arXiv:2305.01238v1 [cs.LG] 2 May 2023

动态调度　　面向流式数据联邦边缘学习的动态调度

Chung-Hsuan Hu、*Zheng Chen* 和 *Erik G. Larsson*

电气工程系 （ISY），林雪平大学，¨581 83 林雪平，瑞典　　n

摘要

在本研究中，我们考虑一种联邦边缘学习（FEEL）系统，其中训练数据随时间在一组分布式边缘设备上随机生成，且这些设备受到长期能耗约束。由于通信资源有限且存在时延要求，每次迭代中仅调度部分设备参与本地训练过程。我们将其表述为一个随机网络优化问题，旨在设计动态调度策略，在满足能耗和时延约束的前提下，最大化所调度用户集合的数据重要性时间平均值。我们基于 Lyapunov 优化框架提出的算法优于未考虑数据重要性时变性的其他方法，尤其是在训练数据的生成具有较强时间相关性的情况下。

索引词— 联邦边缘学习、调度、能效、流式训练数据

1. 引言

无线网络中的联邦学习（FL）是一项新兴研究方向，处于无线通信与机器学习的交叉领域。特别是在联邦边缘学习（FEEL）中，大量无线边缘设备参与共同的模型训练任务，无线通信资源（如频率、时间、能耗）受限会显著影响模型聚合的效率和学习性能。设备在训练数据分布、信道条件和计算能力方面存在异构性，这使得最优调度与资源分配设计成为一项艰巨任务。

在联邦边缘学习系统的设备调度与资源分配相关文献中，大多数现有工作关注数据和/或无线信道的异质性，而未考虑计算能力和能量可用性的异质性 [1–7]。在联邦边缘学习系统中，本地流程包含两个阶段：模型训练和更新传输。计算能力较强的设备能够更快地完成模型训练；然而，以 CPU（中央处理器）周期频率衡量的计算能力可能会随时间变化，具体取决于设备同时执行的活动。采用较高的 CPU 工作频率会导致更多能耗，这对电池容量有限的设备至关重要。另一方面，模型传输阶段的能耗受功率控制和传输时间约束的影响。因此，最优的调度设计应考虑信道状况、计算能力和能耗方面的所有系统动态。一些现有研究探讨了能量预算有限的联邦边缘学习系统中的设备调度 [8–10], , 或进一步考虑时延约束 [11, 12], ; 另一些研究则着重于最小化能耗 [13, 14], , 或针对给定的学习性能准确度水平，同时优化能量效率和时间效率 [15, 16], 。此外， [17–19] 采用了其他方法，将学习效率与系统效率结合起来，并从能量和/或时间角度将其作为优化目标。

然而，现有方法都聚焦于静态训练数据场景，这意味着所有本地数据在训练过程开始时都已可用。在实际场景中，训练数据可能会随时间随机生成，从而导致本地损失函数随时间变化 [20–22]。为避免模型训练过拟合，调度设计应考虑新到达数据相对于整个数据收集过程的统计特性。

本研究的主要创新在于，我们考虑了无线边缘设备上生成流式数据的联邦边缘学习系统。我们将其表述为一个随机网络优化问题，并提出一种动态调度算法，综合考虑数据重要性、每轮时延要求和时间平均能耗约束。 [8–11, 18] 中也采用了类似的随机优化方法。目标函数基于重要性感知指标设计，可确保在异构数据分布以及不同设备间数据到达模式各异的情况下，仍具备稳健的学习性能。数值仿真验证了所提出设计的有效性。

2. 系统模型

我们考虑一个有 K 个边缘设备参与全局模型 $\boldsymbol{\theta} \in \mathbb{R}^d$训练的联邦边缘学习系统。我们将设备集表示为 $\mathcal{K} =\{1, ..., K\}$，其中每个设备 $k \in \mathcal{K}$ 都有一个本地训练数据集$\mathcal{S}_k$。系统的目标是最小化经验损失函数

$$F(\boldsymbol{\theta}) = \sum_{k\in\mathcal{K}} \frac{|\mathcal{S}_k|}{|\cup_{j\in\mathcal{K}} \mathcal{S}_j|} F_k(\boldsymbol{\theta}), \tag{1}$$

