备的本地时钟。所提方法机会性地利用 LTE 信号，并将其与基于在线长短期记忆网络的预测模型相结合，从而实现精准的本地时钟漂移预测。这种精准预测显著减少了设备间重新同步的需求，进而降低了整体网络同步开销。具体而言，基于测量的结果表明，与完全不进行补偿时的 2 分钟相比，所提模型可将设备间重新同步的需求降至 55 分钟一次，从而使设备在 90% 的时间内保持同步精密度为 10 微秒。本文的主要贡献有两点。

- 首先，我们提出了一种采用在线学习的新型基于LSTM 的时钟模型。与现有文献中的方法不同，该模型不需要全面且频繁的重新训练。所提出的模型能够预测并补偿设备的本地时钟，从而最大限度地减少设备之间重新发送同步信号的需求。我们基于这样一个事实：大多数无线收发器使用相同的振荡器作为本地时钟和射频（RF）前端的振荡器，通过测量射频前端的频率偏移，可以准确测量振荡器频率，使我们提出的方法能够根据依次获得的测量值，以在线方式调整模型。
- 其次，我们使用现成的软件定义无线电（SDR）进行了大量测量，收集其本地时钟测量值、接收到的 LTE 导频信号以及温度测量值。我们选用 SDR，是因为它们能够模拟一些有意义的应用场景，例如无蜂窝网络和众包网络，并且可用于许多应用，其中一些应用对时间同步有严格要求。

本文其余部分安排如下：第二节介绍系统模型。第三节介绍我们提出的同步方法。第四节详细说明实验设计与数据采集。随后，我们在第五节给出性能评估结果。最后，第六节对全文进行总结。

II. 系统模型

本文考虑一组由软件定义无线电（SDR）表示、随机分布在给定区域内的静止收发器。目标区域可能兼有室内和室外环境。我们假设这组目标节点位于某个 LTE 基站的通信范围内，从而能够机会性地利用 LTE 信号作为同步参考来测量振荡器频率。我们的目标是使这组收发器保持同步，以满足协同频谱感知和协作解码等应用的精密度要求。网络中的每个节点都配有一个独立的振荡器（TG2016SBN），用于生成本地时间基准，以时钟滴答表示，并为射频前端和基带处理提供时序。文献中讨论时钟的非理想行为时，通常会使用三个不同的术语：

- 时钟偏移 是两个时钟之间的时间差；当该值为零时，两个时钟便完全同步。
- 偏斜 是时钟频率之间的差异。
- 漂移 是指偏斜的微小变化，通常是温度等环境变化所导致的 [20]。

本文始终使用 ppm（百万分率）来概括结果，因为它与频率无关。此外，使用 ppm 还能带来一项额外好处：可快速计算特定时间段后的时钟偏移。例如，ppm 恒定为 0.1 的振荡器运行 1 秒后，时钟偏移将达到 0.1 μ秒。如果该系统要求时钟偏移不超过 6 μ秒，则时钟必须每分钟同步一次。

III. 基于 LSTM 的在线学习方法

本节介绍我们提出的基于长短期记忆网络的时钟模型及其在线训练。鉴于时钟建模问题的特点，即真实参考时钟的

表 I：循环神经网络模型架构。

层索引	Type	详情
1	输入	单元数：5
2	LSTM	隐藏状态：24
		状态激活：$tanh$
		门控激活：$sigmoid$
3	全连接层	单元数：24

