

基于改进 LSTM 的数字媒体网络视频通信流量预测方法

崔 健¹ 张梦榛¹
CUI Jian ZHANG Mengzhen

摘 要

受多源异构环境干扰,数字媒体网络视频通信流量存在大量噪声,不同时间节点的流量特征呈现非线性独立性,常用模型难以捕捉其变化规律,提取自相关特征,导致通信流量预测效果不佳。为此,文章提出一种基于改进 LSTM 的数字媒体网络视频通信流量预测方法。利用小波变换消除原始流量数据中的噪声信号,并基于自相关函数计算不同时间点流量的相关性,结合拓扑图帧映射技术,提取流量数据的自相关性特征。将自相关性特征作为预测模型输入,引入注意力机制为 LSTM 的参数分配权重,建立多因子变量与预测值之间的非线性关系,并利用历史数据对网络模型进行持续参数调优与更新,实现通信流量动态预测。实验结果表明,采用该方法预测数字媒体网络视频通信流量时,所得决定系数均高于 0.8,表明预测值与实测值之间具有较高的拟合度,预测精度较高,应用效果较好。

关键词

改进 LSTM;数字媒体;网络视频通信;流量预测;预测模型

doi: 10.3969/j.issn.1672-9528.2025.06.016

0 引言

随着 5G、物联网和云计算等技术的普及,网络环境变得更加复杂,视频通信流量的波动性和不确定性显著增加,传统的流量预测方法难以应对这种非线性和非平稳性的数据特征,导致预测精度不足,影响网络资源的优化配置和服务质量。在此背景下,研究数字媒体网络视频通信流量预测具有重要的现实意义。首先,精准的流量预测能够帮助网络运

营商和服务提供商更好地规划网络资源,避免带宽浪费或网络拥塞,提升用户体验;其次,通过预测流量的动态变化,可为网络优化、负载均衡和故障预警提供科学依据,增强网络的稳定性和可靠性;最后,高效的流量预测技术还能为新兴应用场景提供技术支撑,推动数字媒体产业的创新发展。

近年来,众多学者针对网络视频通信流量提出了多种预测方法。文献[1]先通过自动编码器融合自注意力与双注意力机制,以减少模型内存开销并提高预测性能,后结合流量变化特征实现流量预测。该方法并未对多源异构环境对数据

1. 黄河水利职业技术大学信息工程学院 河南开封 475001

- [6] 余超群,蔡建国,宋道斌,等.基于快速链路动态感知的多路分流算法[J].无线电通信技术,2023,49(5):979-986.
- [7] 魏文佳.基于MPTCP的多路径传输中的耦合拥塞控制和数据调度机制研究[D].合肥:中国科学技术大学,2020.
- [8] BAHNASSE A, LOUHAB F E, AIT OULAHYANE H, et al. Novel SDN architecture for smart MPLS traffic engineering-diffserv aware management[J]. Future generation computer systems, 2018, 87: 115-126.
- [9] 徐玉华,孙知信.软件定义网络中的异常流量检测研究进展[J].软件学报,2020,31(1):183-207.
- [10] CHANG Y C, LIN H T, CHU H M, et al. Efficient topology discovery for software-defined networks[J]. IEEE transactions on network and service management, 2021,18(2):1375-1388.
- [11] HA S, RHEE I, XU L S, et al. CUBIC: a new TCP-friendly

high-speed TCP variant[J]. ACM SIGOPS operating systems review, 2008, 42(5): 64-74.

- [12] 杨晓.基于Ryu控制器和生成树协议的环路避免系统研究[D].成都:西华大学,2019.

【作者简介】

赵柏山(1980—),男,辽宁铁岭人,博士,副教授,研究方向:信号处理与保密通信。

秦旭升(2000—),男,湖南张家界人,硕士研究生,研究方向:信号处理。

王庆祝(1991—),男,黑龙江五大莲池人,硕士,工程师,研究方向:信号处理与保密通信。

(收稿日期:2025-01-14 修回日期:2025-06-03)

产生的噪声干扰进行处理,且在提取流量变化特征时主要关注时间序列特征,缺乏对空间特征的有效提取,无法明晰流量数据的自相关性特征,模型无法全面捕捉流量数据的动态变化,预测结果不佳。文献[2]通过构建时空图,整合时空特征,实现了对网络流量的预测。此方法能捕获交通数据的局部和全局时空相关性,但同样未对多源异构环境对数据产生的干扰进行处理,流量自相关特征提取不够准确,导致模型无法全面描述流量数据的动态变化,难以得到理想的预测结果。在该背景下,本文提出了一种基于改进 LSTM 的数字媒体网络视频通信流量预测方法。该方法在模型结构优化、特征提取机制方面进行了创新,即采用多尺度特征提取技术,结合小波变换和自相关函数,从原始流量数据中提取出自相似特征,其包括多层次的时间特征和空间特征,增强了模型对复杂流量模式的理解能力;引入注意力机制对传统 LSTM 模型进行了改进,使其能同时捕捉时间序列数据的前向和向后依赖关系,从而更全面地理解流量变化的规律。通过上述,分析视频通信流量的时间依赖性与潜在模式,以实现更准确、更稳定的流量预测。