其中， $F_k(\boldsymbol{\theta})$表示设备 k处的本地损失函数。新的训练样本会随着时间的推移，按照某些随机过程随机到达。在时刻 t，只有 $\mathcal{S}_k(t) = \mathcal{S}_k(t-1) \cup \mathcal{B}_k(t)$可用于本地训练，其中 $\mathcal{B}_k(t)$表示前一时刻之后新到达的数据集， $\mathcal{S}_k(0) = \emptyset$ 且 $\lim_{t\to\infty} \mathcal{S}_k(t) = \mathcal{S}_k$。[1] 因此，我们最小化一个时变损失函数

$$F(\boldsymbol{\theta}, t) = \sum_{k\in\mathcal{K}} \frac{|\mathcal{S}_k(t)|}{|\cup_{j\in\mathcal{K}} \mathcal{S}_j(t)|} F_k(\boldsymbol{\theta}, t), \tag{2}$$

其中， $F_k(\boldsymbol{\theta}, t)$基于 $\mathcal{S}_k(t)$进行评估，$\lim_{t\to\infty} F_k(\boldsymbol{\theta}, t) = F_k(\boldsymbol{\theta})$, 且$\lim_{t\to\infty} F(\boldsymbol{\theta}, t) = F(\boldsymbol{\theta})$。

训练过程由多个通信轮次组成。在第 t 个通信轮次中，使用 $t = 1$, 2, .., 执行以下步骤:

本研究部分由 Zenith、ELLIIT 以及 Knut 和 Alice Wallenberg 基金会（KAW）资助。

[1]我们还可以考虑另一种设定： $S_k(t) = S_k(t-1) \cup B_k(t) \backslash D_k(t)$，其中 $D_k(t)$表示每个时间实例 t 中删除的数据集合。

1. 服务器将当前全局模型 $\boldsymbol{\theta}(t)$ 广播给参与设备集合，该集合记为 $\Pi(t)$。2. 每台设备 $k \in \Pi(t)$ 执行固定次数的小批量随机梯度下降（随机梯度下降），以获得模型更新 $\triangle\boldsymbol{\theta}_k(t)$，并将其传输给服务器。。

3 服务器聚合接收到的信息并更新全局模型

$$\boldsymbol{\theta}(t+1) = \sum_{k\in\Pi(t)} \frac{|\mathcal{S}_k(t)|}{|\cup_{j\in\Pi(t)}\mathcal{S}_j(t)|}\triangle\boldsymbol{\theta}_k(t) + \boldsymbol{\theta}(t). \quad (3)$$

2.1. 能耗模型

第 k 个设备在第 t 个通信轮次中的能耗可写为

$$E_k(t) = E_k^{\text{cmp}}(t) + E_k^{\text{tr}}(t), \quad (4)$$

其中， $E_k^{\text{cmp}}(t)$ 表示计算所消耗的能耗，$E_k^{\text{tr}}(t)$ 表示传输能耗。

2.1.1. 本地计算的能耗

我们采用动态电压与频率调节（DVFS）来调整中央处理器实际使用的计算资源。令 $f_k(t)$ 表示第 k 个设备在第 t 轮中的中央处理器时钟频率。模型更新计算的能耗近似为 [23]

$$E_k^{\text{cmp}}(t) = \lambda c f_k^2(t), \quad (5)$$

其中， λ 是功率系数， c 是计算固定数量小批量随机梯度下降所需的中央处理器周期数。

2.1.2. 更新传输的能耗

为将模型更新传输至服务器，所有参与设备共享整个带宽B 。我们将 $\rho_k(t)$定义为第 k个设备在第 t轮中所分配的带宽份额，其中$\sum_{k\in\Pi(t)}\rho_k(t) = 1$。此外， $P_k(t)$表示发射功率。可达速率为

$$R_k(t) = \rho_k(t)B\log_2\left(1 + \frac{P_k(t)|g_k(t)|^2}{\rho_k(t)BN_0}\right), \quad (6)$$

