

# 基于长短期记忆网络的数字孪生移动通信网络环境生成技术



## Digital Twin Environment Generation for Mobile Communication Networks: A Long Short-Term Memory Approach

梁广明/LIANG Guangming<sup>1</sup>, 杨鲲/YANG Kun<sup>1</sup>,  
刘强/LIU Qiang<sup>1</sup>, 陈建军/CHEN Jianjun<sup>2,3</sup>

(1. 电子科技大学, 中国 成都 611731;  
2. 中兴通讯股份有限公司, 中国 深圳 518057;  
3. 移动网络和移动多媒体技术国家重点实验室, 中国 深圳 518055)  
(1. University of Electronic Science and Technology of China, Chengdu 611731, China;  
2. ZTE Corporation, Shenzhen 518057, China;  
3. State Key Laboratory of Mobile Network and Mobile Multimedia Technology, Shenzhen 518055, China)

DOI: 10.12142/ZTETJ.202303004

网络出版地址: <http://kns.cnki.net/kcms/detail/34.1228.TN.20230620.1322.004.html>

网络出版日期: 2023-06-20

收稿日期: 2023-04-26

**摘要:** 未来6G时代将进入虚拟化的数字孪生世界, 实现“万物智联, 数字孪生”的愿景。移动通信网络的数字孪生需要建立物理通信网络与孪生通信网络之间的高精度映射, 保证孪生虚拟数据与实际物理数据保持高度匹配。针对上述数字孪生环境生成的问题, 采用了数据驱动的长短期记忆网络的方法, 对移动通信网络中的无线信道、基站业务流和用户移动轨迹进行时序预测与生成, 从而构建出高精度数字孪生环境。仿真结果表明, 所提算法能精准生成未来时序数据, 与物理通信网络真实数据保持高度一致。

**关键词:** 移动通信网络; 数字孪生; 长短期记忆网络; 时序预测

**Abstract:** The future 6G era will enter a virtual digital twin world and realize the vision of wisdom connection and digital twin. The digital twin of mobile communication network needs to establish a high-precision mapping between the physical communication network and the twin communication network to ensure that the virtual data and the physical data are highly matched. To solve the problem of digital twin environment generation, the method of data-driven long short-term memory network is adopted to predict the time sequence of wireless channel, base station traffic flow and user mobility trajectory in mobile communication network, so as to construct a high-precision digital twin environment. Simulation results show that the proposed algorithm can accurately predict future time series data.

**Keywords:** mobile communication network; digital twin; long short-term memory network; time series prediction

**引用格式:** 梁广明, 杨鲲, 刘强, 等. 基于长短期记忆网络的数字孪生移动通信网络环境生成技术 [J]. 中兴通讯技术, 2023, 29(3): 15-20. DOI: 10.12142/ZTETJ.202303004

**Citation:** LIANG G M, YANG K, LIU Q, et al. Digital twin environment generation for mobile communication networks: a long short-term memory approach [J]. ZTE technology journal, 2023, 29(3): 15-20. DOI:10.12142/ZTETJ.202303004

数字孪生是指对物理世界的数字镜像, 借助数据驱动的方法对物体实体的历史数据和实时数据进行分析与挖掘, 从而对物理实体进行高精度模拟和预测。同时, 数字孪生需要具备强大的智能纠错和数据自生成能力。当前数字孪生已经开始应用在各个领域中, 为各项技术提供模拟、验证和试错的高精度孪生环境。在工业领域, 文献[1]提出了一种数据驱动的工业设备数字孪生结构和维护框架, 为发电厂

的风力涡轮机开发了一个数字孪生体, 以便进行故障预测与检测。在电力和能源领域, 文献[2]提出了一种采用前馈神经网络的冷却器数字孪生方法, 将孪生体收集到的数据提供给遗传算法, 从而进行多目标优化, 使冷却效率、性能系数和湿球效率实现最大化。在医疗与健康领域, 文献[3]提出了一种模拟患者的头部行为的数字孪生模型, 并在该模型上检测患者颈动脉狭窄的严重程度, 实现了非侵入式的检测。

IMT-2030 (6G) 推进组在《6G 总体愿景与潜在关键技术白皮书》<sup>[4]</sup>中指出, 未来6G时代将进入虚拟化的数字孪生

基金项目: 国家重点研发计划 (2021YFB2900204); 国家自然科学基金 (62132004)