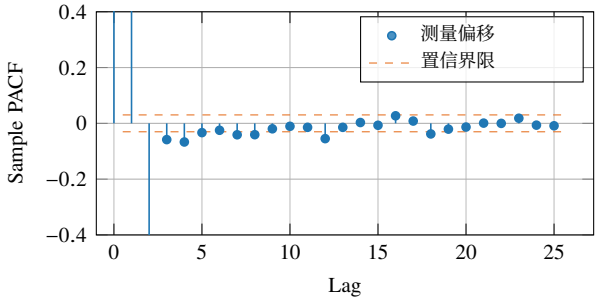

图 1：测得的时钟偏移的样本偏自相关函数及其 95% 置信区间。

时钟是通过导频信号依次测量或获取的，因此我们采用在线学习方法持续更新基于长短期记忆网络的模型。这种在线方法无需使用大量训练数据重新训练底层模型，从而降低了训练开销。我们考虑一个循环神经网络，其中包含一个长短期记忆网络层，后接一个全连接层。使用 Adam优化器 [21]，以 0.001 的学习率训练该网络。表 I 详细列出了网络架构。该长短期记忆网络的目标是估算振荡器的百万分率，并利用温度变化是造成时钟漂移的主要原因之一这一事实 [7]。下文将详细介绍我们所提方法的各项设计参数。

1) 滞后：滞后定义了当前预测所依赖的过去样本数量。我们依据偏自相关函数（PAFC）这一已知指标来选择滞后，该指标能够反映不同滞后的影响。从图 1 可以看出，大于五的滞后没有显著影响，因为其相关性低于 95% 置信区间。因此，所提出的模型选择滞后为五。

2) 输入特征：所提出的方法考虑的输入特征是时间戳和温度。具体而言，时间戳是从午夜开始计数的当日秒数时间。

3) 状态和门激活函数：对于状态和门激活函数，选择长短期记忆网络循环神经网络所使用的默认激活函数，其中 $tanh$ 用于状态激活，$sigmoid$ 用于门激活。

4) 初始轮数（$N_{initial}$）和隐藏状态：初始轮数和隐藏状态的数量通过蒙特卡罗模拟获得，并据此选取了表现最佳的参数。初始轮数决定模型使用数据进行训练的频率。经过经验选择，初始轮数和隐藏状态大小分别设为 25 和 24，因为这两个值在学习底层模型与学习测量值噪声之间实现了最佳折中

学习底层模型并学习测量值中的噪声。

5) 在线测量之间的时间间隔 (Δt_{online})：我们将时间 Δt_{online} 定义为使用新的训练数据更新长短期记忆网络模型的周期。例如，$\Delta t_{\text{online}} = 20$ 分钟表示我们每隔 20 分钟使用新的训练数据更新一次长短期记忆网络模型。

6) 在线训练轮数（N_{online}）：在线训练轮数表示模型针对依次到达的数据点进行训练的次数。直观而言，在线训练轮数取决于所选的 Δt_{online}。较低的Δt_{online} 需要较少的训练轮数，因为循环神经网络会更频繁地重新训练，且每次训练的时间更短。

考虑到所提出的基于长短期记忆网络的在线学习方法的设计参数，下一节将设计一项实验，利用真实测量值评估所提出方法的性能。

IV. 实验设计与数据采集

本节介绍实验设置和数据采集过程，重点关注节点级别，旨在补偿硬件缺陷所导致的任何漂移和偏斜。

A. 实验设置

图 2 所示的实验设置由两台共用振荡器和参考时钟的 Pluto-SDR，以及一个单音信号发生器组成。

- Analog Devices 生产的 Pluto-SDR1 是一种低成本软件定义无线电，常用于学术研究和教育用途。Pluto-SDR 在无线通信领域广泛应用于各种场景，并配备先进的射频前端，因此是我们实验的理想候选设备。然而，这款现成软件定义无线电采用了质量为 25 百万分率的低端振荡器，不适用于对时间敏感的应用和同步需求。通过连接外部振荡器，可以绕过该低端振荡器，按需轻松将其替换为高端振荡器。