其中， $g_k(t)$是信道增益，且 $\mathbb{E}[|g_k(t)|^2] = \beta_k$； N_0 是噪声功率谱密度。假设模型更新经过压缩并以 S 比特量化，则所需的传输时间为

$$T_k^{\text{tr}}(t) = \frac{S}{R_k(t)}. \quad (7)$$

因此，传输能耗为

$$E_k^{\text{tr}}(t) = P_k(t)T_k^{\text{tr}}(t). \quad (8)$$

2.2. 时延模型

定义 $T_k^{\text{cmp}}(t)$ 为模型更新计算所需的时间；我们有

$$T_k^{\text{cmp}}(t) = \frac{c}{f_k(t)}. \quad (9)$$

根据（7）和（9），设备 k 在第 t 轮完成传输和计算的延迟为

$$T_k(t) = T_k^{\text{cmp}}(t) + T_k^{\text{tr}}(t).$$

3. 问题表述

在流式数据设置下，我们考虑任意一次迭代 t 时， $\mathcal{S}_k$累积的训练数据t可能随时间呈现高度异质性，尽管其渐近对应形式 $\mathcal{S}_k$ 在不同设备之间是同质的。为了调度对学习性能影响最大的设备，一种自然的选择是优先考虑与现有数据相似度较低、且自上次模型拉取以来新到达数据量较大的设备。因此，我们为每个设备 k 定义一个数据重要性度量指标 $I_k(t)$,

$$I_k(t) = \frac{|\Pi_f(t)|\cdot|\mathcal{B}_k(t)|}{\sum_{j\in\Pi_f(t)}|\mathcal{B}_j(t)|} + \mathbf{1}\{t>1\}\cdot\frac{||\boldsymbol{x}-\boldsymbol{y}_k||_2^2}{||\boldsymbol{x}||_2^2+||\boldsymbol{y}_k||_2^2}. \quad (10)$$

(10) 中的第一项量化了候选设备集 $\Pi_f(t) \subseteq \mathcal{K}^2$ 中新到达数据所占的比例，另一项则通过计算已使用数据 $\boldsymbol{x}$ 与新生成数据 $\boldsymbol{y}_k$ 之间的归一化欧几里得距离，考察两者的特征差异。[3]

为加快联邦学习过程，同时保持能效，我们将随机优化问题表述如下:

$$\underset{\Pi(t)}{\text{maximize}} \quad \limsup_{T\to\infty}\frac{1}{T}\sum_{t=1}^{T}\mathbb{E}\left[\sum_{k\in\Pi(t)} I_k(t)\right], \quad (11a)$$

$$\text{subject to} \quad \limsup_{T\to\infty}\frac{1}{T}\sum_{t=1}^{T}\mathbb{E}\left[E_k(t)\right] \le E_k^{\text{avg}}, \quad (11b)$$

$$T_k(t) \le T_{\text{rd}}, \forall k\in\Pi(t), \quad (11c)$$

$$\Pi(t) \subseteq \mathcal{K}. \quad (11d)$$

此处的期望取决于数据生成、无线链路质量以及计算能力可用性的随机性。对于任意设备 k，约束 (11b) 反映长期能量约束；时延约束 (11c) 确保每一轮全局迭代都能在规定的时间窗口内完成。我们假设参与设备之间均分带宽。在已知 $\mathbb{E}[|g_k(t)|^2] = \beta_k$ 的情况下，我们将发射功率设为 $P_k(t) = P_0/\beta_k$ ，其中 $P_0 > 0$ 为某个常数，以使所有设备的期望信噪比保持相同。

4. 动态用户调度算法

我们采用 Lyapunov 优化框架来求解式（11） [24]中给出的随机网络优化问题。我们为约束（11b）定义一个虚拟队列 $Q_k(t)$，其演化过程为

$$Q_k(t+1) = \max\left[Q_k(t) + s_k(t)E_k(t) - E_k^{\text{avg}}, 0\right], \quad (12)$$

其中 $s_k(t) = \mathbf{1}\{k\in\Pi(t)\}$。随后，式（11）可转化为一个队列稳定性问题[4]

$$\text{minimize} \quad \sum_{k=1}^{K} Q_k(t)s_k(t)E_k(t) - V\sum_{k=1}^{K}s_k(t)I_k(t), \quad (13)$$