世界,实现“万物智联,数字孪生”的愿景。当前,基于数字孪生的移动通信网络受到学术界和工业界的广泛关注,正在成为一个热门研究方向。文献[5]认为模拟器训练得到的策略无法直接部署到真实环境,这极大限制了深度强化学习(DRL)在无人机集群运动场景中的应用;因此提出了一种基于数字孪生的DRL训练框架来解决这个问题。DRL智能体可以学习数字孪生环境,在策略收敛后快速部署在真实世界的无人机上。为了应对高效边缘计算提出的重大挑战,文献[6]将数字孪生技术和人工智能技术融入到车辆边缘计算网络的设计当中,提出了一种协作图驱动的车辆任务卸载方案。该方案通过在数字孪生网络和物理网络中进行智能任务卸载调度来最小化卸载成本。为了解决用户任务卸载中强化学习方法动作空间过大和收敛速度过慢问题,文献[7]提出了一种基于数字孪生的强化学习任务调度方法,利用多个智能体在数字孪生环境中进行交互,以提高决策性能和策略收敛性。然而,目前的研究工作大多基于数字孪生体已经被完美构建的假设,很少探讨移动通信网络数字孪生体的生成问题。

数字孪生需要建立物理通信网络与孪生通信网络之间的高精度映射。在单个运行周期内,两者之间需要保持精确同步。在运行周期之间,数字孪生体需要在交互机制的指导下与物理实体展开数据交互,以保证下一周期能与物理世界保持高度一致。未来6G网络需要兼容海量异构通信设备并满足亚毫秒级时延要求,这对未来网络数字孪生体的构建提出了巨大挑战。因此移动通信网络中的数字孪生环境生成问题是当前亟待攻克的技术难点。

人工智能技术可以用于时间序列预测,从而构建与物理实体时隙对齐的数字孪生体。文献[8]将递归神经网络(RNN)作为流量模型,用于预测即将到来的流量,并与DRL结合从而做出链路布局决策。文献[9]基于多维数据,利用长短期记忆网络(LSTM)的深度学习模型来构建时空中多播服务的动态流量模型,为进一步的网络资源分配提供了基础。

针对上述的背景,本文的主要贡献如下:

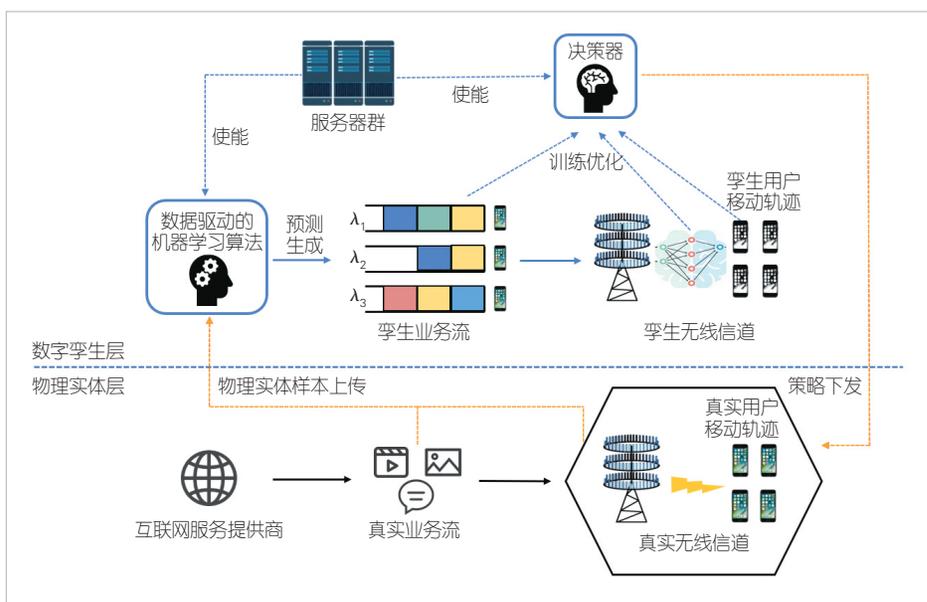
1) 提出了一种基于LSTM网络的移动通信网络数字孪生方法,该方法通过学习时序数据中的时间相

