

面向6G无线组网的基于GCN-LSTM网络的业务流量预测算法

孙诗蕾, 徐 澍, 李春国, 杨绿溪

(东南大学移动通信全国重点实验室, 南京 210096)

摘 要: 随着移动通信技术的飞速发展, 无线网络面临着资源分配、流量分析和6G基站优化等多重挑战。对无线网络流量的有效预测, 有助于合理地分配网络资源, 为用户提供更稳定更高效的服务, 保证网络性能。针对目前无线组网流量预测过程中由于时空特征挖掘不充分导致预测准确率较低的问题, 开展了基于深度学习方法的智能业务流量预测算法的研究, 设计了基于图卷积神经网络-长短期记忆网络(Graph convolutional network-Long short-term memory, GCN-LSTM)模型的预测算法。实验结果显示, 该算法在实际网络应用中的准确率为84.71%, 相较于其他基于深度学习的流量预测方法, 具有显著优势, 为6G网络资源的合理分配和高效服务提供了有力支持。

关键词: 无线网络流量预测; 深度学习; 图卷积神经网络; 长短期记忆; 时空特征挖掘

中图分类号: TN929

文献标志码: A

Service Traffic Prediction Algorithm Based on GCN-LSTM Network for 6G Wireless Networking

SUN Shilei, XU Shu, LI Chunguo, YANG Lvxi

(National Mobile Communications Research Laboratory, Southeast University, Nanjing 210096, China)

Abstract: With the rapid development of mobile communication technology, wireless networks are facing multiple challenges, including resource allocation, traffic analysis, and 6G base station optimization. Effective prediction of wireless network traffic helps to allocate network resources reasonably and provides users with more stable and efficient services, ensuring network performance. To solve the problem of low prediction accuracy in the current wireless network traffic predictions due to insufficient mining of spatial and temporal features, this paper conducts research on intelligent traffic prediction algorithms based on deep learning methods, and proposes a prediction algorithm based on graph convolutional network-long short-term memory (GCN-LSTM) model. Experimental results show that the accuracy of this algorithm is 84.71% in actual network applications, which is superior to other deep learning-based traffic prediction methods, providing strong support for the rational allocation of 6G network resources and efficient service.

Key words: wireless network traffic prediction; deep learning; graph convolutional network (GCN); long short-term memory (LSTM); spatial and temporal features mining

基金项目: 国家重点研发计划(2024YFC3807900, 2024YFE0200701); 国家自然科学基金(62171119); 江苏省前沿引领技术基础研究重大项目(BK20222001)。

收稿日期: 2024-05-03; **修订日期:** 2025-02-16

引言

随着6G技术的推广,对无线网络流量数据的深入分析与精准预测成为优化系统配置、高效利用资源、确保网络稳定运行及推动6G网络高效规划与管理的重要基础^[1],对无线通信行业的持续健康发展至关重要。6G技术以其超高的传输速率、超低的时延和极大的连接密度,将为用户提供更加丰富多样的网络服务体验。特别是对于超高清视频、虚拟现实、增强现实等高带宽应用而言,6G技术将带来前所未有的流畅度和沉浸感^[2]。然而,这也将导致基站流量显著增长,对无线网络流量的预测和管理提出了更高的要求^[3]。在此背景下,深入分析并精准预测无线网络流量数据显得尤为重要。无线网络流量的有效预测对于提升移动网络服务质量、优化系统配置和合理利用资源具有重要意义^[4]。通过精确分析和预测无线网络运营数据,服务提供商可以及时发现并解决网络拥塞、故障等问题,确保网络的良好运行状态;同时,准确的流量预测还为6G网络的规划提供了有力支持,有助于合理规划基站的部署和升级策略,提高网络覆盖率和容量利用率;此外,基于流量预测的资源配置优化还可以有效降低能源消耗和运营成本,实现绿色可持续发展。流量预测的核心在于以流量需求为基准,再根据地理分布因素和忙时需求合理地加以调整^[5],而6G网络的技术革新则进一步加剧了流量预测复杂性与精确性的双重挑战。因此,实现高准确度的流量预测,不仅是推动6G网络高效规划与管理的基础,也是确保未来无线通信行业持续健康发展的关键所在。