满足（11c），（11d）。

[2] $\Pi_f(t)$ 的定义将在第 4 节介绍

[3]设= $L(\mathcal{A})$ = $[l_1,\ldots,l_m]$ 为一个 m 维特征向量，$\bar{L}(\mathcal{A})$ $\boldsymbol{x}$ = $[L\ \mathcal{X}\ -\bar{L}\ \mathcal{X}\ ]/\bar{L}\ \mathcal{X}$ $\boldsymbol{y}_k$ = $[L\ \mathcal{B}_k\ t\ -\bar{L}\ \mathcal{B}_k\ t\ ]/\bar{L}\ \mathcal{B}_k\ t$ $(\sum_{i=1}^{m} l_i)/m$ 为其平均值。然后，我们分别定义 ( ) ( ) ( ) 和 (( )) (( )) (( )), 其中 $\mathcal{X} = \cup_{k\in\mathcal{K}}\mathcal{S}_k\ t_k$ $t_k =$ $\{\tau|\tau \le t-1, k\in($ ˙ $)$ 和 ˆ max ( )$\}$。4 $\Pi\ \tau$

推导过程将在本文的扩展版本中给出

算法 1 学习感知动态资源管理 1：获取 $\mathcal{S}_k(t)$、 β_k、 $f_k(t)$、 $Q_k(t)$、 $\forall k \in \mathcal{K}$、 γ、 T_{rd}、 P_0、 S、 B、 V、 λ、 c、 N_0、 $|\Pi(t)|$、 $\boldsymbol{\theta}(t)$；2：根据 (16) 找到一个可行设备集 $\Pi_f(t)$，并计算 $I_k(t)$ $\forall k \in \Pi_f(t)$。3：通过求解 (17) 确定调度策略 $\Pi^*(t)$。4：将 $\boldsymbol{\theta}(t)$ 广播至 $\Pi^*(t)$。5：对所有设备 $k \in \Pi^*(t)$ 并行执行：6：执行固定步数的小批量随机梯度下降。7：结束循环。8：当设备集 $\Pi^*(t)$ 中的所有设备均完成本地训练时：9：获取 $g_k(t)$ 和 $E_k^{\text{cmp}}(t)$、 $\forall k \in \Pi^*(t)$。¯10：通过第4.2节所述方法获得可行设备子集 $\Pi(t) \subseteq \Pi^*(t)$。11：退出循环。12：结束循环。13：计算 $E_k(t) = \begin{cases} E_k^{\text{cmp}}(t) & k \in \Pi^*(t) \setminus \bar{\Pi}(t) \\ E_k^{\text{cmp}}(t) + E_k^{\text{tr}}(t) & k \in \bar{\Pi}(t) \end{cases}$。14： $Q_k(t+1) \leftarrow Q_k(t) - E_k^{\text{avg}} + \mathbf{1}\{k \in \Pi^*(t)\} \cdot E_k(t)$ ¯。15：对所有设备 $k \in \Pi(t)$ 并行执行¯16：使用 $\rho_k(t) = 1/|\Pi(t)|$ 和 $P_k(t) = P_0/\beta_k$，将 $\triangle\boldsymbol{\theta}_k(t)$ 传输至服务器。17：结束循环¯。18：根据 (3)，使用 $\Pi(t) = \Pi(t)$ 更新 $\boldsymbol{\theta}(t+1)$

其中， $V > 0$ 是一个常数，用于平衡队列稳定性与学习性能优化之间的权衡。我们在算法 1 中总结了所有步骤，并在以下各小节中给出详细说明。

4.1. 调度阶段：确定 $\Pi^*(t)$

由于调度集合中的所有设备都需要满足 (11c)，且在此阶段信道增益 $g_k(t)$ 未知，因此我们定义一个替代速率函数

$$\tilde{R}_k(t) = \frac{\gamma B}{|\Pi(t)|} \log_2 \left(1 + \frac{P_0 |\Pi(t)|}{B N_0}\right) \tag{14}$$