关性,基于历史数据预测未来数据,从而构建移动通信网络的数字孪生环境。

2) 基于3个公开数据集,将该方法应用在移动通信网络中的无线信道孪生、基站业务流孪生和用户移动轨迹孪生上,验证了LSTM网络方法构建高精度数字孪生环境的有效性。

### 1 数字孪生整体架构

移动通信网络数字孪生的整体架构如图1所示,主要分为物理实体层和数字孪生层。在物理实体层中,互联网服务提供商为用户提供业务流,然后蜂窝基站通过无线信道将信息传递给各个用户终端。物理实体层将无线链路质量数据、业务流数据和用户移动轨迹数据定时上传到数字孪生层。在数字孪生层中,通过数据驱动的机器学习方法预测并生成对应的虚拟孪生环境数据,使得自生成的虚拟数据与实际数据保持高度匹配。当虚拟数据被送入无线链路和网络决策器时,决策器基于时隙提前孪生数据完成智能策略的预训练。通过链路控制和资源分配可实现无线链路和网络长期性能最优化。值得注意的是,孪生数据生成过程以及无线链路和网络决策的训练过程均由数字孪生层中的高性能服务器群完成。最后,预训练好的无线链路和网络传输策略被下发并提前部署在物理实体层,从而提升通信系统的各项性能指标。因此,对物理实体中无线信道质量、无线业务流量以及移动用户轨迹进行高精度的时间序列预测,是构建数字孪生环境的关键,是完成数字孪生网络推演的集成。



▲图1 数字孪生构建-决策整体架构

## 2 数字孪生环境生成技术

### 2.1 长短期记忆网络

时间序列预测的基础是，当前时隙的数据与过去时隙的数据存在着时间相关性。通信网络中的时序数据往往都存在着较为复杂的非线性关系，因此适合采用数据驱动的LSTM方法<sup>[10]</sup>来挖掘当中的时序相关性，解决时间序列预测的问题。

LSTM是递归神经网络(RNN)<sup>[11]</sup>的变种，它解决了RNN无法学习时序数据中，当前时隙数据与过去较远时隙数据之间的长期相关性的问题。RNN较为简单的循环结构，导致过去较远时刻产生的梯度在当前时刻会出现消失现象，因此无法有效学习到数据间的长期依赖关系。相比RNN只有一个传递状态，LSTM有两个传输状态，分别是细胞状态 $c^t$ 和隐藏状态 $h^t$ 。细胞状态 $c^t$ 在传递过程中变化很慢，通常是由上一个状态传递过来的 $c^{t-1}$ 经过少量线性变换得到的，而隐藏状态 $h^t$ 则在传递过程中发生较快变化。

LSTM内部结构如图2所示。其中， $z^f$ 、 $z^i$ 和 $z^o$ 是门控状态，相应的生成过程如下：当前状态输入 $x^t$ 和上一状态传递下来的 $h^{t-1}$ 拼接形成向量 $s^t$ ；向量 $s^t$ 乘以不同的权重矩阵，并通过sigmoid激活函数转换为0到1之间的数值。而图2中 $z$ 是输入数据，相应的生成过程如下：拼接向量 $s^t$ 乘以相应的权重矩阵后，通过tanh激活函数转换到-1到1之间的数值。门控状态 $z^f$ 、 $z^i$ 和 $z^o$ 以及输入数据 $z$ 对应的计算公式为：

$$z^f = \text{sigmoid}(W^f s^t), \tag{1}$$

$$z^i = \text{sigmoid}(W^i s^t), \tag{2}$$

$$z^o = \text{sigmoid}(W^o s^t), \tag{3}$$

$$z = \tanh(W s^t), \tag{4}$$

其中， $W^f$ 、 $W^i$ 、 $W^o$ 和 $W$ 分别是 $z^f$ 、 $z^i$ 、 $z^o$ 和 $z$ 对应的权重矩阵。

在LSTM内部向量的计算中， $\odot$ 代表哈达玛乘积，即两个矩阵中对应的元素相乘，而 $\oplus$ 代表的是矩阵加法，即两个矩阵中对应的元素相加。LSTM其余变量计算公式为：