对于无线网络业务流量的预测,国内外的很多学者都进行了有关研究、分析和建模。移动网络流量数据是一种具有时序性特征的数据,流量预测本质上是一个回归的问题^[6],流量数据每天和每周都表现出一定的周期性和相对平坦的平均值。泊松模型、马尔科夫模型、自回归模型和卡尔曼滤波等传统预测模型,虽然在数据传输量较小、应用较单一的早期移动网络上取得了良好的流量预测效果,但是因其依赖于复杂数学模型和优化算法,当业务数目增加时,在精确性和实用性方面存在局限。支持向量机(Support vector machine, SVM)作为数据驱动算法的杰出代表,已成功应用于网络流量预测^[7],然而,其性能很大程度上依赖于核函数的选择和参数的设置,而且,在复杂网络环境下,数据量巨大,可能会导致SVM模型训练时间过长或计算资源过载^[8]。随着深度学习技术不断成熟,该技术在海量数据处理、特征提取和问题求解方面的优势为网络流量预测提供了有效的新途径,极大地提升了无线网络的适应能力和服务质量^[9]。循环神经网络(Recurrent neural network, RNN)作为深度学习领域早期探索时序数据预测的工具之一,其独特之处在于能够将过往时刻的输出反馈作为后续输入,实现信息的连续传递。然而,在处理长序列数据时,标准RNN常遭遇梯度消失与梯度爆炸的难题,这限制了其应用效能。为解决此瓶颈,Hochreiter等^[10]创新性地提出了长短期记忆(Long short-term memory, LSTM)网络。该网络通过集成输入门、遗忘门及输出门3大组件,精妙地调控信息流,显著增强了模型在处理长序列任务时的性能与稳定性,至今仍被视为解决复杂时序预测问题的优选方案,已广泛应用于交通监控^[11]、金融市场分析^[12]、气象预测以及人体危险行为识别^[13]等多个领域。为进一步优化LSTM的性能,Nihale等^[14]采用特征聚类方法预处理网络流量数据,作为LSTM模型的输入,旨在减少预测误差。针对特征间关联性被忽视的问题,潘成胜等^[15]则提出了一种融合双向LSTM与注意力机制的预测模型,通过双向LSTM捕获数据间的特征关系,并借助注意力机制对特征重要性进行二次评估,双重提取机制显著提升了预测精度与鲁棒性。针对网络流量预测中的小样本挑战,Wan等^[16]设计了基于LSTM与迁移学习结合的模型,利用迁移学习技术将大数据源域知识有效迁移至小样本目标域,显著改善了小样本情境下的预测准确性与模型泛化能力。此外,LSTM的变体如门控循环单元(Gate recurrent unit, GRU)及基于注意力机制的Transformer模型也在网络流量预测领域展现出强大潜力。Sun等^[17]利用GRU结合Salp Swarm优化算法,实现了多域软件定义网络(Software defined network, SDN)流量

预测的超参数自动调优,提高了预测效率与效果。而Kong等^[18]则将Transformer模型引入网络流量预测,利用其自注意力机制有效捕捉流量序列中的长期依赖,进一步推动了预测精度的提升。

当前众多无线网络流量预测方法主要聚焦于孤岛式节点流量预测,尽管这些方法有效利用了数据的时间关联性,却忽视了各基站间的空间相关性。鉴于用户在移动过程中,其无线网络信号连接的基站会随位置变化而发生切换,这实际上表明基站与其邻近基站间存在紧密的联系。因此,本文提出了一种基于图卷积神经网络-长短期记忆(Graph convolutional network-LSTM, GCN-LSTM)网络模型的预测算法,通过图卷积神经网络(Graph convolutional network, GCN)将基站间的相对位置信息加入到LSTM时序预测模型的训练中。具体而言,GCN用于捕捉基站间的空间拓扑结构特征,而LSTM则用于提取时间序列中的长期依赖关系。通过这种结合,模型能够同时考虑时空特征,从而提高预测精度。在GCN部分,本文通过构建基站间的距离矩阵和邻接矩阵,将基站的物理位置关系转化为图结构数据。GCN通过图卷积操作,聚合每个基站及其邻近基站的特征信息,从而捕捉基站间的空间相关性。在LSTM部分,模型通过输入基站的历史流量数据,利用其门控机制(遗忘门、输入门和输出门)来捕捉时间序列中的长期依赖关系。LSTM能够有效处理流量数据中的周期性变化和突发性波动,从而提升预测的准确性。此外,本文还通过引入L2正则化项来防止模型过拟合,并通过AdamW优化器进行参数优化,确保模型在训练过程中能够快速收敛并保持良好的泛化能力。基于PyTorch框架设计对应的仿真实验,验证了该算法的有效性。实验结果表明,GCN-LSTM模型能够有效结合时空特征,显著提升流量预测的准确性。