用于计算传输时间。在 (14) 中， $\gamma \leq 1$被引入为一个缩放因子，与为未来传输预留的时间成反比。[5] 然后，我们将 (13) 重新整理为

$$\begin{aligned} \underset{\Pi(t)}{\text{minimize}} \quad & \sum_{k \in \Pi(t)} \Big[Q_k(t) \lambda c f_k^2(t) - V I_k(t) \\ & + \frac{Q_k(t) S |\Pi(t)| P_0}{\gamma B \beta_k \log_2 \left(1 + \frac{|\Pi(t)| P_0}{B N_0}\right)} \Big], \end{aligned} \tag{15}$$

$$\text{subject to} \quad \Pi(t) \subseteq \mathcal{K}, \ \forall k \in \Pi(t), \\ \frac{c}{f_k(t)} + \frac{S|\Pi(t)|}{\gamma B \log_2 \left(1 + \frac{|\Pi(t)| P_0}{B N_0}\right)} \leq T_{\text{rd}}. \tag{16}$$

用 $\Pi_f(t)$ 表示满足 (16) 的可行设备子集。然后，我们得到最优调度策略

$$\Pi^*(t) = \underset{\Pi(t) \subseteq \Pi_f(t)}{\arg\min} \quad (15) \tag{17}$$

[5]采用较小的 γ，可视为在评估时延约束时有策略地低估传输速率，从而为传输预留额外的时间缓冲，以防链路质量在本地训练前后发生变化。

¯4.2. 聚合阶段：确定 $\Pi(t)$

当所有参与设备的本地训练结束后、更新传输开始前，我们需要根据 $g_k(t)$、 $\forall k \in \Pi^*(t)$，验证每个调度设备 k 的剩余时间 $T_{\text{rd}} - T_k^{\text{cmp}}(t)$ 是否足以进行传输。我们定义函数 $\mathcal{G}$： $\Pi \to \Pi^-$ ，该函数根据时延约束 (11c) 返回不可行设备子集 $\Pi^- \subseteq \Pi$ ；

$$\mathcal{G}(\Pi) = \left\{ k \middle| |g_k(t)|^2 < \frac{3 C_1 \beta_k B N_0}{|\Pi| P_0}, k \in \Pi \right\},$$

其中 $C_1 = 2^{S|\Pi|/\left[B(T_{\text{rd}} - T_{\text{cmp}\,k}(t))\right]} - 1$。令 $\bar{\Pi}(t)$ 初始化为 $\Pi^*(t)$。如果 $|\mathcal{G}(\bar{\Pi}(t))| > 0$，则将传输时间最长的设备 j（即 $j = \arg\min_{i \in \mathcal{G}(\bar{\Pi}(t))} |g_i(t)|^2/\beta_i$）从 $\bar{\Pi}(t)$ 中移除。重复此步骤，直到 $\mathcal{G}(\bar{\Pi}(t)) = \emptyset$。

5. 仿真结果

我们对一个包含 $K = 40$ 个设备的联邦边缘学习系统进行仿真，使用 MNIST[25] 作为本地数据来训练一个用于解决手写数字分类问题的 $d = 21840$ 卷积神经网络 $\boldsymbol{\theta}$ 的 d 维模型。系统设置的详细信息如下。

- (训练数据分布) 将 60000 个数据样本均匀分配给各设备，即 $|\mathcal{S}_k| = 60000/K$。对于独立同分布（i.i.d.）情形，样本在不重复的情况下随机分配给所有设备；对于非独立同分布情形，每个设备包含的数字类别多样性较低。

- (数据到达) 数据按数字顺序到达，每台设备随机选取最先到达的数字。到达时间服从均值为 $\mu_k \sim \mathcal{U}(0, T_{\text{tot}})$、截断范围为 $[0, T_{\text{tot}}]$, 的截断正态分布，其中 T_{tot} 表示系统的总执行时间。
- CPU频率 $f_k(t) \sim \mathcal{U}(0.02, 1.52)$ GHz。
- 大尺度衰落因子 $\beta_k \sim \mathcal{U}(-5\text{dB}, 3\text{dB})$。
- 常数参数列于表 1 中。