$$c^t = z^f \odot c^{t-1} + z^i \odot z, \tag{5}$$

$$h^t = z^o \odot \tanh(c^t), \tag{6}$$

$$y^t = \text{sigmoid}(W' h^t), \tag{7}$$

其中， $y^t$ 为当前状态输出值， $W'$ 为 $y^t$ 对应的权重矩阵。

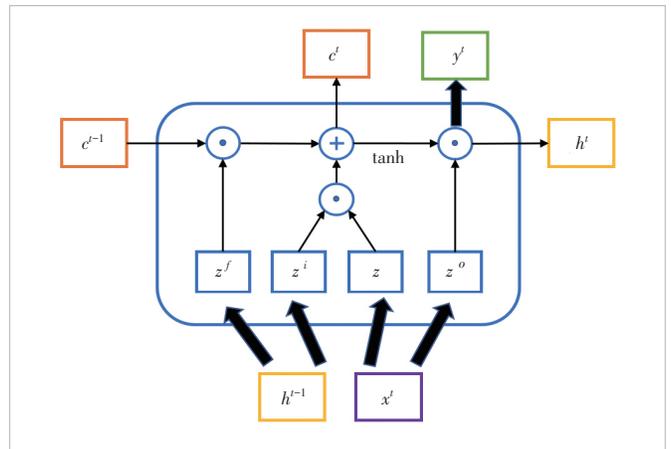
LSTM内部主要有3个阶段，分别是遗忘阶段、选择记忆阶段和输出阶段：

1) 遗忘阶段。该阶段是对上一个状态输入的 $c^{t-1}$ 信息进行选择性遗忘，即采用 $z^f$ 作为遗忘门控，以控制哪些数值需要遗忘。

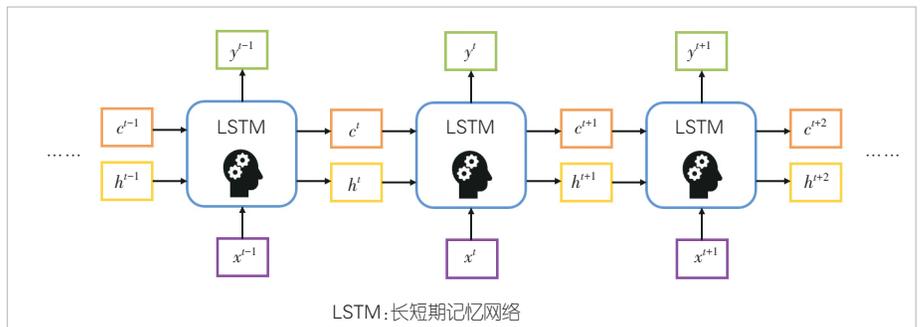
2) 选择记忆阶段。该阶段对当前状态输入的 $x^t$ 和 $h^t$ 信息进行选择性记忆，即采用 $z^i$ 作为选择记忆门控，以控制哪些数值需要被着重记忆。

3) 输出阶段。该阶段将决定哪些经过变换后的输入信息将会被当成当前状态的输出，即采用 $z^o$ 作为输出门控，以控制整个输出过程。与RNN类似， $y^t$ 是通过 $h^t$ 进行变换得到的。

如图3所示，将LSTM按状态进行展开时，每个状态的细胞状态和隐藏状态信息都会被刷新并向下一个状态传输，而权重矩阵 $W^f$ 、 $W^i$ 、 $W^o$ 、 $W$ 和 $W'$ 都是固定的。训练时，需要采用反向传播算法<sup>[12]</sup>优化上述5个权重矩阵。训练完成后，选择性能表现最好的矩阵参数，执行前向传播算法，并输出预测结果。这种方法的总体思想是，通过LSTM中的细胞状态和隐藏状态提取时间特征之后，将时序特征送入全连



▲图2 长短期记忆网络的内部结构图



▲图3 LSTM状态展开图

接神经网络，实现连续数据预测。

## 2.2 无线信道数据孪生生成

在移动通信网络的蜂窝内，基站到用户终端的无线信道质量随时间变化，构成时变信道。信道的时变性质主要由用户与基站之间的相对运动引起。在信号中心频率 $f_c$ 和信号传输周期 $T_s$ 确定的情况下，用户与基站之间的相对速度 $v$ 引起的多普勒频偏 $f_d$ 直接决定了无线信道变化的快慢。在经典无线通信理论中，在传播信号的相干时间 $T_c$ 内，可以近似认为无线信道质量保持不变<sup>[13]</sup>，其中相干时间的计算可由公式(8)完成：

$$T_c \approx \frac{0.5c}{vf_c} = \frac{1}{2f_d} \quad (8)$$

我们考虑基站单发射天线、用户单接收天线的场景，并采用单载波信号传输（信号传输周期 $T_s$ 远小于相干时间 $T_c$ ）。在该场景下，采用LSTM网络对无线信道数据进行孪生生成，而孪生生成的时序信道数据中每个时隙的长度均是 $T_s$ 。我们将过去 $P_w$ 时隙的实际物理信道数据输入LSTM网络结构，生成未来 $L_w$ 时隙的数字孪生信道数据。