1 数据集介绍

本文使用的数据集为一个地区内约5 000个基站采集到的连续5天的数据。采集到的原始数据中包括总流量、基站经纬度坐标、无线利用率等在内的38维相关指标。首先对这些原始数据进行预处理,经过数据清洗、箱线图异常值筛选^[19]和数据规格化处理,最终与流量预测强相关的26维数据为小区无线链路控制(Radio link control, RLC)层下行丢包率、媒体接入控制(Media access control, MAC)层上行误块率、MAC层下行误块率、上行混合自动重传请求(Hybrid automatic repeat request, HARQ)重传比率、下行HARQ重传比率、下行双流占比、下行3流占比、下行4流占比、上行正交相移键控(Quadrature phase shift keying, QPSK)编码比例、上行16正交幅度调制(Quadrature amplitude modulation, QAM)编码比例、上行64QAM编码比例、上行256QAM编码比例、下行QPSK编码比例、下行16QAM编码比例、下行64QAM编码比例、下行256QAM编码比例、上行业务信息物理资源块(Physical resource block, PRB)占用率、下行业务信息PRB占用率、上行PRB平均利用率、下行PRB平均利用率、物理下行控制信道(Physical downlink control channel, PDCCH)信道控制信道单元(Control channel element, CCE)占用率、无线利用率、上行每PRB平均吞吐量、下行每PRB平均吞吐量、总流量、基站经纬度坐标。其中,基站经纬度坐标用来描述5 000个基站构成的网络静态拓扑结构,提供用于流量预测的空间相关性信息;每个基站连续5天的总流量以及另外24维指标可以反映多个连续时间片的加权动态网络的演化模式,提供用于流量预测的时间相关性信息。在训练过程中,前4天的数据用于前向预测,然后通过损失函数计算预测流量与第5天的基站流量数值(实测流量数据)之间的差距,进行反向传播。使用均方误差损失函数计算预测流量与实测流量数据之间的差距,同时通过向损失函数中添加L2正则化项来防止模型的过拟合和提高泛化能力,表达式为

$$L(\mathbf{w}) = \frac{1}{2N} \sum_{i=1}^N (y_i - \hat{y}_i(\mathbf{w}))^2 + \lambda \|\mathbf{w}\|^2 \quad (1)$$

式中: N 表示总数据量; y_i 表示第*i*组输入数据对应的实测总流量; $\hat{y}_i(\mathbf{w})$ 表示该组数据对应的

GCN-LSTM网络预测的总流量; $\lambda\|\mathbf{w}\|^2$ 是L2正则化项,用于惩罚较大的权重值,从而减小参数 $\mathbf{w}$ 的范围,对异常值更加鲁棒,减少模型对单个特征的过度依赖,防止模型的过拟合,提高算法的泛化能力; $\|\mathbf{w}\|^2$ 是模型中所有权重的平方和; $\lambda \geq 0$ 是正则化系数,用于控制正则化项的强度, λ 的值越大,正则化作用越强,在本文实验中为 λ 取值为0.01。

2 面向6G无线组网的基于GCN-LSTM网络的业务流量预测算法

本文提出的无线组网业务流量预测算法具体过程如算法1所示。首先,对采集到的原始数据进行预处理,包括数据清洗、箱线图异常值筛选和数据规格化处理。然后对预处理后的数据进行图数据处理,通过构建距离矩阵和调整邻接矩阵权值,使数据适合在图卷积网络中进行训练。然后在合理划分数据集的基础上,采用GCN与LSTM网络的组合模型进行网络流量的智能预测。具体而言,GCN被用来捕捉每个图快照中隐含的拓扑结构特征^[20],以考虑基站流量数据之间的空间相关性,并通过多重非线性变换增强流量预测能力。之后,将GCN学习到的网络表征传递给LSTM网络,以进一步捕捉加权动态网络在时间序列上的演变规律,特别是跨越多个连续时间点的动态特性。这一流程旨在综合空间与时间维度的信息,实现更为精准的无线组网业务流量预测。

算法1 基于GCN-LSTM网络流量预测算法

- (1) // 数据预处理
- (2) 对原始数据进行数据清洗
- (3) 使用箱线图进行异常值筛选
- (4) 对数据进行规格化处理
- (5) 获得数据集:包含5 000个基站连续5天的总流量、基站坐标以及另外24维指标
- (6) // 生成每个基站对应的图数据,包括本基站及距离本基站最近的4个基站的相关数据
- (7) 构建距离矩阵 $D_t \in \mathbf{R}^{5 \times 5}$, $(D_t)_{ij} = (D_t)_{ji}$ 表示基站 i 和基站 j 之间的距离
- (8) 构建邻接矩阵 $A_t \in \mathbf{R}^{5 \times 5}$, $A_t = \begin{cases} 0 & (D_t)_{ij} \geq 600 \text{ m} \\ 600 - (D_t)_{ij} & (D_t)_{ij} \leq 600 \text{ m} \end{cases}$
- (9) 构建特征矩阵 $Z \in \mathbf{R}^{5 \times 24}$,矩阵 Z 的行向量是本基站的24维特征向量
- (10) 初始化GCN网络的参数 $\mathbf{w}^G$,LSTM网络的参数 $\mathbf{w}^L$
- (11) 使用AdamW优化器,初始学习率为0.000 1
- (12) for epoch = 1, 2, ..., 200 do
- (13) for $n = 1, 2, \dots, 5\ 000$ do
- (14) // GCN网络捕捉相邻基站之间的拓扑结构特征
- (15) 每个基站每天对应一个GCN网络,以特征矩阵 Z 为输入,并在其上根据邻接矩阵 A_t 进行定域一阶近似的谱图卷积运算,使用标准的全连接层以生成最终输出24维特征向量 $\mathbf{X}$
- (16) end for
- (17) // LSTM捕获时间序列特征
- (18) LSTM结构包含两个隐含层,总计4个时刻点信息,接收各小区基站的前4天的时间序列数据作为输入,每个时间步的特征向量为 $\mathbf{X}$,预测各基站的第5天的总流量 y
- (19) 根据式(1)计算预测流量与实测流量数据之间的差距 $L(\mathbf{w})$
- (20) 使用优化器最小化 $L(\mathbf{w})$,更新GCN网络参数 $\mathbf{w}^G$ 和LSTM网络参数 $\mathbf{w}^L$