表 1：系统参数

参数	值	参数	值
有效接收功率 P_0	28 dBm	带宽 B	20 MHz
功率系数 λ	10^{-27}	模型大小 S	$32d$
计算缩放 c	$600 \cdot 32d$	噪声功率 N_0	10^{-13} W
时延上限 T_{rd}	4 秒		
平均能耗 E_k^{avg}， $\forall k$	0.0005 焦耳		

5.1. 学习与能效的改进

我们将所提出设计的性能与一种基线方法进行比较，该方法采用随机设备调度，同时满足每轮的时延要求。在独立同分布（i.i.d.）和非独立同分布（non-i.i.d.）数据设置下，测试准确率的比较结果分别如图 1a 和图 1b 所示。由仿真结果可见，在独立同分布场景下，我们的方法具有更高的测试准确率，这是因为所提出的调度

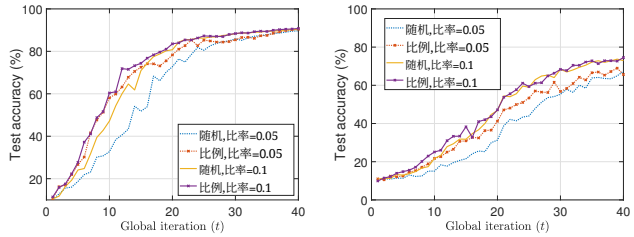

(a) 独立同分布　(b) 非独立同分布

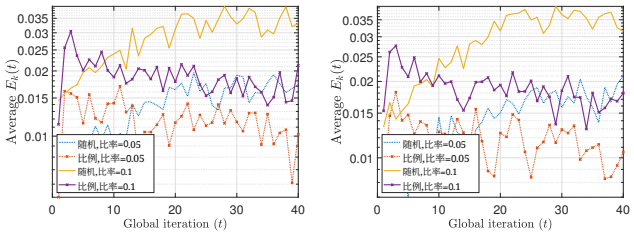

(c) 独立同分布　(d) 非独立同分布

图 1：提出的（'prop'）方法与随机（'rdm'）方法的测试准确率和能耗对比，采用不同的调度比率 $|\Pi(t)|/K$ 和 $V = 0.05$。对于非独立同分布情况，每个设备最多包含 3 个不同的数字。

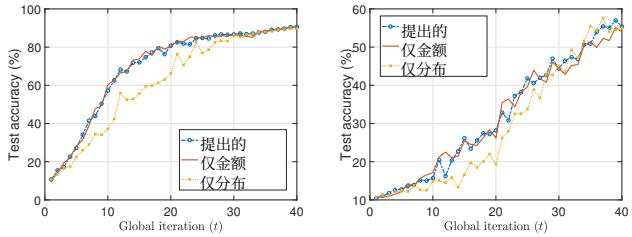

（a）独立同分布　(b) 非独立同分布

图 2：基于不同数据重要性指标的测试准确率。$|\Pi(t)|/K = 0.05$。对于非独立同分布的情况，每台设备最多包含 2 个独特数字。

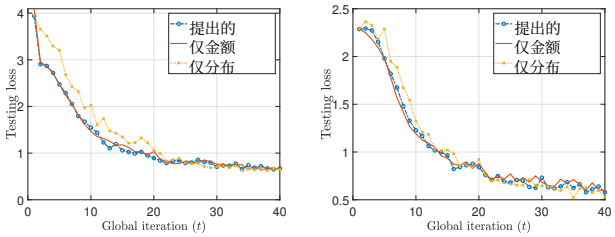

(a) 截断正态分布　(b) 在 $(0,\ T_{\text{tot}})$ 中均匀分布

图 3：基于不同数据重要性指标的测试损失。除 $0.2K$ 的设备仅包含数字 8 和 9 的数据外，大多数设备的数据均为数字 0 到 7 的独立同分布数据。

策略优先调度拥有更多新鲜数据的设备。在非独立同分布场景下，由于调度标准考虑了新数据的多样性，我们的方法同样优于替代方法；这通过降低聚合模型中的偏差，避免了过拟合问题。此外，图 1c 和图 1d 展示了设备平均能耗的比较结果，表明在整个学习过程中，我们的方法消耗更少。具体而言，在调度比率为 $|\Pi(t)|/K = 0.05$ 和 $|\Pi(t)|/K = 0.1$ 的情况下，我们观察到功耗分别降低了 16% 和 35%。

