基于机器学习的机器类通信流量模式预测器性能分析

David E. Ru´iz-Guirola，IEEE 学生会员，Onel L. A. L´opez，IEEE 会员，Samuel Montejo-S´anchez，IEEE 高级会员，Richard Demo Souza，IEEE 高级会员，以及 Mehdi Bennis，IEEE 会士

arXiv:2304.02100v1 [eess.SP] 4 Apr 2023

摘要——延长大规模机器类通信（MTC）网络的生命周期，是实现可持续数字化社会的关键。准确预测机器型通信流量并采用适当设计的资源分配机制，可显著节能。然而，选择合适的机器类通信流量预测器并非易事，取决于准确率与复杂度之间的权衡，以及具体的机器类通信应用和网络特性。值得注意的是，相关前沿文献仍缺乏此类讨论。本文评估了多种机器学习（ML）方法在预测泊松流量和准周期性机器类通信流量时的性能，考察其准确率和计算成本。结果表明，时序卷积网络（TCN）的表现优于长短期记忆网络（LSTM）、门控循环单元（GRU）和循环神经网络（RNN），依次递减。对于泊松流量，各预测器之间的准确率差距大于准周期流量下的差距。最后，我们表明，运行 TCN 预测器的成本约为其他方法的三倍，而其训练时间最长、推理时间最短。

索引词—长短期记忆网络、机器学习、机器型通信流量、时间卷积网络。

I. 引言

THE 物联网（IoT）旨在互联万物，推动社会迈向数据驱动社会 [1]。物联网的一项关键使能技术是机器类型通信（MTC），设备无需人工干预即可交换信息 [2]。机器类通信设备（MTD）通过带宽受限网络向更专业的设备传输数据，以供进一步处理，从而支持多种应用，例如智能监控、智慧农业和自动驾驶 [3], 。MTD通常部署在大范围区域，可能使用无法充电或更换的容量有限的电池。为延长网络寿命，并避免为大量MTD频繁更换电池，有必要采用节能技术 [4]。

流量预测有助于实现高效的网络资源调度，并避免密集机器类型通信网络中因空闲监听和信道接入竞争而造成的潜在能源浪费 [4]。然而，警报发出的时刻机器类型设备（MTD）的事件触发信息交换通常尚不明确，需要通过持续观测进行估算，这会耗尽 MTD 的电池电量。了解 MTC流量特征并设计合适的流量预测器，是实现节能型MTC网络的关键。在这方面，机器学习（ML）算法极具吸引力 [5]。通常，基于机器学习的技术能够让系统从数据中学习，从而实时优化整体运行，提高资源利用率并实现节能 [6]。

沿着这一研究方向， [7] 提出了一种有监督机器学习模型，用于预测突发性MTC流量到达，从而避免碰撞和长时延。 [8]–[13]提出了长短期记忆网络（LSTM）机制。具体而言， [8], [9] 中的方法旨在预测突发性MTC流量和拥塞，而 [10], [11]则考虑了事件驱动流量。对于 [11], , 预测结果用于恰当调整唤醒参数，以避免在空闲状态下频繁出现寻呼监测时机，并促进节能。同时， [12] 中的方案旨在有效预测峰值流量，最终降低时延和丢包率；而 [13] 中的作者则通过预测每个时刻哪些设备处于活跃状态并对其优先级进行分类，为海量机器类通信（mMTC）开发快速上行授权。最后， [14] 提出了一种利用设备流量相关性来提高预测效果的神经网络（NN）算法。

尽管近期取得了进展，但针对机器型通信流量的不同机器学习预测器，尤其是在准确率和复杂度方面，仍缺乏充分的性能比较。因此，难以选择合适的机器学习模型，尤其是在要求能效的应用中 [15]。本文迈出了填补这一空白的第一步。为此，我们概述了多种方法，包括循环神经网络（RNN）、门控循环单元（GRU）、长短期记忆网络（LSTM）和时间卷积网络（TCN），用于识别和预测泊松及准周期性机器类通信流量模式。我们从准确率、内存和响应时间等方面分析并讨论了它们的性能权衡。结果表明，基于TCN的预测器准确率最高，尽管其计算成本高于其他模型。此外，我们的方法提供了一个统一的框架，用于评估RNN、GRU、LSTM和TCN在不同流量模型下的性能。