- 本实验常用的外部振荡器是 Leo Bodnar 设计的 Mini Precision GPS Reference Clock[2]。该时钟几乎可设置为 400Hz 至 810MHz 之间的所有频率；受硬件限制，某些频率无法实现。连接 GPS 天线后，该振荡器可由全球定位系统驯服，精度接近 1e−6 百万分率。不连接 GPS 天线时，振荡器的稳定性由高端内部振荡器（TG2016SBN）决定，因此容易受到环境影响，在 -30 至 85 °C 范围内的百万分率为 0.5。
- 单音信号发生器是另一台配备 GPS 驯服振荡器的 Pluto-SDR。该 Pluto-SDR 会在载波频率上发射指定频率的单一正弦波。由于振荡器稳定，生成的信号和载波频率都准确且稳定。

[1]https://wiki.analog.com/university/tools/pluto [2] http://www.leobodnar.com

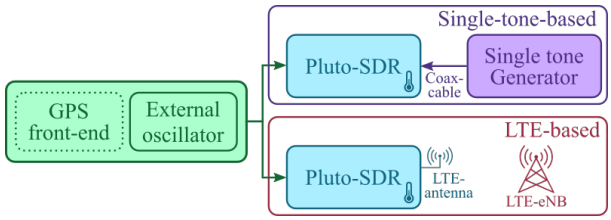

图 2：数据采集的实验设置（使用/不使用 GPS 前端）。

如图 2 所示，两个 Pluto-SDR 共用同一个外部振荡器，并使用不同方法测量该外部振荡器的百万分率；第一个以单音为参考，第二个以 LTE 主同步信号（PSS）为参考。这两种方法都利用 Pluto-SDR 的射频前端来测量振荡器的百万分率。振荡器频率 f_{xo} 与其标称频率 $f_{xo,\ nom}$ 之间的偏差会导致采样频率 f_s 与其标称频率 $f_{s,\ nom}$之间产生偏差。频率与相应百万分率之间的关系可描述为

$$\text{pmm} = \frac{f_x - f_{x,nom}}{f_{x,nom}} 10^6, \quad \forall x \in \{xo, s, sine\}, \qquad (1)$$

其中，下标 xo、s 和 $sine$ 分别用于指代振荡器、采样和正弦波。下面我们将详细介绍作为测量参考的单音和 LTE。

1) 作为基准的基于单音的方法：单音发生器通过同轴电缆，在载波频率为 2.4GHz 的情况下，以 $f_{sine,\ nom}$ 160kHz 的频率发射单一正弦波。当接收器的采样频率 f_s 偏离标称采样率 $f_{s,\ nom}$ 5Msps 时，接收到的正弦波频率 f_{sine} 也会发生偏移。因此，可以使用公式（1）计算 ppm，其中下标 x 为 $sine$。值得注意的是，这种通常用于软件定义无线电校准的单音方法，仅作为我们采用 LTE 信号的基于 LSTM 的方法的基准参考。

2) 基于 *LTE*：我们基于 LTE 的方法依赖于统计频分双工（FDD）LTE基站每隔$5ms$ 传输的 PSS 之间的采样点数量[22]。该方法采集包含约 200 个 PSS 的一秒采样值。通过时间相关、上采样和峰值检测来检测 PSS 信号。通过计算峰值之间的平均采样点数，可以计算出有效采样频率 f_s，进而根据（1）计算出 f_{xo} 和百万分率。该基于 LTE 的方法为大规模部署网络（如众包网络）中的同步问题提供了一种有前景的解决方案 [4]。

B. 数据采集和模型训练

1) 数据采集：为了收集用于所提出方法性能评估的数据集，我们使用了图 2 所示的设置，并断开 GPS 前端，表示系统模型中没有 GPS 驯服振荡器的节点。该实验在室外进行，以捕获

表 II：百万分率测量值的详细信息。

	基于单音	基于 LTE
准确度	0。395e−3	0。812e−3
精密度	0.396e−3	16.602e−3

与室内缓慢变化的温度相比更广泛的温度范围。采集的数据包括：1) 时间戳（当天的秒数）；2) 温度（由 Pluto-SDR 板载温度传感器采集的测量值）；3) 基于 LTE 的 ppm 测量值；以及 4) 基于单音的 ppm 测量值（基准）。数据被连续采集，并以每一分钟为窗口进行平均，以提高测量值的精密度并降低噪声（参见 V-A）。总计在 70 小时内采集了 4,200 个数据点。