## 2.3 基站业务流数据孪生生成

移动通信网络的蜂窝基站为用户提供的语音、短信、业务流量也是随着时间变化的，具备时序数据特征。因此，根据过去 $P_j$ 时隙的物理移动网络实际业务流量数据，通过挖掘时序相关特征，可以在数字孪生层生成未来 $L_j$ 时隙虚拟业务流，以便对业务流调度策略等移动网络传输策略进行提前训练。然而，蜂窝基站承载的网络业务流除了存在时间相关性外，还存在显著的周期性。因此，除了采用LSTM网络外，还需要采用快速傅里叶变换（FFT）的方法提取周期性<sup>[14]</sup>。具体孪生业务生成器的训练步骤如下：

1) 将训练集数据 $X_t$ 送入FFT模块，然后提取频谱中峰值最高的50个频率分量，并根据这些参数生成相应的正弦波叠加的大尺度周期分量集 $X_t^p$ ；

2) 将周期分量的数据从数据集中减去，得到小尺度分量集 $X_t^r = X_t - X_t^p$ ；

3) 利用数据集 $X_t^r$ 来训练LSTM模块。

在孪生业务生成器训练收敛后，根据物理移动网络实际业务流量数据，孪生业务流的具体生成步骤为：

1) 用提取到的频率分量参数预测大尺度周期性分量 $\widehat{X}_t^p$ ；

2) 用LSTM预测小尺度分量集 $\widehat{X}_t^r$ ；

3) 获得最终用户业务流预测结果 $\widehat{X}_t = \widehat{X}_t^p + \widehat{X}_t^r$ 。

## 2.4 用户移动轨迹数据孪生生成

物理移动网络中用户的移动轨迹记录了移动对象的时空分布足迹，是移动对象活动特征的真实反应，具备空间特征和时间特征，同时数据中隐藏着方向、速度、用户聚集性等重要的属性信息。用户移动轨迹数据兼具时间相关性和空间相关性。LSTM等方法可以深入挖掘移动轨迹数据的时空特征，根据当前 $P_w$ 时隙的物理移动网络中用户移动轨迹数据，孪生生成 $L_w$ 时隙的虚拟轨迹数据。但在移动网络中，海量用户精准轨迹的预测将浪费极大的计算资源。精准移动轨迹并不能显著提升移动网络的吞吐量等网络性能。

移动通信网络通常由相互独立的蜂窝构成。当进入某一基站的覆盖范围时，移动用户会与该基站形成关联，由该基站满足其各类通信需求。伴随用户移动行为，网络中各个基站承载的用户数目发生时序动态变化。不同蜂窝基站可关联不同数目的用户。我们将用户移动区域划分为若干小区，针对每一个蜂窝小区，设计LSTM网络，以便根据过去 $P_w$ 时隙中物理移动网络内的各个基站关联的用户数目真实数据，在数字孪生层生成未来 $L_w$ 时隙中各个基站关联的用户数目虚拟数据。该孪生数据可以用于移动网络中基站间资源分配策略的提前训练。