II. 系统模型

我们考虑一个单一的协调器/基站，如图 1 所示，它充当短距离机器类型设备的网关。机器类型设备向协调器发送数据包，协调器负责控制所有

David Ru´ız-Guirola、Onel L´opez 和 Mehdi Bennis 任职于芬兰奥卢大学无线通信中心。 {David.RuizGuirola, Onel.AlcarazLopez, Mehdi.Bennis@oulu.fi} Samuel Montejo-S´anchez 任职于智利圣地亚哥大都会理工大学机构研究、发展与创新促进计划。{smontejo@utem.cl} Richard Souza 任职于巴西圣卡塔琳娜联邦大学，位于圣卡塔琳娜州弗洛里亚诺波利斯。 {richard.demo@ufsc.br}

这项工作部分获得了以下资助：智利 ANID FONDECYT 初创项目 No. 11200659 和 FONDEQUIP-EQM180180；巴西 CNPq（402378/2021-0、305021/2021-4）、CAPES-UFSC“自动化4.0”以及 RNP/MCTIC（资助编号 01245.010604/2020-14）；芬兰 6Genesis旗舰项目（资助编号 318927）和 Tekniikan Edist¨amiss¨a¨ati¨on。

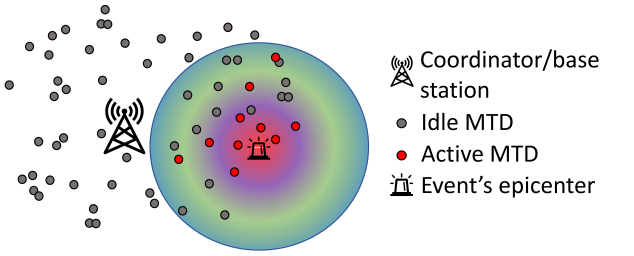


图 1. MTC网络示意图，其中协调器控制并收集来自机器类型设备的信息。事件对周围机器类型设备的影响由一个概率函数建模，该函数取决于事件震中与机器类型设备之间的距离。

其小区内的信息交换。每个机器类型设备可以处于空闲状态（I），等待触发事件；也可以处于活跃状态（A），与协调器交换信息。当检测到事件并触发机器类型设备与协调器之间的信息交换时，设备便从状态 I 转换为状态 A。机器类型设备进入状态 A 后，会在事件持续期间一直保持该状态。假设时间以传输时间间隔（TTI）为单位划分为时隙。在时隙 k 且处于状态 A 时，机器类型设备以速率 R 产生流量。处于状态 I 时，机器类型设备不产生流量。

为对机器类型设备和事件中心的位置进行建模，我们使用泊松点过程（PPP）表示节点和事件，并假设它们以随机方式部署在欧几里得平面 [11]上。机器类型设备按照密度为 λ_M的二维齐次泊松点过程 Φ_M 部署。事件震中由密度为λ_E的二维齐次泊松点过程 Φ_E 表示。假设过程 Φ_M和 Φ_E 相互独立，而协调器位于原点，如图 1 所示。

A. 事件震中的影响

为描述给定事件对感知型机器通信设备的影响，我们定义函数 $p(d_{i,\ j})$，表示位于 i^{th} 震中（$i \in \Phi_E$）的事件触发位置$j \in \Phi_M$处机器类型设备 j 的概率，其中 $d_{i,\ j}$是它们在欧几里得平面 $\Re^2$ [16]上的距离。此外，$p(d_{i,\ j}): [0,\infty) \to [0,1]$是非递增的，以模拟事件影响随距离 $d_{i,\ j}$ 增加而衰减的现象 [11]。图 1 展示了事件震中对周围机器类型设备的影响。

III. MTC流量模型

机器型通信流量通常以上行为主，其特点是传输时长较短，且结合了来自多个来源的实时流量和非实时流量。根据应用场景，MTC有三种基本流量模式 [17]: (i) 周期性更新（PU），设备会定期发送状态报告，例如智能电表读数（燃气、电力、水）；(ii) 事件驱动（ED），描述由特定随机触发在未知时间引起的非周期性流量，例如警报；(iii) 有效载荷交换（PE），由突发流量构成，通常发生在PU或ED流量之后。