2) 训练与预测：为了训练和评估我们提出的在线长短期记忆网络方法，我们使用了对应于第一天所进行测量的 1440 个数据点，作为所提出的长短期记忆网络模型的初始训练数据。随后，将剩余数据分为两组，用于我们的在线学习方法。第一组用于测试我们使用温度和时间戳作为输入特征的在线预测，第二组则依次用于我们提出的长短期记忆网络在线学习，即在新的标注数据到达时更新和调整模型。

V. 性能评估结果

本节评估基于单音和基于 LTE 的百万分率测量的准确度，并评估所提出方法的性能。

A. 百万分率测量精度

为评估基于单音和基于 LTE 的百万分率测量的准确度，采用图 2 所示的实验设置。我们连接了全球定位系统前端，从而提高了外部振荡器的稳定性。外部振荡器被编程为以 0.025 百万分率的步长，从 −0.5 百万分率扫描至 0.5 百万分率，以模拟具有固定偏斜的振荡器。我们使用基于单音和基于 LTE 的方法测量振荡器的百万分率，并将测量值与相应的设定百万分率进行比较。所得测量值经过离群值筛除；根据经验比较结果，扫描中的一些步骤被省略，因为外部振荡器无法准确地产生相应的百万分率。总计收集了约 21,400 个基于单音的测量值和 2,840 个基于 LTE 的测量值。

表 II 展示了 ppm 测量的详细信息。表 II 中的准确度表示测量值的偏差，定义为测量值与对应编程 ppm 之间差值的平均值。两种方法的测量值都存在偏差。不过，两种情况下的偏差都相对较小，例如，1e−3 的偏差会导致时钟每秒偏移 1 纳秒，或每小时偏移 3.6 微秒。表 II 中所示测量值的精密度，定义为测量值与对应编程 ppm 之间差值的标准差。基于单音的方法的测量值

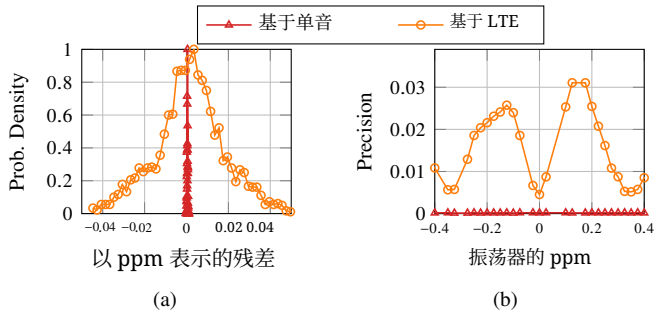

图 3：（a）残差分布。（b）LTE 和单音方法的每 ppm 精度。

每分钟引入的误差小于 $25ns$ ，精密度很高。这证实了基于单音的测量值可用作我们模型的基准。基于 LTE 的方法不如基于单音的方法精密，因为它每分钟会引入 1 微秒的误差。通过对多次测量值取平均，可以进一步提高精密度。平均会带来测量准确度与测量时间之间的权衡。在我们的数据采集中，选择了对一分钟内的测量值取平均。

图 3a 和图 3b 分别展示了步长为 0.025 百万分率的扫描所得残差和精度。残差定义为设定值与测量值之间的差值。与几乎基于 LTE 的方法相比，基于单音的方法的精度相对稳定。基于 LTE 的方法在 0、-0.35 和 0.35 百万分率附近的精度有所提高，因为这些值对应于 PSS 峰值之间的整数个采样点。其他区域精度下降，是由于峰值检测的准确度有限。