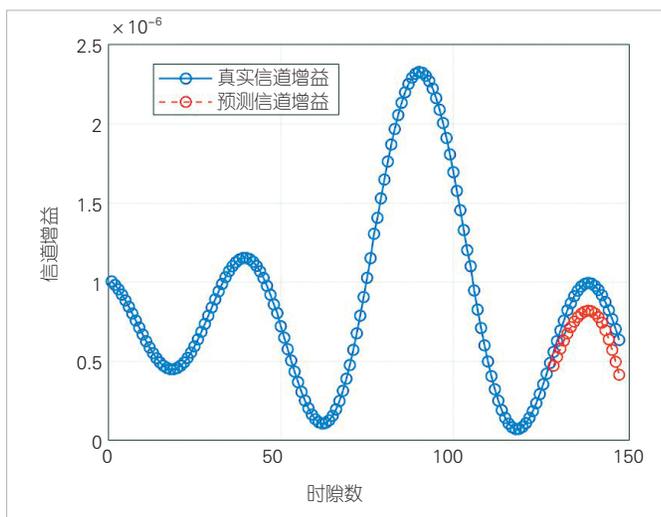
## 3 仿真实验

### 3.1 无线信道预测生成

在本部分实验中，物理移动网络的真实无线信道数据来自基于3GPP TR 38.901 TDL-A协议的5G toolbox<sup>[15]</sup>，其中信号的中心频率 $f_c = 1.71$  GHz，多普勒频偏 $f_d = 50$  Hz，基站高度 $h_b = 20$  m，用户高度 $h_u = 10$  m，基站与用户间距离 $d = 10$  m，信号周期 $T_s = 0.25$  ms。我们每隔 $T_s$ 周期采集1次无线信道数据，一共采集了15 000组数据，且划分训练集和测试集的比例为5 : 1。

我们采用3层LSTM网络，设置输入层节点数目为 $1 \times 128$ ，隐藏层节点数目为200，输出层节点数为20；采用适应性矩估计（Adam）优化器，损失函数采用均方误差（MSE），对输入数据进行线性归一化处理。

我们设置 $P_w = 128$ ， $L_w = 20$ ，即使用128个时隙（单时隙时长度为0.25 ms）的信道增益预测未来20个时隙的信道增益。由图4中可知，预测值与真实值在趋势上与幅度上都较为接近。LSTM方法能较好地预测未来20个时隙信道增益先上升后下降的走势。训练收敛后，LSTM最终在测试集上



▲图4 时隙为0.25 ms时的无线信道时序预测

取得了94.2%的准确率。

### 3.2 基站业务流预测生成

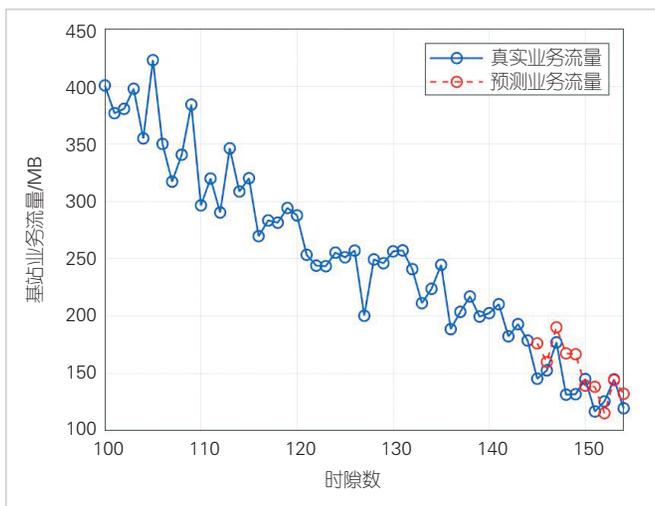
我们选取哈佛大学公开的一个基站流量数据集<sup>[16]</sup>作为数据来源。该数据集记录了意大利电信公司于2013年11月1日—2014年1月1日在米兰市采集的区域流量信息。该数据集将区域划分为 $100 \times 100$ 个小区，每隔10 min记录一次当前区域内的短信业务、话音业务及互联网业务的流量数据。每一条数据均包含小区编号、时间戳、国家代码、短信接收流量、短信发出流量、电话呼入流量、电话呼出流量以及互联网流量。我们只选取其中一个小区的互联网业务流量，以用于分析与预测。我们采用30 d共4 320条数据，其中29 d的4 176条数据作为训练集，1 d的144条数据作为测试集，即训练集和测试集的比例为29 : 1。

我们采用3层LSTM网络，输入层节点数目为 $1 \times 144$ ，隐藏层节点数目为200，输出层节点数为12，采用Adam优化器，损失函数采用MSE，对输入数据进行线性归一化。