机器型通信流量通常是上述类型的组合 [11]。例如，MTD 可能进入省电模式并按固定间隔触发 PU 模式，而警报或关键事件则可能激活 MTD，并产生 ED 流量，随后产生 PE 流量。因此，利用上述三种基本类别，可以构建具有任意计算复杂度和准确率的流量模型 [13]。

A. 事件生成

这些事件随时间按照以下方式生成：

1) 泊松模型：事件发生之间的时间服从密度为 λ_T 的泊松分布。然后，每个MTD以概率进入状态 A

$$P_A = 1 - \exp\left(-2\pi\lambda_T \int_0^\infty p(d)\partial d\right). \tag{1}$$

2) 准周期流量：这种模式在工业物联网中很常见 [18]。这里，我们考虑具有均匀异步周期性的机器型通信流量。j^{th} MTD的传输间隔T_j （即连续传输之间的时隙数）相互独立，且服从准同分布 [18]。协调器在相互独立的起始时刻接收机器类型设备的信号（κ_j）。每个MTD的激活概率和传输时长分别表示为$P_{A_j} \in [0,1]$ 和 δ_j。后者表示每次传输所需的时隙数。最后，来自同一个MTD的数据包以起始时间 t_j 传输，使得

$$t_j = (\kappa_j + (m-1)T_j)B_j,\ m = 1,2,\ldots, \tag{2}$$

其中，B_j 是参数为 P_{A_j}的伯努利随机变量，m 表示传输机会。

B. 有效载荷交换

有效载荷交换模式的持续时间由 δ_j 量化，并通过几何分布建模。几何分布的参数 q 用于调节事件产生流量的突发性。具体而言，一旦进入状态 A，机器类型设备以概率.....在该状态停留 k 个传输时间间隔

$$G_k(q) = (1-q)q^k,\ k = 0,1,\ldots \tag{3}$$

我们假设 T_j 足够大，因此由于相对较大的 δ_j （k 个传输时间间隔）而导致两个传输机会重叠的概率几乎为零。请注意，参数 q 可用于调节机器类型设备各自速率过程及总速率过程的时间相关性，从而模拟各种机器类通信应用。例如，当 q 较小时，流量的行为类似于伯努利过程（无记忆） [11]。随着 q 增大，内存也随之增加，因为给定时刻 k 的总速率与许多过去的取值相关。于是，一旦进入状态 A，设备就会在其中停留更长时间 [11]。当协调器与机器类型设备之间的流量遵循泊松模型时，可使用具有两个状态 I 和 A 的遍历马尔可夫链 [11] 对其建模。

图 2 展示了从 MTD 流量中截取的片段。由于激活概率不同，一些 MTD 具有周期性流量模式，而另一些则很少处于活动状态。具体而言，y 轴上的值表示随机选取的 30 个 MTD，x 轴表示从流量中截取的 10^3 ms 时间帧。此外，点表示 y 轴上相应 MTD 生成数据包的时隙。底部的图显示了流量模式的准周期行为，而顶部的图显示了类泊松行为。这些模型能够准确拟合真实的 MTC 流量，例如与温度、光照和 CO_2, 测量值相关的流量。