B. 所提出的长短期记忆网络模型的评估

在上一小节中，我们定义了基于单音和基于 LTE 的方法的最大测量准确度。本小节将介绍对所提出模型的性能评估。图 4 展示了一个示例，其中包括所提出的长短期记忆网络模型预测的百万分率、基于 LTE 的百万分率测量值，以及相应的基于单音的百万分率测量值。这里，Δt_{online} 设为 20 分钟。用于在线学习的数据点以星号标示。

将所提出的基于 LTE 的长短期记忆网络模型的 ppm 预测结果与三种补偿方法进行比较。第一种补偿方法名为 不进行补偿，不对振荡器的 ppm 进行补偿；该方法预测的 ppm 为零。基于单音的补偿 使用通过基于单音的方法测得的预测 ppm 来补偿振荡器的 ppm；在后续测量之前，该方法预测的 ppm 保持不变。与基于单音的补偿类似，不使用长短期记忆网络补偿的基于 *LTE* 的方法使用恒定的预测 ppm 进行补偿，该 ppm 基于 LTE 测得，且不依赖任何时钟建模。所提出的长短期记忆网络模型的预测 ppm 通过训练获得，随后根据相应的温度和时间戳

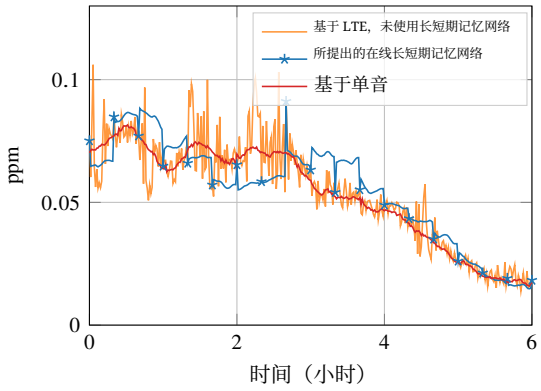

图 4：使用基于单音的方法、基于 LTE 的方法采集的数据样本，以及所提出的在线长短期记忆网络模型的预测结果。星号表示用于在线学习的测量值。

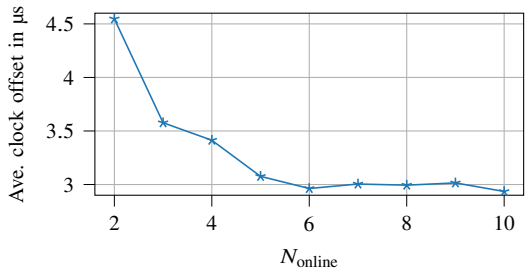

图 5：所提出的在线长短期记忆网络在不同 N_{online} 下， Δt_{online} 为 25 分钟时的平均时钟偏移。

持续进行在线自适应。

使用预测的百万分率对本地时间进行补偿。预测的百万分率与实际百万分率之间的差异越小，时钟偏移就越小。时钟偏移定义为补偿后的本地时间与全局时间（即绝对时间）之间的差值。我们使用时钟偏移作为性能指标，比较不同的补偿方法。将时钟偏移设为零即表示完美同步。我们每隔 Δt_{online} 分钟同步一次本地时钟，将完美同步与振荡器的百万分率测量值相结合；对于所提出的在线长短期记忆网络模型，还会同时更新模型。

一分钟后时钟偏移（以微秒计）的变化量，通过将实际百万分率与预测百万分率之差乘以 60 计算得出。在某一特定时刻的时钟偏移，可以通过将从上一次完美同步开始的所有先前时钟偏移变化量相加来计算，因为完美同步会重置时钟偏移。图 5 展示了所提出的在线长短期记忆网络模型在不同 N_{online} 下、考虑 Δt_{online}为 25 分钟时的平均时钟偏移。根据该图，我们选择将 N_{online} 设为 6，因为进一步增加 N_{online} 并不会为相应的 Δt_{online} 为 25 分钟带来明显的性能提升。图 6 展示了采用不同补偿方法时系统每 25 分钟进行一次同步情况下的时钟偏移累积分布函数（CDF）。较低的时钟