1 数字媒体网络视频通信流量预测方法

1.1 流量自相关性特征提取

数字媒体网络视频通信流量在传输分布上展现出时间序列的特性,即流量数据在不同时间点间呈现出一定的关联性或模式。为提升预测效果,关键在于识别并提取这些特征,尤其是自相关性特征,这有助于深入理解流量的动态行为。在多源异构网络环境下,网络设备的异构性、数据传输的随机性、用户行为的多样性以及外部环境的干扰导致原始流量数据中包含大量噪声,这些噪声会干扰自相关性特征的提取。因此,本次先采用小波变换方法对原始流量数据进行多尺度变换,有效滤除噪声信号,该处理过程可表示为:

$$w_d = \left(a_0 - \beta / \exp \left(\frac{|X| - \beta}{N} \right) \right) \quad (1)$$

$$X = f(t) + \eta \cdot n \quad (2)$$

式中: a_0 表示流量中的噪声水平; β 表示负荷平均值正态分布的过程残差值; X 表示空间权重系数; N 表示流量数据点数量; w_d 表示小波系数; $f(t)$ 表示第 t 时间单位的流量; η 表示滤除阈值; n 表示相关值向量。

完成流量数据降噪处理后,将其整理为时间序列,采用自相关函数计算时间序列中不同时间点之间的相关性^[3]。公式为:

$$r(j, k) = \frac{E[(x_t - \mu)(x_{t+1} - \mu)]}{w_d E[(x_t - \mu)^2]} \quad (3)$$

式中: x_t 表示 t 时刻网络流量的样本数; μ 表示时间序列的均值; x_{t+k} 表示下一时刻的流量样本数; $E[\cdot]$ 表示序列期望; $r(j, k)$ 表示时间点 j 和 k 对应的流量数据的相关性。

为进一步直观展现不同时间点之间流量数据的相关性和趋势,本次构建了图形结构如图 1 所示。




图 1 流量数据相关性图谱

在此结构中,每个节点代表一个特定的时间点,节点之间的边反映了这些时间点之间数据的相关性。通过分析节点之间的连接模式和图结构中边的权重分布,识别出流量数据的自相关性特征 V ,具体过程为:

$$\mathbf{G} = \sum_{i=1}^N \sum_{j=1}^N w_{ij} \mathbf{v}_i \mathbf{v}_j^T \quad (4)$$

$$V = \arg \max \log PG \cdot r(j, k)^c \quad (5)$$

式中: $\mathbf{G}$ 代表图信号矩阵; w_{ij} 代表节点 i 和节点 j 之间的边权重; $\mathbf{v}_i$ 、 $\mathbf{v}_j$ 代表节点 i 和节点 j 的特征向量; P 表示时间序列的方差; c 表示时间常数。

综上,消除原始流量数据中的噪声,提取了通信流量的自相关性特征,以为后续构建网络视频通信流量预测模型提供条件。

1.2 基于改进 LSTM 构建通信流量预测模型

完成流量自相关性特征提取可以帮助人们理解流量的长时依赖性和突发性,接下来,以提取的流量自相关特征为基础,完成通信流量预测模型构建。网络视频通信流量受到用户行为、时间段、视频内容等多种因素的影响,展现出时间依赖性以及复杂的空间特征,在处理这种高度动态和非线性的流量数据时,传统 LSTM 模型难以有效捕捉这些空间特征,因此容易出现过拟合问题,导致模型的泛化能力下降。为此,将自相关性特征作为预测模型输入,并引入了注意力机制改进 LSTM,并基于改进 LSTM 构建通信流量预测模型。