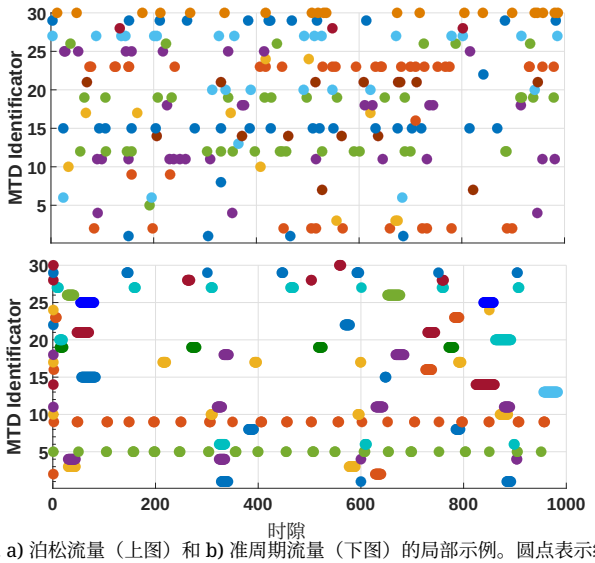


图 2. a) 泊松流量（上图）和 b) 准周期流量（下图）的局部示例。圆点表示给定 MTD（纵轴）处于活动状态的时隙（横轴）。

来自奥卢大学智慧校园网络的声音和湿度 [19][1]。

IV. 流量预测器

本文概述了所使用的机器学习预测器。这些机器学习机制部署在协调器侧，使机器类型设备保持简单且节能。协调器接收的流量数据的时间戳被用作机器学习机制的输入，以训练预测模型；随后，该模型用于优化网络性能[2]。机器类型设备会产生海量数据。然而，对机器学习服务器而言，关键在于数据的特征，而非数据本身 [20]。具体来说，为了预测下一个数据包的到达时间，协调器只需要训练好的模型以及此前数据包时间戳的历史记录。

A. 循环神经网络（RNN）

神经网络是由单元（神经元）组成的灵活非线性模型，能够从数据中学习模式。在非线性处理单元数量适当的情况下，神经网络能够从经验中学习，并以很高的准确率估计任意复杂的函数关系 [21]。此外，循环神经网络是一类强大的动态神经网络系统，可用于对序列数据中的长期依赖关系建模 [21]。循环神经网络在每个时间步接收序列中的一个元素，并将当前输入与此前时间步的信息结合起来，以学习内在模式。传统循环神经网络在训练过程中因循环运算而面临梯度消失问题。现代循环神经网络变体（如长短期记忆网络和门控循环单元）解决了传统循环神经网络的训练难题。

[1]具体而言，这些模型对真实数据的刻画误差小于 9%；对于事件驱动型流量和准周期流量，均方根误差（RMSE）分别为 0.947 和 0.982。

[2]尽管我们假设学习过程在协调器中进行，但模型可以离线训练，并仅在预测出现偏差时重新训练。此外，在需要保持 MTD 和协调器简洁且节能的场景中，可以利用云计算进行训练，然后只需在协调器中更新训练好的模型。

1) 长短期记忆网络（LSTM）是一种循环神经网络（RNN），它根据较长序列的先前输入值进行预测，而非仅依据单个值 [22]。基于 LSTM 的技术能够显著提升学习速度，尤其适用于状态/动作空间较大的问题。长短期记忆单元由三个门组成：输入门、输出门和遗忘门。这些门决定信息是被读取（输入门）、被认为无关而舍弃（遗忘门），还是被保存并影响当前时间步（输出门）。

2) 门控循环单元（GRU）仅包含两个门，即更新门和重置门。GRU 与长短期记忆网络（LSTM）相似，但少用一个门控信号及其相关参数进行训练 [23]。

在本研究中，我们构建了传统循环神经网络（RNN）、长短期记忆网络（LSTM）和门控循环单元（GRU）架构，包含 h 个隐藏层，每层有 n_1、n_2、$\cdots$ 和 n_h 个神经元；初始学习率为（ϵ），损失函数采用均方根误差（RMSE），最大训练轮数为（n_{ep}），并使用 Adam优化器 [24]。RNN 的学习算法在空间和时间上均为局部的；其每个时间步和每个权重的计算复杂度为 $\mathcal{O}(1)$ [25]，，因此计算复杂度为 $\mathcal{O}(2 \times n_1 \times n_2 \times \cdots \times n_h)$。

B. 时间卷积网络（TCN）

TCN架构使用因果卷积层，确保信息不会从未来泄漏到过去，并捕获序列数据中的复杂依赖关系。与常规卷积神经网络相比，该层使网络能够在更大的尺度上运行 [21]。我们构建了一个TCN架构，包含 l个卷积层，并采用丢弃正则化来减少过拟合（节点丢弃率 ρ）、滤波器数量（ω）、每层连接到同一区域（感受野， r）的神经元、大小为 $1 \times z$的卷积滤波器（f）、指数膨胀（Λ）且第 i层的膨胀率为 2^i、初始学习率（ϵ），并使用Adam优化器 [24]。其复杂度为 $\mathcal{O}$（$f \times \omega \times r$）。