(21) end for

2.1 GCN捕获图拓扑结构特征

GCN是一种专注于图结构数据的处理与分析的深度学习模型。它通过有效地整合图中的结构特征来推导节点的表示,进而支持对图数据的深入理解和学习。GCN的网络结构包括多个图卷积层,每一层都通过邻居节点的信息聚合来更新节点的表示。在流量预测的场景下,一个由多基站构成的无线组网可以被抽象成一个动态图网络 $G=\{G_1, G_2, \dots, G_\tau\}$, 其中 $G_t=(V, E_t, W_t)$ 是时间 t 处的图快照,其中包含节点集 V 、边集 E_t 和权集 W_t 。本文仅考虑无向加权动态网络的情况,且所有时间上的图快照共享节点 V ,利用GCN对动态网络中每个单图快照的局部拓扑结构进行建模。形式上,假设静态图中有 N 个节点,每个具有 M 维特征,拓扑结构和节点属性可分别用邻接矩阵 $A \in \mathbb{R}^{N \times N}$ 和特征矩阵 $Z \in \mathbb{R}^{N \times M}$ 表示(其中 Z 的第 i 行对应节点 i 的特征向量)。典型的GCN单元以特征矩阵 Z 为输入,并根据邻接矩阵 A 进行定域一阶近似的谱图卷积运算,使用标准的全连接层以同样的方式生成最终输出。某一特定GCN单元的整体运作可简述为

$$X = \text{GCN}(Z, A) = f(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{\frac{1}{2}} Z W) \quad (2)$$

式中: X 是GCN单元的输出,代表了更新后的节点表示; Z 是特征矩阵,包含了图中各节点对应的特征向量; A 是邻接矩阵,描述了图中节点之间的连接关系,在本应用场景中,由于考虑的是无向加权图,并且为了包含自环,实际使用的是 $\hat{A} = A + I_N$ (I_N 为 N 维的单位矩阵); $\hat{D}$ 是一个对角矩阵,其对角线上的元素 $\hat{D}_{ii} = \sum_{j=1}^N \hat{A}_{ij}$; $\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{\frac{1}{2}}$ 是对邻接矩阵 $\hat{A}$ 进行归一化处理的结果,有助于在聚合相邻节点信息时保持稳定性;权重矩阵 W 是需要学习的参数,在训练GCN-LSTM模型时,这些参数与LSTM模型中的权重参数都会通过反向传播算法进行更新,以最小化模型输出与真实值之间的误差; f 为修正线性单元(Rectified linear unit, ReLU)激活函数,用于引入非线性,使得模型能够学习复杂的模式。对于考虑多个静态图的时序预测任务,本算法给每个时刻的输入 A_t ($t \in \{\tau-l, \dots, \tau\}$) 进行图卷积计算得到输出向量 $\text{GCN}(Z, A_t) = X_t$, 并将 X_t 作为输入给到LSTM来学习时序数据的长期依赖性,以捕获加权动态网络的演化模式。

在本文中,邻接矩阵 A_t 为各基站的距离矩阵用来描述网络静态拓扑结构,因为基站的选址是不变的,因此各个时刻的 A_t 也是相同的。在无线通信系统中,相对于距离相对较大的基站来说,应该给予彼此相对较近的基站更多的关注。因此,本文为无线网络系统构建了一个距离矩阵 D_t , $(D_t)_{ij} = (D_t)_{ji}$ 表示基站 i 和基站 j 之间的距离,加权网络的链路权重与相应的距离成反比。

$$A_t = \begin{cases} 0 & (D_t)_{ij} \geq \delta \\ \delta - (D_t)_{ij} & (D_t)_{ij} \leq \delta \end{cases} \quad (3)$$

式中:如果两基站距离大于预先设置的阈值 δ ,链路权值设为0。特征矩阵 Z 共5行,代表本基站及距离本基站最近的4个基站,每行的行向量是 A_t 节点的特征向量(24维),诸如有效无线资源控制(Radio resource control, RRC)连接最大数、RRC连接平均数等。