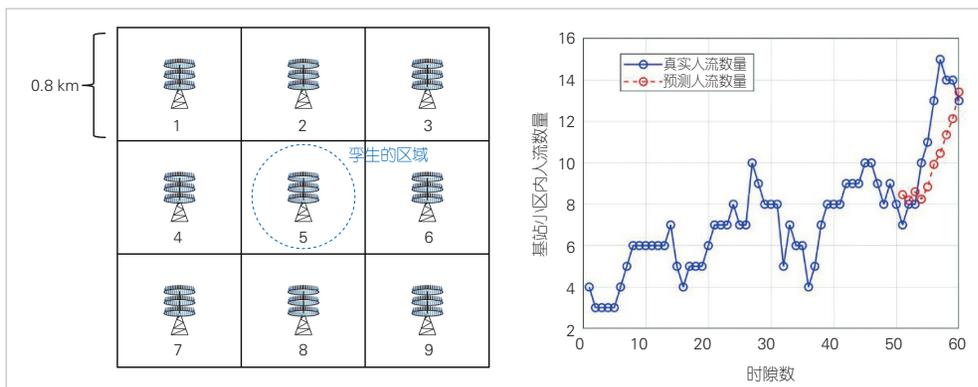
我们设置  $P_f = 144$ ， $L_f = 12$ ，即使用144个时隙（单时隙长度为10 min）的业务流量来预测未来12个时隙的业务流量。从图5中可以看出，预测值与真实值在趋势上与幅度上都较为接近。LSTM方法能较好地预测未来12个时隙互联网业务流量总体下降走势。训练收敛后，LSTM最终在测试集上取得了81.2%的准确率。

### 3.3 用户移动轨迹预测生成

我们选取韩国科学技术学院公开的用户移动轨迹数据集<sup>[17]</sup>。该数据集每30 s记录一次92名用户的具体坐标，其中所有用户的最短记录时长为250 min。由于预测的是基站所在小区内的人流数量，因此需要根据用户移动轨迹数据集中的坐标信息，为基站划定小区的范围。简单起见，我们假设基站的小区为正方形区域。用户的移动行为具备显著的聚集特征，即绝大多数用户偏向于在某些区域内活动，只有极少数用户会前往较为遥远的区域。我们决定不依据用户最大的活动范围来划分区域，因为这会造成只有少量区域有用户关联，而其他大部分区域没有用户。如图6所示，将用户的活动范围划分成9个 $0.8 \times 0.8 \text{ km}^2$ 的标准正方形，最终形成一个 $2.4 \times 2.4 \text{ km}^2$ 的九宫格，其中每个正方形格子拥有一个基站。根据最小距离关联原则，用户至与其距离最近的基站进行关联。我们共采用数据集中的500条用户坐标数据，并将其关联到各个基站中。本文对九宫格中的5号基站的人流数量进行时序预测生成，其中，225 min（450条数据）为训练集，25 min（50条数据）为测试集，划分训练集和测试集的



▲图5 时隙为10 min时的基站业务流时序预测



▲图6 时隙为30 s时的用户移动轨迹时序预测

比例为9 : 1。

我们采用3层LSTM网络, 输入层节点数目为 $1 \times 50$ , 隐藏层节点数目为200, 输出层节点数为10, 采用Adam优化器、MSE损失函数, 对输入数据进行线性归一化处理。

我们设置 $P_{lr} = 50$ ,  $L_{lr} = 10$ , 即使用50个时隙(单时隙长度为30 s)的基站蜂窝人流量来预测未来10个时隙的基站小区内人流量。从图6可以看出, LSTM方法能较好地预测未来10个时隙的蜂窝基站人流量总体上升走势。训练收敛后, LSTM最终在测试集上取得了82.0%的准确率。

#### 4 结束语

在未来的6G时代, 基于数字孪生的移动通信网络具有广阔的应用前景。本文利用数据驱动的长短期神经网络的方法, 对无线信道、基站业务流和用户移动轨迹进行时序预测。结果表明, 这些预测最终均达到了80%以上的准确率。该方法生成了移动通信网络中关键数据的数字镜像, 为无线链路和网络的智能传输策略提供了预训练的高精度数字孪生环境。

#### 致谢

感谢电子科技大学信息与通信工程学院的车畅、杨子慕、陈昌彬3位同学对本论文做出的贡献。

#### 参考文献

[1] ZHANG T, REN G, MING H, et al. Application exploration of digital twin in rail transit health management [C]//Proceedings of 2022 Global Reliability and Prognostics and Health Management. IEEE, 2022: 1-5. DOI: 10.1109/phm-yantai55411.2022.9942083

[2] GOLIZADEH A Y, BADIEI A, ZHAO X D, et al. A constraint multi-objective evolutionary optimization of a state-of-the-art dew point cooler using digital twins [J]. Energy conversion and management, 2020, 211: 112772. DOI: 10.1016/j.enconman.2020.112772