因果卷积确保，对于给定的序列输入x_0、 x_1、.....、 x_N，时刻 t的输出仅取决于时刻 t及之前的输入，即对于给定的 r，仅取决于 x_t、 x_{t-1}、.....、 x_{t-r+1}。与此同时，膨胀因果卷积，即D（t） $= \sum_{i=0}^{z-1} f$（i）$x_{t-\Lambda i}$，使网络能够以较少的层数获得较大的 r，因为（Λ）会随着层数增加而呈指数增长。然而，由于膨胀因果卷积 [21]，较高层未能充分提取相邻时间步之间的局部连接。与循环神经网络相比，TCN的一个缺点是在推理期间内存占用较大，因为必须在下一个时间步计算整个序列。

V. 性能评估与讨论

第 II 节中的流量模型用于在协调器处模拟多条流量轨迹。在每条轨迹中，MTDs 和事件震中分别按照 Φ_M 和 Φ_E 随机部署在欧几里得平面上。各事件相互独立，同时我们假设事件对每个 MTD 流量的影响可用负指数函数建模为 $p(d) = \exp(-d)$。然后，$\int_0^\infty p(d) = 1$ 和 $P_A = 1 - \exp(-2\pi\lambda_T)$。

使用了两种流量模型：泊松模型（第 III-A1 节），其中包含$\lambda_T \in [1, 50]$；以及准周期模型（第 III-A2 节）。对于后者，每个 MTD 的传输间隔范围为 50 – 1000 毫秒（变化幅度上限为 ±5% 和 ± 10%），传输所需时间服从

表 I 仿真参数

参数	值	参考文献
ρ(丢弃率)	0.05	[27]
z (滤波器大小)	2	[21], [27]
l(卷积层)	3	[21], [27]
n 用于循环神经网络（隐藏神经元）	256	[11], [13]
n_{ep} (训练轮数)	50	[11], [13]
ω (滤波器数量)	32	[21]
r(感受野)	8	[21], [27]
ϵ(初始学习率)	10^{-3}	[27]

表 II 泊松（灰色）和准周期（白色）流量模式下流量预测器的性能比较

性能指标	RNN	LSTM	GRU	TCN	ARIMA
R指标	0.928	**0.962**	0.941	0.959	0.894
	0.968	0.989	0.981	**0.991**	0.953
TPR	0.896	0.912	0.908	**0.937**	0.852
	0.951	0.981	0.969	**0.986**	0.947
TNR	0.931	0.987	0.965	**0.991**	0.926
	0.976	**0.995**	0.986	**0.995**	0.964
准确率	0.914	0.949	0.937	**0.964**	0.889
	0.964	0.988	0.978	**0.990**	0.958

与第 III-B 节相同的几何分布。随后使用流量数据训练预测算法。在 9.8×10^4 个数据样本中，70% 用于训练，15 % 用作验证集，其余 15% 用于测试。MTD 的部署密度为 $\lambda_M = 10^{-1}$（MTD/m^2），并假设 TTI 等于 1 毫秒。所有 MTD 在初始时均处于状态 I，且为 $R = 1$ 个数据包/TTI。这些参数汇总于表 I，并用于所有仿真。

每种预测器的性能结果均基于 150 次蒙特卡洛运行，其中每次运行中机器类型设备的位置和事件震中均为随机分布。作为比较基线，我们采用自回归积分滑动平均（ARIMA），这是一种由 Box 和 Jenkins 提出的、广为人知的线性统计模型 [26]，用于时间序列预测。为确保公平，预测器的配置经过设计，使它们具有相同的大-$\mathcal{O}$ 复杂度。