LSTM 遗忘门、输入门和输出门的表达式^[4]分别为:

$$f_0 = \delta(W_0 h_{t-1} + U_0 + b_0) \quad (6)$$

$$f_1 = \delta(W_1 h_{t-1} + U_1 + b_1) \quad (7)$$

$$f_2 = \tan \delta(W_2 h_{t-1} + U_2 + b_2) \quad (8)$$

式中: δ 表示流量分片的时间步长; W_0 、 W_1 、 W_2 分别表示遗忘门、输入门和输出门当前时刻的输入值; h_{t-1} 表示前一刻

网络的偏置项； U_0 、 U_1 、 U_2 分别表示遗忘门、输入门和输出门的激励函数； b_0 、 b_1 、 b_2 均表示利用有效变换函数确定的候选值； f_0 、 f_1 、 f_2 分别表示遗忘门、输入门和输出门的序列状态表达式。

为建立多因子变量与预测值之间的非线性关系，改进网络结构，增强模型的拟合度^[5]，引入注意力机制对 LSTM 的参数进行权重赋值，其计算公式为：

$$L = -f_0 \log(y_q) - V(1 - f_1) \cdot \log(1 - f_2)$$

(9)

式中： y_q 表示模型平方梯度的指数衰减平均值； V 表示流量序列的自相关性特征； L 表示网络模型注意力分配系数。

将注意力机制与 LSTM 结合，改进后的 LSTM 模型能够更好地捕捉流量数据的动态变化，其表达式为：

$$h_t = f_0 f_1 f_2(x_t, h_{t-1}) \cdot L$$

(10)

式中： h_t 表示时刻 t 的隐藏状态； x_t 表示时刻 t 的输入； h_{t-1} 表示前一时刻的隐藏状态。

通过引入注意力机制，模型能够动态调整对不同时间的关注程度，更好地捕捉流量数据的复杂特性^[6-8]。该模型训练过程中，利用反向传播算法更新网络模型的权重和偏差值，结合历史数据不断进行参数调优与更新，得到输出门值的权重 ϖ ，其表达式为：

$$\varpi = \lambda(D_0[L, K] + d) \cdot \tan h_t(\vartheta)$$

(11)

式中： λ 表示均方根误差； D_0 表示模型阶数； K 表示模型损失函数； d 表示滞后变量； ϑ 表示误差系数。

通过不断优化参数，模型能够更好地拟合数据，提升预测精度。此外，为进一步提升其精度，使用均方根误差作为损失函数，其计算公式为：

$$\lambda = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

(12)

式中： y_i 表示实际值； $\hat{y}_i$ 表示预测值； N 表示样本数量。

完成改进 LSTM 通信流量预测模型构建后，以上文提取的自相关性特征 V 为输入，捕捉流量数据的动态变化^[9-10]，生成准确的预测结果，预测表达式为：

$$\hat{y}_t = \varpi \cdot h_t + b_y$$

(13)

式中： $\hat{y}_t$ 是预测值； b_y 是输出层的偏置项。

综上，完成数字媒体网络视频通信流量预测设计。

2 实例论证分析

2.1 实验准备

本文通过监控网络流量和抓取视频传输数据包的方式从实际的网络环境中获取大量的视频流量数据，具体包括以 1 min 时间间隔采样的历史流量数据、用户行为数据以及网络特征数据。该数据集大小约为 10 GB，包含数百万个数据

点，时长为 1~10 min 不等，涵盖了不同的时间段和各种网络环境。预处理后，将其转化为标准视频测试序列，以此对提出的方法进行验证。原始网络视频流量的分布参数如表 1 所示。

表 1 网络视频通信流量分布参数

参数	数据
视频分辨率	1 080 P
视频帧率	25 帧/s
视频比特率（码率）	3 500 kbit/s
用户数量	100 人
总带宽需求	1 260 Gbit/s
音频比特率	128 kbit/s
网络延迟	50 ms

实验硬件环境包括服务器、Catalyst 9300 千兆以太网交换机和路由器；软件环境包括 Ubuntu 20.04 LTS 操作系统和 scikit-learn 学习库以及 Catalyst 9300 可视化工具，以构建和训练 LSTM 模型和绘制数据曲线与模型预测结果。实验平台使用本地服务器进行模型训练和评估，借助阿里云进行大规模数据集处理和模型部署。另外，本地服务器通过 SSH 连接进行管理，以确保实验环境的独立性和安全性。

基于表 1 所示的网络视频通信流量分布参数，提取流量数据间的序列自相关性特征，并以此构建 LSTM 预测模型，该模型参数配置如表 2 所示。以此为基础实验过程为：（1）使用网络流量监控方法收集流量数据，并使用 Pandas 进行数据清理和预处理，包括缺失值处理、特征缩放等；（2）在 TensorFlow 中构建一个改进的 LSTM 模型，引入注意力机制来提高模型性能；（3）使用训练集训练模型，并通过调整学习率和批量大小等参数来优化其性能；（4）根据评估结果调整模型参数和架构，并在测试集上评估最终模型，以确保其在实际应用中的性能。