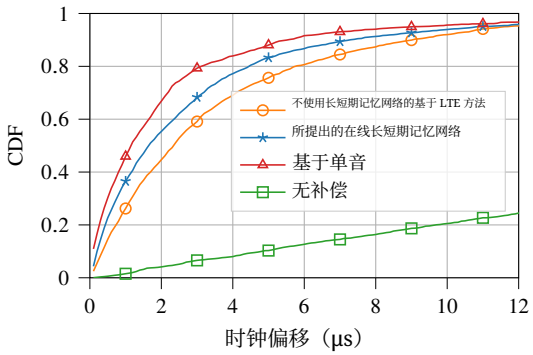

图 6：使用 Δt_{online}，历时 25 分钟，有补偿和无补偿时钟偏移的累积分布函数。

表 III： Δt_{online} 在 90% 的时间内，时钟偏移小于 $10\,\mu$ 秒。

方法	Δt_{online}
无补偿	2 分钟
基于 LTE，不使用长短期记忆网络	26 分钟
基于单音	55 分钟
所提出的在线长短期记忆网络	55 分钟

偏移意味着更好的同步性能。在这四种补偿方法中，不进行补偿的表现最差。对百万分率进行补偿是实现低开销同步的必要条件。图 6 表明，我们提出的在线基于 LSTM 的方法在 N_{online} 等于 6 时，性能优于不使用 LSTM 的基于 LTE 的补偿，缩小了与基于单音的补偿基准之间的差距。

表 III 展示了所考虑的补偿方法所需的 Δt_{online}。可根据网络的同步要求和允许的最大同步开销选择最佳的 Δt_{online}。例如，当系统要求 90% 的时间内时钟偏移不超过 10µsec 时，可以测量表 III 所示不同补偿方法对应的 Δt_{online}。对于所提出的方法，网络仅需每 55 分钟重新同步一次。此外，表 III 表明，与无补偿相比，所提出的方法将同步开销降低了约 95%；与不使用长短期记忆网络的基于 *LTE*补偿相比，降低了 50% 以上。最后，我们在 Raspberry Pi 4 上评估了所提出方法的计算时间。所提出方法在初始训练、预测和在线学习阶段的计算时间分别为 14.9 秒、22.52 毫秒和 242.1 毫秒。

VI. 结论

我们提出了一种在线长短期记忆网络模型，通过利用温度和基于 LTE 的振荡器的百万分率测量值，实现时钟偏斜和漂移补偿，旨在降低分布式无线网络中的空口同步开销。我们使用真实测量值对所提出的模型进行了验证，并将其与不同的补偿方法进行了比较，例如利用基于 LTE 的测量值和基于单音的测量值进行恒定补偿。结果表明，借助基于 LTE 的百万分率测量值，与采用周期性同步信号但不使用在线学习的方法相比，所提出的在线长短期记忆网络方法可将维持 10µsec 同步精度所需的同步开销减少几十分钟。对所提出的方法进行微调，使其更适用于特定应用，是一项有趣的未来工作。