A. 数值结果

表 II 比较了各预测器的召回率（R）、真正率（TPR）、真负率（TNR）和准确率。具体而言，R 是衡量预测准确能力的绝对指标，表示为 $\mathrm{R} = \left(1 - \frac{1}{M}\sum_{i=1}^{M}(1 - \hat{} g_i/g_i)^2\right)^{1/2}$，其中 $\hat{} g_i$ 和 g_i 分别为估计的和实际的到达间隔值，M 表示样本量。R 指标越高，数据拟合效果越好。TPR 按真正例/(真正例 + 假负例)计算，用于衡量虚警概率[3]。TNR 按真负例/(真负例 + 假正例)计算，用于衡量漏检信息。同时，准确率综合了 TPR 和 TNR，计算方式为正确预测数量/预测总数。时间卷积网络（TCN）的表现大多优于其他模型，而 ARIMA 的表现最差。此外，在准周期流量下，TCN 与其他模型之间的差距并不显著；而在泊松流量下，只有长短期记忆网络（LSTM）的表现接近 TCN。

[3]较高的真正率（较低的虚警概率）意味着更高的能效，因为这可以避免与未激活 MTD 进行通信尝试。

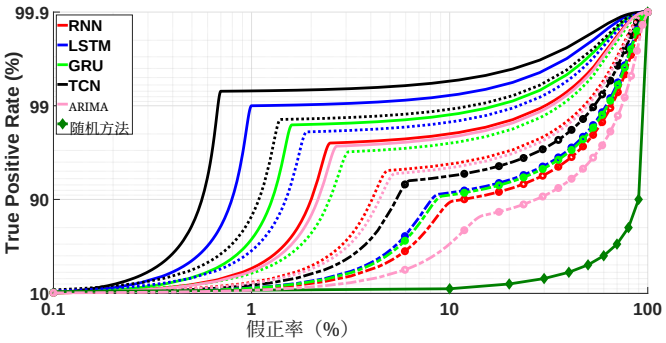


图3. 各模型对应的 ROC曲线：准周期流量变化为±5%（实线）和 ±10%（点线），泊松流量模型（点划线，带圆形标记）。请注意，纯随机方法的性能不取决于所用的流量模型。

图 3 展示了两种流量模型的受试者工作特征（ROC）曲线。可以看出，时间卷积网络的表现优于其他预测器，但与长短期记忆网络相比，优势并不显著。请注意，长短期记忆网络和时间卷积网络的虚警概率（1 − 真正率）约为 1%，而其他模型最高可达 7.4%。在对时延和丢包敏感的场景建模时，这一指标十分重要。图 3 显示了预测器应对数据分布变化的稳健性，其中时间卷积网络和长短期记忆网络最能适应流量模式的变化。值得注意的是，在准周期流量变化幅度为 10% 时，长短期记忆网络优于变化幅度为 5% 时的循环神经网络；在流量变化幅度为 10% 时，时间卷积网络优于变化幅度为 5% 时的门控循环单元。对于泊松流量，值得注意的是，时间卷积网络优于其他预测器，而长短期记忆网络和门控循环单元的表现相近。

值得注意的是，在准周期流量条件下，预测器表现相对较好，即使在时间卷积网络和长短期记忆网络的情况下，变化幅度接近 ±30%，其余情况下则高达 ±25%。与此同时，在泊松流量下，由于其固有的随机性更强，预测准确率受到的影响更为严重。不过，泊松流量的轻微变化对预测器的准确率没有显著影响。

B. 复杂度分析

表 III 展示了推理时间、训练时间和模型大小方面的性能。这三个参数根据各架构的贡献相对于总量进行了归一化。请注意，TCN 和循环神经网络的模型大小分别最大和最小。同时，就推理时间而言，TCN 和长短期记忆网络分别是最快和最慢的。然而，长短期记忆网络只需较短的训练时间即可获得可用的预测模型，而时间卷积网络则需要更长时间。

无论如何，更深的网络架构可以通过提取更多相关信息来提高预测准确率，但代价是复杂度、训练时间和推理时间增加。请注意，模型大小和训练数据大小应根据基站的硬件、应用的需求、设备数量以及目标分组错误率 [13] 进行调整。

图 4a 展示了性能与模型复杂度的关系。当复杂度 (C) 低于 1024 时，随着采用更深的架构，真正率不断提高；而超过该值后，模型往往会出现过拟合。达到最佳性能后，时间卷积网络与循环神经网络之间的差距逐渐缩小。长短期记忆网络的性能排名第二，需要更深的架构才能达到最佳预测性能。