[3] CHAKSHU N K, CARSON J, SAZONOV I, et al. A semi-active human digital twin model for detecting severity of carotid stenoses from head vibration—a coupled computational mechanics and computer vision method [J]. International journal for numerical methods in biomedical engineering, 2019, 35(5): e3180. DOI: 10.1002/cnm.3180

[4] IMT-2023(6G)推进组. 6G总体愿景与潜在关键技术白皮书 [R]. 2021

[5] SHEN G Q, LEI L, LI Z L, et al. Deep reinforcement learning for flocking motion of multi-UAV systems: learn from a digital twin [J]. IEEE Internet of Things journal, 2022, 9(13): 11141-11153. DOI: 10.1109/JIOT.2021.3127873

[6] ZHANG K, CAO J Y, ZHANG Y. Adaptive digital twin and multiagent deep reinforcement learning for vehicular edge computing and networks [J]. IEEE transactions on industrial informatics, 2022, 18(2): 1405-1413. DOI: 10.1109/TII.2021.3088407

[7] WANG X C, MA L F, LI H C, et al. Digital twin-assisted efficient reinforcement learning for edge task scheduling [C]//Proceedings of 2022 IEEE 95th Vehicular Technology Conference: (VTC2022-Spring). IEEE, 2022: 1-5. DOI: 10.1109/VTC2022-Spring54318.2022.9860495

[8] LUO Z Y, WU C, LI Z P, et al. Scaling geo-distributed network function chains: a prediction and learning framework [J]. IEEE journal on selected areas in communications, 2019, 37(8): 1838-1850. DOI: 10.1109/JSAC.2019.2927068

[9] YU P, ZHOU F Q, ZHANG X, et al. Deep learning-based resource allocation

for 5G broadband TV service [J]. IEEE transactions on broadcasting, 2020, 66(4): 800-813. DOI: 10.1109/TBC.2020.2968730

[10] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9(8): 1735-1780. DOI: 10.1162/neco.1997.9.8.1735

[11] LIPTON Z C, BERKOWITZ J, ELKAN C. A critical review of recurrent neural networks for sequence learning [EB/OL]. [2023-04-16]. <https://arxiv.org/abs/1506.00019>

[12] YANN L. A theoretical framework for back-propagation [EB/OL]. [2023-04-16]. [https://www.researchgate.net/publication/2360531\\_A\\_Theoretical\\_Framework\\_for\\_Back-Propagation](https://www.researchgate.net/publication/2360531_A_Theoretical_Framework_for_Back-Propagation)

[13] TSE D, VISWANATH P. Fundamentals of wireless communication [M]. Cambridge: Cambridge University Press, 2005

[14] WANG W, ZHOU C H, HE H L, et al. Cellular traffic load prediction with LSTM and Gaussian process regression [C]//Proceedings of ICC 2020 - 2020 IEEE International Conference on Communications (ICC). IEEE, 2020: 1-6. DOI: 10.1109/ICC40277.2020.9148738

[15] 3GPP. User equipment (UE) radio transmission and reception: 3GPP TS 38.521-3 [S]. 2022


[16] Harvard Dataverse. A multi-source dataset of urban life in the city of Milan and the Province of Trentino Dataverse [EB/OL]. [2023-04-16]. <https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/EGZHFV>

[17] Data World. A user movement trajectory dataset from the Korean academy of science and technology [EB/OL]. [2023-04-16]. <https://data.world/crawdad/human-mobility-data-collected>

#### 作者简介



梁广明, 电子科技大学信息与通信工程学院在读硕士研究生; 主要研究方向为面向移动通信网络的数字孪生、机器学习在无线通信中的应用、数能一体化通信网络等。



杨鲲, 电子科技大学特聘教授、数能网络实验室主任、国家海外高层次人才计划人才、欧洲科学院院士、IEEE Fellow、IET Fellow; 研究领域包括无线通信和网络、未来网络技术以及移动边缘计算等; 发表论文300余篇, 获授权发明专利20余项。



刘强, 电子科技大学长三角研究院(衢州)副教授; 长期从事通信与网络相关的教学和科研工作, 主要研究方向为物联网、无线传感器网络、无线自组织网络、低功耗广域网、分子通信等; 发表论文40余篇。



陈建军, 中兴通讯股份有限公司无线架构工程师; 曾担任中兴通讯5G分布式皮基站产品经理, 负责TD-SCDMA网络组网性能优化、TD-LTE高速组网方案制定; 主要研究方向为下一代无线通信组网架构。