5.2. 数据重要性指标的有效性

为验证提出的数据重要性指标 $I_k(t)$的性能优势，我们将式 (10) 与其他指标进行比较：

- 仅金额指标，即式 (10) 中的第一项。
- 仅分布指标，即式（10）中的第二项。

此处，特征向量 $\boldsymbol{x}$ 和 $\boldsymbol{y}_k$ 是基于所考虑数据的数字标签分布计算得出的。测试准确率的比较如图 2 所示，验证了该设计倾向于选择新到达数据数量较多的设备。[6] 在早期迭代中，测试准确率曲线在仅金额方法和仅分布方法之间呈现出更大的差距；而在后期迭代中，仅分布方法达到与其他方法相近甚至更高的测试准确率。测试准确率差异巨大的原因在于设备生成数据所遵循的时间分布高度不平衡。在图 3 中，我们展示了不同时间分布下的测试损失曲线。测试损失之间的差异

[6]在图 2、图 3 中，缩放因子 V 被选取得足够大，以便更加侧重于优化时间平均目标。

在均匀分布的时间场景下，这两个指标的数值都会变小，因为每次迭代中所有设备新到达的样本数量都相近。此外，在所考虑的非独立同分布场景下，图 3b 更清晰地展示了仅基于分布的方法在后期阶段所获得的性能提升。通过结合这两个指标各自的优势，可以进一步确认，所提出的数据重要性指标是一种有效的度量方式，能够支持最优调度设计。

6. 结论

我们研究了联邦边缘学习系统中的设备调度问题。在该系统中，边缘设备随机生成数据，并受到能耗和时延约束。为应对数据到达和能耗的动态变化，我们采用 Lyapunov 优化设计了一种动态调度算法，在能耗和每轮时延约束下，最大化调度设备集的长期数据重要性。与基准方法相比，提出的方法在降低能耗和提升学习性能方面表现出明显优势。

7. 参考文献

[1] E. Rizk、S. Vlaski 和 A. H. Sayed，《基于重要性采样的联邦学习》，*IEEE* 信号处理汇刊，第 70 卷，页码 5381–5396，2022 年。