表 2 LATM 预测模型参数配置

参数	取值
输入特征的维度	26
隐藏层的特征数量	128
LSTM 堆叠的层数	2
学习率	0.001
列长度	100
批处理大小	32
训练轮数	20
输入层大小	50
时间窗口大小	5 min

2.2 网络视频通信流量预测结果

为直观展示提出网络视频通信流量预测方法的准确度,采用文献[1]基于深度学习的预测方法(方法1)和文献[2]基于时空融合的预测方法(方法2)与本文方法进行对比。基于历史流量数据,分别采用3种方法对该网络通信系统的实时视频流量进行预测,得到结果如图2所示。




图2 网络视频通信流量预测结果

从图2中可以看出,与本文方法相比,对照组方法预测的流量值与实测值之间存在较大误差,表明其在预测网络视频通信流量时存在一定的不准确。这主要是由于网络视频通信流量具有复杂的非线性特征,而对照组方法无法有效捕捉这些特征,导致预测结果与实际值偏差显著。相比之下,本方法在不同时刻的预测值与实际值基本拟合,证明了其更高的预测精度。分析原因可知,本文方法通过动态分配权重、注意力机制使模型能够聚焦于对预测结果影响更大的特征,从而更准确地捕捉流量的非线性变化,因此预测精度较高。

为定量分析对照组方法与本文方法的预测性能,采用决定系数 R^2 来衡量网络视频通信流量预测值与实际值之间差异。 R^2 越接近于1,预测值与实测值的拟合程度越高,预测精度也就越高。通过测试,得到对比结果如图3所示。




图3 基于不同预测方法的决定系数对比结果

根据图3可以看出,应用本文方法进行网络视频通信流量预测,在100~800测试样本数量条件下,得到的决定系数均在0.8以上,表明本文方法在预测网络视频通信流量时具有更高的准确性,能够更好地捕捉流量的变化趋势。而对照组方法的决定系数普遍较低,表明预测值与实测值之间存在

一定的偏差,整体预测效果较差。由此可充分说明本方法在网络视频通信流量预测精度方面的优异性能。分析原因可知,由于本文方法引入了注意力机制,使流量预测模型能智能地为不同输入特征分配权重,从而更精确地捕捉影响流量的关键因素,提升预测准确度。

3 结语

为实现对数字媒体网络视频通信流量的高精度预测,提升模型的预测性能和鲁棒性,本研究通过引入改进LSTM算法,结合流量自相关性特征的提取与模型构建,成功实现了对数字媒体网络视频通信流量的高精度预测。该方法的应用能够为网络服务提供商提供有力的数据支持,帮助其制定更为科学的流量管理策略,进而优化网络资源分配,保障视频通信的流畅与稳定。此外,该方法还为智能网络管理提供坚实的理论与实践指导,对于推动数字媒体技术的进步及提升用户体验具有重要意义。

参考文献:

- [1] 刘洋,廉咪咪.基于深度学习的移动通信网络流量预测方法研究[J].长江信息通信,2024,37(2):90-92.
- [2] 罗永华,王敏竹,宁芊.基于时空融合的网络流量预测模型研究[J].现代计算机,2023,29(6):60-65.
- [3] 熊志华.基于大数据分析的灌区配水渠道流量预测分析研究[J].陕西水利,2024(4):90-91.
- [4] 王波,卫培培.基于蚁群算法的通信网络流量分析[J].长江信息通信,2023,36(3):103-106.
- [5] 林尚静,马冀,李月颖,等.基于个性化联邦学习的无线通信流量预测[J].电子科技大学学报,2023,52(1):64-73.
- [6] 高跃衡,张艳,石尚轩,等.基于双向门控循环单元的通信基站流量预测研究[J].软件导刊,2022,21(6):176-182.
- [7] 林尚静,马冀,庄排,等.基于联邦学习的无线通信流量预测[J].计算机应用,2023,43(6):1900-1909.
- [8] 赵巍.基于改进长短时记忆神经网络的5G通信网络流量预测[J].沈阳工业大学学报,2022,44(6):672-676.
- [9] 惠聪.基于流量预测的5G通信网络资源分配方法[J].信息技术,2023(7):71-76.
- [10] 李兵.基于改进BPNN的5G通信网络流量预测[J].通信电源技术,2024,41(1):203-205.

【作者简介】

崔健(1994—),男,山东曹县人,本科,助教,研究方向:数字媒体。

张梦榛(1996—),女,河南郑州人,硕士,助教,研究方向:人工智能。

(收稿日期:2025-03-04 修回日期:2025-06-10)