2.2 LSTM捕获时间序列特征

LSTM是一种特殊的RNN,专门用于处理和预测时间序列数据。LSTM单元主要由1个内部状态单元和3个门组成:遗忘门、输入门和输出门。这些门控制着信息的流动,使LSTM能够学习长期依赖关系,并有效地处理梯度消失和梯度爆炸等问题。内部细胞状态单元可以在不同的时间步长上保留或遗忘信息,从而捕获数据中的长期依赖关系,使得LSTM在处理时间序列数据时非常有效。

在本文的 GCN-LSTM 模型中, GCN 网络输出的 24 维特征向量 X 被输入到 LSTM 层中, LSTM 层具有强大的学习序列数据长期依赖关系的能力, 能够捕捉加权动态网络的演变模式。对于特定的时间步 t , LSTM 单元将当前输入向量 X_t 以及上一个时间步的状态向量 h_{t-1} 作为输入, 然后输出当前时间步的状态向量 h_t 。

$$i_t = \sigma(W_X^i X_t + W_h^i h_{t-1} + b^i) \quad (4)$$

$$f_t = \sigma(W_X^f X_t + W_h^f h_{t-1} + b^f) \quad (5)$$

$$o_t = \sigma(W_X^o X_t + W_h^o h_{t-1} + b^o) \quad (6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (7)$$

$$\tilde{C}_t = \tanh(W_X^c X_t + W_h^c h_{t-1} + b^c) \quad (8)$$

$$h_t = o_t \odot \tanh(C_t) \quad (9)$$

式中: i_t, f_t, o_t 和 C_t 分别表示输入门、遗忘门、输出门和记忆单元; $\{W_X, W_h, b\}$ 是相应单元的参数; $\sigma(\cdot)$ 表示 Sigmoid 激活函数; “ $\odot$ ” 表示按元素相乘。最终, 将最后一个状态向量 h 视为历史快照的分布式表示, 并将其输入到一个全连接层以生成预测的总流量。

在考虑 LSTM 网络的输入情况时, 本文将数据样本按小区进行划分, 不同小区的数据被视为不同模型的训练样本, 连续星期内的数据变化被视为时间维度的信息。每个小区包含连续 5 天的数据, 其中前 4 天的数据用于前向预测, 然后通过损失函数计算预测流量与第 5 天的基站流量数值(实测流量数据)之间的差距, 进行反向传播。每天包含 24 个经过 GCN 网络处理后的特征。在应用 LSTM 模型进行流量预测时, 需要将历史流量数据转换成如图 1 所示的三维矩阵形式。

本文所采用的 LSTM 结构包含两个隐含层, 总计 4 个时刻点信息, 如图 2 所示。在时间点 $T=1$ 处, 该网络呈现为一般的反向传播神经网络结构, 在时间点 $T=2$ 处同样呈现类似结构, 沿时间轴展开后, $T=1$ 时刻的隐含层信息将传递至下一时刻 $T=2$, 进而逐步向未来时刻延伸。采用这种建模方式, 有助于研究业务流量及其他数据特征在时间维度上的变化关系, 并挖掘数据特征之间的内在联系。

3 实验结果及分析

3.1 实验过程及相关参数

本实验采用 Python 语言编程, 基于 Pytorch 框架进行仿真。使用的数据集为一个地区内约 5 000 个基站采集到的连续 5 天的 26 维数据, 具体介绍在第 1 节。实验中训练集、验证集和测试集的比例为 7:2:1。在训练过程中, 使用 AdamW 优化器, 初始学习率为 0.000 1,




图1 LSTM网络的输入数据结构

Fig.1 Input data structure of LSTM network




图2 长短期记忆神经网络结构图

Fig.2 Structure of LSTM neural networks

使用带有L2正则化项的均方误差损失函数计算预测流量与实测流量数据之间的差距,正则化强度 λ 为0.01,具体表达式见式(1)。设定对算法准确率的评判流程如算法2所示,每次输入1 024组数据,称为一个Batch。在每一次前向传播之后,可以计算准确率来检验当前网络性能。当网络预测的流量数据与真实流量数据的相对误差满足设定阈值0.3时,认为网络预测正确。相对误差的计算公式为

$$\text{相对误差} = \left| \frac{\text{预测流量} - \text{真实流量}}{\text{真实流量}} \right| \quad (10)$$

预测准确率的计算公式为

$$\text{准确率} = \frac{\text{正确预测样本数}}{\text{总样本数}} \times 100\% \quad (11)$$

算法2 准确率评判算法

- (1) 输入数据:训练集、验证集或测试集的图数据
- (2) 初始化批处理数据量 batch_size = 1 024
- (3) for epoch = 1, 2, ..., 200 do
- (4) 初始化正确预测样本数 correct_count = 0
- (5) 随机选取 batch_size 组数据输入预测网络
- (6) 根据式(10)计算相对误差 relative_error
- (7) if relative_error $\leq$ 0.3 do
- (8) 更新正确预测样本数 correct_count $\leftarrow$ correct_count + 1
- (9) end if
- (10) 计算准确率 accuracy = correct_count/batch_size
- (11) end for