[2] M. M. Amiri、D. G¨und¨uz、S. R. Kulkarni 和 H. Vincent Poor，《无线边缘联邦学习中更新感知设备调度的收敛性》，*IEEE* 无线通信汇刊，页码 1–1，2021 年。[3] H. Wu 和 P. Wang，《面向非独立同分布数据联邦学习加速收敛的节点选择》，*IEEE* 网络科学与工程汇刊，第 9 卷，第 5 期，页码 3099–3111，2022 年。[4] C.-H. Hu、Z. Chen 和 E. G. Larsson，《无线网络异步联邦学习的调度与聚合设计》，*IEEE* 通信领域精选期刊，页码 1–1，2023 年。[5] M. Salehi 和 E. Hossain，《不可靠且资源受限的蜂窝无线网络中的联邦学习》，*IEEE* 通信汇刊，第 69 卷，第 8 期，页码 5136–5151，2021 年。[6] F. Malandrino 和 C. F. Chiasserini，《网络边缘的联邦学习：并非所有节点都生而平等》，*IEEE* 通信杂志，第 59 卷，第 7 期，页码 68–73，2021 年。[7] M. Zhang、G. Zhu、S. Wang、J. Jiang、Q. Liao、C. Zhong 和 S. Cui，《通过最优概率设备调度实现高通信效率的联邦边缘学习》，*IEEE* 无线通信汇刊，第 21 卷，2022 年，页码 8536–8551，第 10 期。[8] Y. Sun、S. Zhou 和 D. G¨und¨uz，《含冗余数据的联邦学习能量感知模拟聚合》，载于*2020 IEEE* 国际通信会议（*ICC*），2020 年，页码 1–7。[9] Y. Sun、S. Zhou、Z. Niu 和 D. G¨und¨uz，《能量受限条件下空中联邦边缘学习的动态调度》，*IEEE* 通信领域精选期刊，第 40 卷，第 1 期，页码 227–242，2022 年。[10] J. Xu 和 H. Wang，《无线联邦学习网络中的客户端选择与带宽分配：长期视角》，*IEEE* 无线通信汇刊，第 20 卷，第 2 期，页码 1188–1200，2021 年。[11] K. Guo、Z. Chen、H. H. Yang 和 T. Q. S. Quek，《专用 5G 边缘网络中异构联邦学习的动态调度》，*IEEE* 信号处理专题汇刊，第 16 卷，第 1 期，页码 26–40，2022 年。[12] M. Chen、Z. Yang、W. Saad、C. Yin、H. V. Poor 和 S. Cui，《无线网络联邦学习的联合学习与通信框架》，*IEEE* 无线通信汇刊，第 20 卷，第 1 期，页码 269–283，2021 年。[13] Y. Li、Y. Cui 和 V. Lau，《基于优化的联邦边缘学习 GenQSGD》，载于*2021 IEEE* 全球通信会议（*GLOBECOM*），2021 年，页码 1–6。[14] A. Albaseer、M. Abdallah、A. Al-Fuqaha 和 A. Erbad，《用于提升联邦边缘学习能效的细粒度数据选择》，*IEEE* 网络科学与工程汇刊，第 9 卷，第 5 期，页码 3258–3271，2022 年。[15] B. Luo 、X. Li、S. Wang、J. Huang 和 L. Tassiulas，《移动边缘网络中的高性价比联邦学习》，*IEEE* 通信领域精选期刊，第 39 卷，第 12 期，页码 3606–3621，2021 年。[16] S. Wan、J. Lu、P. Fan、Y. Shao、C. Peng 和 K. B. Letaief，《无线网络联邦学习的收敛性分析与系统设计》，*IEEE* 通信领域精选期刊，第 39 卷，第 12 期，页码 3622–3639，2021 年。

[17] J. Zheng、K. Li、E. Tovar 和 M. Guizani，《移动边缘计算中用于能量均衡客户端选择的联邦学习》，载于*2021*年国际无线通信与移动计算会议（*IWCMC*），2021年，第1942–1947页。[18] Y. Ji、Z. Kou、X. Zhong、H. Li、F. Yang 和 S. Zhang，《联邦学习中的客户端选择与带宽分配：在线优化视角》，载于*2022*年*IEEE*全球通信大会，2022年，第5075–5080页。[19] L. Yu、R. Albelaihi、X. Sun、N. Ansari 和 M. Devetsikiotis，《面向物联网的无线联邦学习中联合优化客户端选择与资源管理》，*IEEE*物联网期刊，第9卷，第6期，第4385–4395页，2022年。[20] Y. Chen、Y. Ning、M. Slawski 和 H. Rangwala，《面向非独立同分布数据边缘设备的异步在线联邦学习》，载于*2020*年*IEEE*国际大数据会议（*Big Data*）。IEEE，2020年，第15–24页。[21] G. Damaskinos、R. Guerraoui、A.-M. Kermarrec、V. Nitu、R. Patra 和 F. Taiani，《Fleet：通过陈旧性感知和性能预测实现在线联邦学习》，载于第*21*届国际中间件会议论文集，2020年，第163–177页。[22] A. Mitra、H. Hassani 和 G. J. Pappas，《在线联邦学习》，载于*2021*年第*60*届*IEEE*决策与控制会议（*CDC*），2021年，第4083–4090页。[23] E. G. Larsson 和 O. Gustafsson，《动态电压与频率调节对多核数字信号处理器算法设计的影响 [探索性数字信号处理],》，*IEEE*信号处理杂志，第28卷，第3期，第127–144页，2011年。[24] M. J. Neely，《随机网络优化及其在通信与排队系统中的应用》，通信网络综合讲义，第3卷，第1期，第1–211页，2010年。[25] Y. LeCun 和 C. Cortes，《MNIST手写数字数据库》，2010年。 [在线]。网址：http://yann.lecun.com/exdb/mnist/