表 III 各机器学习架构的复杂度

	RNN	LSTM	GRU	TCN
推理时间	0.222	0.324	0.271	**0.183**
训练时间	0.304	**0.145**	0.213	0.338
模型大小	**0.167**	0.229	0.181	0.423

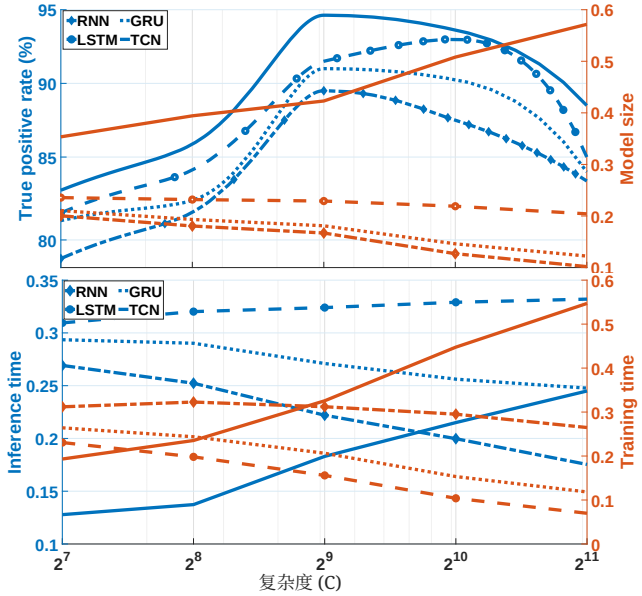


图 4. 泊松流量下，性能随复杂度 $\mathcal{O}(C)$ 变化的情况：a) 真正率和模型大小（上），以及 b) 推理时间和训练时间（下）。b) 中 y 轴和 a) 中右侧 y 轴的数值均已归一化。

门控循环单元的收敛速度快于长短期记忆网络，因此使用复杂度较低的模型即可达到最佳性能。这是因为门控循环单元通常具有更少的可训练参数 [27]。总的来说，无论网络深度如何，时间卷积网络都表现出最高的预测准确率。就模型大小而言，更深的时间卷积网络架构需要更多计算资源（右侧 y 轴），从而扩大了其与其他模型之间的差距，而长短期记忆网络与门控循环单元之间的差距则略有扩大。

图 4b）展示了不同模型复杂度下的相对耗时。对于推理时间（左侧 y 轴），无论复杂度如何，长短期记忆网络耗时最长，而时间卷积网络与门控循环单元之间的差距会随复杂度增加而缩小。对于训练时间，更深的架构会扩大时间卷积网络与其他模型之间的差距，而长短期记忆网络收敛最快。

VI. 结论

我们比较并分析了多种流量预测方法。我们采用独立泊松点过程对机器类型设备和事件中心进行空间建模。除此之外，我们还对泊松流量模式和准周期流量模式进行了建模，并考虑了突发持续时间服从几何分布的事件驱动流量模式。我们展示了时间卷积网络的优越性，以及循环神经网络所达到的极低准确率。在准周期流量下，长短期记忆网络和时间卷积网络的预测准确率相近，且优于其他方法。不过，前者的推理时间更短，而使用长短期记忆网络时训练时间也更短。另一方面，从内存占用来看，运行基于时间卷积网络的预测器成本要高得多，约为其他基线方法的3倍。