另外,平均绝对误差(Mean absolute error, MAE)也是衡量模型预测性能的一个重要指标。MAE是预测值与真实值之间差异的平均绝对值,计算公式为

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (12)$$

式中: N 表示总数据量; y_i 表示第 i 组输入数据对应的实测总流量; $\hat{y}_i$ 表示该组数据对应的模型预测的总流量。

3.2 流量预测准确率对比和分析

实验1 时序预测算法性能对比

在实验1中,对4种主流时序预测算法进行了性能对比实验,包括RNN、LSTM、GRU以及Transformer。在这4种算法中,选取在小区流量数据集上表现最优的算法,作为流量预测网络中捕获数据时间相关性的结构。

在本实验中,每次输入1 024组数据,一组数据为一个基站连续5天的包括总流量在内的25维相关指标(不包括经纬度坐标);使用AdamW优化器,初始学习率为0.000 1;RNN、LSTM和GRU模型均为4层隐含层,Transformer模型使用8头的4层编码器结构;最后连接一个全连接层输出的预测总流量。将收敛速度、预测准确率、训练MAE和测试MAE共同作为评价指标,各算法的性能如表1及图3所示。

在无线网络流量预测任务中,LSTM和GRU由于具有门控机制,能够较好地处理长期依赖问题,因此在预测准确率上通常优于RNN。而Transformer则通过自注意力机制捕获全局依赖关系,也能取得较高的预测准确率。然而,Transformer的计算量较大,需要更多的计算资源和训练时间。测试MAE

表 1 时序预测算法在训练阶段和测试阶段的性能对比

Table 1 Performance of time series prediction algorithms in the training phase and the testing phase

算法	准确率/%	训练 MAE/(Mb·s ⁻¹)	测试 MAE/(Mb·s ⁻¹)
RNN	75.41	336.219	352.988
LSTM	81.04	315.681	320.081
GRU	77.70	317.092	339.763
Transformer	75.94	343.283	349.357

是评估模型泛化能力的重要指标,LSTM的测试 MAE 最低,表明其在未知数据上的预测性能最好,即泛化能力最强。综合考虑各算法在收敛速度、预测准确率、训练 MAE 和测试 MAE 等方面的表现,应用于流量预测网络中捕获时间相关性的算法选择为 LSTM。实验数据进一步证实了这一结论:LSTM 在流量预测任务中取得了 81.04% 的准确率,并且其训练 MAE 为 313.374 Mb/s,测试 MAE 为 320.081 Mb/s,显示了良好的模型泛化性能和相对较快的收敛速度。

实验 2 链路权重阈值 δ 取值

本文通过式(3)将基站之间的距离转换为 GCN 网络中的链路权重,即邻接矩阵 $\mathbf{A}_t$,其中阈值 δ 的取值与基站的覆盖范围密切相关。按照 3GPP 38.901 中常规的 5G 基站设计模型(如图 4),路径损耗可表示为

$$PL = \begin{cases} PL_1 & 10 \text{ m} \leq d_{2D} \leq d_{BP} \\ PL_2 & d_{BP} \leq d_{2D} \leq 10 \text{ km} \end{cases} \quad (13)$$

$$PL_1 = 20 \lg(40\pi d_{3D} f_c/3) + \min(0.03h^{1.72}, 10) \lg d_{3D} - \min(0.044h^{1.72}, 14.77) + 0.002 \lg(h) d_{3D} \quad (14)$$

$$PL_2 = PL_1(d_{BP}) + 40 \lg(d_{3D}/d_{BP}) \quad (15)$$

式中:分界点距离 $d_{BP} = 2\pi h_{BS} h_{UT} f_c/c$, f_c 为中心频率, $c =$

$3.0 \times 10^8 \text{ m/s}$ 为信号在自由空间内的传播速率, h_{BS} 和 h_{UT} 分别为基站和用户设备的天线实际高度, h 为平均建筑物高度, d_{2D} 和 d_{3D} 分别为基站与用户设备之间的二维距离和三维距离, $d_{3D} = \sqrt{d_{2D}^2 + (h_{BS} - h_{UT})^2}$ 。一般各参数的默认值分别为: $h_{BS} = 35 \text{ m}$, $h_{UT} = 1.5 \text{ m}$, $h = 5 \text{ m}$ 。

如图 5 所示,在不考虑增益的情况下,当基站发射中心频率 $f_c = 2.6 \text{ GHz}$,功率为 53 dBm 的信号时,用户端接收到的信号功率与基站侧发射信号功率比值 P_r/P_t 随着二维距离的增大而不断减小,大致在 $d_{2D} = 500 \text{ m}$ 处逐渐趋近于 0。因此,可推断出一般 5G 基站的覆盖半径 $r \approx 500 \text{ m}$ 。