参考文献

[1] Y. Mao、C. You、J. Zhang、K. Huang 和 K. B. Letaief，《移动边缘计算综述：通信视角》，IEEE Communications Surveys & Tutorials，第 19 卷，第 4 期，2017。[2] P. Kairouz、H. B. McMahan、B. Avent 等，《联邦学习的进展与开放问题》，Foundations and Trends® in Machine Learning，第 14 卷，第 1–2 期，第 1–210 页，2021。[3] S. Chen、J. Zhang、J. Zhang、E. Bj¨ornson 和 B. Ai，《以用户为中心的无蜂窝大规模多输入多输出系统综述》，Digital Communications and Networks，2021。[4] S. Rajendran 等，《Electrosense：开放且海量的频谱数据》，IEEE Communications Magazine，第 56 卷，第 1 期，第 210–217 页，2017。[5] ¨O. T. Demir、E. Bj¨ornson、L. Sanguinetti 等，《以用户为中心的无蜂窝大规模多输入多输出系统基础》，Foundations and Trends® in Signal Processing，第 14 卷，第 3–4 期，第 162–472 页，2021。[6] R. Calvo-Palomino 等，《使用非相干接收机进行协作宽带信号解码》，载于 2019 年第 18 届 ACM/IEEE 信息处理传感器网络国际会议（IPSN），第 37–48 页，IEEE，2019。[7] H. Sallouha、A. Chiumento 和 S. Pollin，《利用非相干众包无线网络跟踪航空器》，IEEE Transactions on Vehicular Technology，第 70 卷，第 10 期，第 10780–10791 页，2021。[8] G. Interdonato 等，《无处不在的无蜂窝大规模多输入多输出通信》，EURASIP Journal on Wireless Communications and Networking，第 2019 卷，第 1 期，第 1–13 页，2019。[9] H. Sallouha、A. Chiumento、S. Rajendran 和 S. Pollin，《超窄带物联网网络中的定位：设计指南与权衡》，IEEE Internet of Things Journal，第 6 卷，第 6 期，第 9375–9385 页，2019。[10] U. E. U. conformance specification Radio，《3GPP：第三代合作伙伴计划；无线接入网技术规范组；演进型通用陆地无线接入（E-UTRA）；用户设备（UE）无线电发射与接收一致性规范》，2011。[11] W. Masood、J. F. Schmidt、G. Brandner 和 C. Bettstetter，《Disty：无线传感器网络的动态随机时间同步》，IEEE Transactions on Industrial Informatics，第 13 卷，第 3 期，2016。[12] H. Kim、X. Ma 和 B. R. Hamilton，《利用卡尔曼滤波跟踪具有时变漂移的低精度时钟》，IEEE/ACM Transactions on Networking，第 20 卷，第 1 期，第 257–270 页，2011。[13] S. Hu 等，《无线通信网络中的分布式机器学习：技术、架构与应用》，IEEE Communications Surveys & Tutorials，第 23 卷，第 3 期，2021。[14] S. Zhu 等，《Airsync：利用飞机信号实现大规模物联网网络的时间同步》，载于第 17 届 IEEE 传感、通信与组网国际年会（SECON），2020。[15] C. Lenzen、P. Sommer 和 R. Wattenhofer，《PulseSync：高效且可扩展的时钟同步协议》，Networking, IEEE/ACM Transactions on，第 PP 卷，第 1–1 页，2014 年 1 月。[16] H. Puttnies 等，《利用线性规划、多播和温度补偿实现时钟同步》，载于 2019 年 IEEE 全球通信大会（GLOBECOM），第 1–6 页，2019。[17] Z. Yang、L. He、L. Cai 和 J. Pan，《用于传感器网络的温度辅助时钟同步与自校准》，IEEE Transactions on Wireless Communications，第 13 卷，第 6 期，第 3419–3429 页，2014。[18] F. Gong 和 M. L. Sichitiu，《温度补偿的卡尔曼分布式时钟同步》，Ad Hoc Networks，第 62 卷，2017。[19] T. Haapala、A. Liscidini 和 K. Halonen，《窄带物联网调制解调器中晶体基准的温度补偿》，IEEE Transactions on Circuits and Systems I: Regular Papers，第 PP 卷，第 1–14 页，2020 年 2 月。[20] F. Tirado-Andr´es 和 A. Araujo，《时钟源的性能及其对无线传感器网络时间同步的影响》，International Journal of Distributed Sensor Networks，第 15 卷，2019 年 9 月。[21] D. P. Kingma 和 J. Ba，《Adam：一种随机优化方法》，第 3 届学习表征国际会议，圣迭戈，2015。[22] R. Calvo-Palomino、F. Ricciato、D. Giustiniano 和 V. Lenders，《Ltess-track：面向低成本软件定义无线电平台的精确快速频偏估计》，第 51–58 页，2017 年 10 月。