参考文献

[1] Y. Zhang 等，“具有严格时限服务的超可靠低时延通信多小区免授权上行物联网网络”，IEEE Wireless Commun. Lett.，第11卷，第7期，第1448–1452页，2022年。[2] L. Zhao 等，“决策质量驱动的机器类型通信”，IEEE Internet Things J.，2022年。[3] B. Mareri 等，“用于5G网络切片的多车道胶囊网络辅助流量分类”，IEEE Wireless Commun. Lett.，第11卷，第9期，第1905–1909页，2022年。[4] F. Mehmeti 等，“5G基站中的海量机器类型通信流量建模与分析”，载于 IEEE CCNC，2022年，第652–660页。[5] F. Wang 等，“基于时间感知局部敏感哈希的海量物联网大规模交通流6G赋能短期预测”，IEEE Internet Things J.，第8卷，第7期，第5321–5331页，2020年。[6] M. Zakarya 等，“节能计算、集群、网格与云：分类与综述”，Sustainable Comput. Informat. Sys.，第14卷，第13–33页，2017年。[7] T. N. Weerasinghe 等，“基于监督学习的突发流量到达预测与动态前导码分配”，载于 IEEE INFOCOM 计算机通信会议研讨会（INFOCOM WKSHPS）。IEEE，2019年，第1–6页。[8] T. Weerasinghe 等，“面向海量机器类型通信突发流量的前导码传输预测：一种基于机器学习的方法”，载于 GLOBECOM IEEE 全球通信会议。IEEE，2020年，第1–6页。[9] A. Søraa 等，“面向海量机器类型通信突发流量的前导码传输预测：一种基于机器学习的方法”，载于 GLOBECOM，2020年，第1–6页。[10] T. Senevirathna 等，“使用长短期记忆网络预测机器类型通信中的事件驱动源流量”，载于 GLOBECOM IEEE 全球通信会议。IEEE，2020年，第1–6页。[11] D. E. Ruiz-Guirola 等，“基于流量感知长短期记忆预测的机器类型设备节能唤醒信令”，IEEE Internet Things J.，第1–1页，2022年。[12] M. Chen 等，“面向边缘计算5G网络的智能流量自适应资源分配”，IEEE Trans. Cogn. Commun. Netw.，第6卷，第2期，第499–508页，2019年。[13] E. Eldeeb 等，“通过支持向量机和长短期记忆网络为海量物联网提供基于学习的快速上行授权”，IEEE Internet Things J.，第9卷，第5期，第3889–3898页，2022年。[14] A. D. Shoaei 等，“相关流量机器类型通信网络的可重构接入方案流量预测”，载于 IEEE 第32届年度国际个人、室内与移动无线电通信研讨会（PIMRC）。IEEE，2021年，第953–958页。[15] A. Mughees 等，“利用机器学习实现节能5G网络：分类、研究挑战与未来研究方向”，IEEE Access，第8卷，第187 498–187 522页，2020年。[16] H. Thomsen 等，“使用空间点过程的机器类型通信流量模型”，载于 IEEE PIMRC。IEEE，2017年，第1–6页。[17] O. L. L´opez 等，“海量低功耗物联网的无CSI与基于CSI的多天线无线能量传输”，IEEE Trans. Wireless Commun.，第20卷，第5期，第3078–3094页，2021年。[18] M. Mitev 等，“面向工业物联网的智能链路自适应与调度”，IEEE Netw. Lett.，2022年。[19] 奥卢大学，“奥卢智慧校园室内气候、空气质量与运动”，https://doi.org/ 10 23729 9 0 2 7381 45 32 7 78 1 9 3, 。/b adb a - - 6 2021, db-b f- e ae bc e 奥卢大学，CWC - 网络与系统。[20] S. Hu 等，“ 无线通信网络的分布式机器学习：技术、架构与应用”，IEEE Commun. Surv. Tutor.，第23卷，第3期，第1458–1493页，2021年。[21] T. N. Duc 等，“用于视频流服务持续体验质量预测的卷积神经网络”，IEEE Access，第8卷，第116 268–116 278页，2020年。[22] Y.-H. Xu 等，“用于无人机服务的机器间通信资源分配的生成对抗长短期记忆网络学习”，IEEE Wireless Commun. Lett.，第10卷，第7期，第1601–1605页，2021年。[23] R. Dey 等，“门控循环单元（GRU）神经网络的门控变体”，载于 IEEE MWSCAS，2017年，第1597–1600页。[24] M. Sharma 等，“Adam：一种随机优化方法”，Pattern Recogn. Lett.，第94卷，第172–179页，2017年。[25] F. A. Gers 等，“学习遗忘：使用长短期记忆网络进行持续预测”，Neural computat.，第12卷，第10期，第2451–2471页，2000年。[26] G. E. Box 等，《时间序列分析：预测与控制》。John Wiley & Sons，2015年。[27] F. Sadique 和 S. Sengupta，“使用时间卷积网络（TCN）对物联网僵尸网络中的攻击者行为建模与分析”，Computers & Security，第117卷，第102714页，2022年。