图 3 时序预测算法性能对比

Fig.3 Performance comparison of time series prediction algorithms




图 4 常规的 5G 基站设计模型

Fig.4 Typical 5G base station design model




图 5 接收功率与发射功率比值曲线图

Fig.5 Receiving power to transmitting power ratio curve

为了确定在本文研究背景下预测准确度最优的阈值 δ ,以100 m为步长,在0.2 $r \sim 4r$ (即100 m~2 000 m)的范围内进行遍历。图6展示了GCN-LSTM网络预测准确度以及收敛速度随阈值 δ 变化的曲线。通过对图6的结果进行分析,发现当 δ 大于0时,GCN-LSTM模型的预测准确率普遍保持在82%以上,显著优于单一的时序预测算法。进一步结合图7中基站距离数据的分布情况以及邻接矩阵 A_i 的稀疏度进行分析,得出以下结论:由于基站距离数据主要集中在400 m以内,当 δ 值小于400 m时,邻接矩阵 A_i 中包含大量权重较小的非零元素,这导致梯度更新的步长减小,从而影响了模型的收敛速度。同时,由于 A_i 的稀疏度较高,模型可能无法充分学习到图中的结构信息和节点特征,进而影响了预测结果的准确性。当 δ 值在400 m至800 m之间时, A_i 中的权重较小的非零元素相对较少,且稀疏度适中。在这种情况下,模型的预测准确率较高且收敛速度较快。特别当 δ 值接近600 m时,模型的预测准确率达到最高值84.71%。然而,当 δ 值大于800 m时, A_i 变得相对稠密,即节点之间存在大量的连接,这可能导致梯度的计算变得复杂,进而影响模型的收敛速度。此外,找到全局最优解或接近全局最优解的点可能变得更加困难,从而在一定程度上降低了模型的预测性能。




图6 预测准确度及收敛速度曲线图

Fig.6 Accuracy and convergence rate curves




图7 数据分布及邻接矩阵稀疏度

Fig.7 Data distribution and the sparsity of adjacency matrix

实验3 消融实验

为验证GCN-LSTM网络相比于传统LSTM网络的优势,进行了一组消融实验,实验结果如图8所示。可以看出,两种网络的收敛速度基本相同,但GCN-LSTM网络在预测准确率上表现出显著的优势。

在训练初期,由于LSTM需要学习的参数相对较少,因此其性能略高于GCN-LSTM,且模型收敛速度相对较快。但是,随着迭代轮次的增加,GCN-LSTM的准确率提升更为显著,这是因为GCN-LSTM结合了图卷积网络和长短期记忆网络的优点,更好地利用数据中的图结构信息,学习到更加复杂和有效的特征表示,从而加速预测准确率的提升。特别是在迭代后期,GCN-LSTM的预测准确率达到84.71%,相较于传统LSTM高出约4%。这一结果表明,在处理具有复杂图形结构信息的序列数据时,GCN-LSTM网络具有更好的建模能力和预测性能。




图8 GCN-LSTM和LSTM的预测准确率对比

Fig.8 Prediction accuracy comparison between GCN-LSTM and LSTM

4 结束语

在总结现有无线网络流量预测方法的基础上,本文针对目前由于时空特征挖掘不充分导致预测准确率较低的问题,提出了一种基于 GCN-LSTM 的无线网络流量预测算法。该算法将 GCN 网络和 LSTM 网络相结合,其中 GCN 捕获基站流量数据之间的空间相关性,通过多重非线性变换的组合提高流量预测性能;LSTM 网络捕获具有多个连续时间片的加权动态网络的演化模式,有效提取了无线网络流量数据的时序特征。实验结果显示,该算法在实际网络应用中的准确率为 84.71%,相较于其他基于深度学习的流量预测方法,具有显著优势,为 6G 网络资源的合理分配和高效服务提供了有力支持。鉴于当前模型训练数据需求庞大且涉及参数繁多,在后续的研究探索中应致力于开发更为精简的模型架构,并减少参数数量,以期在不牺牲性能的前提下,提升预测的准确性。

参考文献:

- [1] HUANG Y, JIN J, LOU M, et al. 6G mobile network requirements and technical feasibility study[J]. *China Communications*, 2022, 19(6): 123-136.
- [2] LIU G, HUANG Y, LI N, et al. Vision, requirements and network architecture of 6G mobile network beyond 2030[J]. *China Communications*, 2020, 17(9): 92-104.
- [3] QADIR Z, LE K N, SAEED N, et al. Towards 6G internet of things: Recent advances, use cases, and open challenges[J]. *ICT Express*, 2023, 9(3): 296-312.
- [4] GAO Y, ZHANG M, CHEN J, et al. Accurate load prediction algorithms assisted with machine learning for network traffic [C]//*Proceedings of the 2021 International Wireless Communications and Mobile Computing(IWCMC)*. Harbin, China: IEEE, 2021: 1683-1688.
- [5] 张可涵, 李红艳, 刘文慧, 等. 面向流量预测的时间相关图卷积网络构建方法[J]. *西安电子科技大学学报*, 2023, 50(5): 11-20.
ZHANG Kehan, LI Hongyan, LIU Wenhui, et al. Construction method of temporal correlation graph convolution network for traffic prediction[J]. *Journal of Xidian University*, 2023, 50(5): 11-20.
- [6] XU F, LIN Y, HUANG J, et al. Big data driven mobile traffic understanding and forecasting: A time series approach[J]. *IEEE Transactions on Services Computing*, 2016, 9(5): 796-805.
- [7] LI Z, YUAN R, GUAN X. Accurate classification of the Internet traffic based on the SVM method[C]//*Proceedings of the 2007 IEEE International Conference on Communications*. Glasgow, UK: IEEE, 2007: 1373-1378.
- [8] 强延飞, 刘雅婷, 王永程, 等. 基于 MAWILab 数据集的短期网络流量预测[J]. *计算机仿真*, 2019, 36(5): 407-411.
JIANG Yanfei, LIU Yating, WANG Yongcheng, et al. Short-term prediction for network traffic based on MAWILab dataset [J]. *Computer Simulation*, 2019, 36(5): 407-411.
- [9] FERREIRA D, REIS A B, SENNA C, et al. A forecasting approach to improve control and management for 5G networks[J]. *IEEE Transactions on Network and Service Management*, 2021, 18(2): 1817-1831.
- [10] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [11] LI J, GUO F, SIVAKUMAR A, et al. Transferability improvement in short-term traffic prediction using stacked LSTM network[J]. *Transportation Research Part C: Emerging Technologies*, 2021, 124: 102977.
- [12] KIM H Y, WON C H. Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models[J]. *Expert Systems with Applications*, 2018, 103: 25-37.
- [13] 高治军, 顾巧瑜, 陈平, 等. 基于 CNN-LSTM 双流融合网络的危险行为识别[J]. *数据采集与处理*, 2023, 38(1): 132-140.
GAO Zhijun, GU Qiaoyu, CHEN Ping, et al. Dangerous behavior recognition based on CNN-LSTM dual-stream fusion network[J]. *Journal of Data Acquisition and Processing*, 2023, 38(1): 132-140.
- [14] NIHALE S, SHARMA S, PARASHAR L, et al. Network traffic prediction using long short-term memory[C]//*Proceedings of the 2020 International Conference on Electronics and Sustainable Communication Systems(ICESC)*. Coimbatore, India: IEEE, 2020: 338-343.

- [15] 潘成胜, 李志祥, 杨雯升, 等. 基于二次特征提取和BiLSTM-Attention的网络流量异常检测方法[J]. 电子与信息学报, 2023, 45(12): 4539-4547.
PAN Chengsheng, LI Zhixiang, YANG Wensheng, et al. Anomaly detection method of network traffic based on secondary feature extraction and BiLSTM-Attention[J]. Journal of Electronics & Information Technology, 2023, 45(12): 4539-4547.
- [16] WAN X, LIU H, XU H, et al. Network traffic prediction based on LSTM and transfer learning[J]. IEEE Access, 2022, 10: 86181-86190.
- [17] SUN W, GUAN S. A GRU-based traffic situation prediction method in multi-domain software defined network[J]. PeerJ Computer Science, 2022, 8: e1011.
- [18] KONG Q, ZHANG X, ZHANG C, et al. Network traffic prediction: Apply the transformer to time series forecasting[J]. Mathematical Problems in Engineering, 2022, 2022: 8424398.
- [19] 顾国庆, 李晓辉. 基于箱线图异常检测的指数加权平滑预测模型[J]. 计算机与现代化, 2021, 1: 28-33.
GU Guoqing, LI Xiaohui. Exponential weighted smoothing prediction model based on abnormal detection of box-plot[J]. Computer and Modernization, 2021, 1: 28-33.
- [20] 杨洋, 王俊峰. 基于GCN的复杂网络关键节点识别研究[J]. 四川大学学报(自然科学版), 2023, 60(3): 55-64.
YANG Yang, WANG Junfeng. Research on key node identification of complex network based on GCN[J]. Journal of Sichuan University (Natural Science Edition), 2023, 60(3): 55-64.

作者简介:



孙诗蕾(1999-),女,硕士研究生,研究方向:无线超低时延超高可靠、人工智能, E-mail: sunshilei@seu.edu.cn。



徐澍(1997-),男,博士研究生,研究方向:无蜂窝、通信感知一体化、信道校准、人工智能。



李春国(1983-),通信作者,男,教授,研究方向:6G蜂窝通信关键技术、基于人工智能的计算机视觉,语音信号处理, E-mail: chun-guoli@seu.edu.cn。



杨绿溪(1964-),男,教授,研究方向:智能信号处理、通信信号处理。

(编辑:陈璐,王婕)