



5G 核心网业务模型的智能化预测研究

冯楠¹, 刘贺林¹, 周泉¹, 杨海俊¹, 付蜜能², 钟大平¹

(1. 中国移动通信有限公司研究院, 北京 100053;

2. 中国移动通信集团有限公司, 北京 100032)

摘要: 核心网业务模型的建立是 5G 网络容量规划和网络建设的基础, 通过现有方法得到的理论业务模型是静态不可变的且与实际网络存在偏离。为了克服现有 5G 核心网业务模型与现网模型适配性较差以及规划设备无法满足用户实际业务需求的问题, 提出了一种长短期记忆(long short-term memory, LSTM)网络与卷积 LSTM(convolution LSTM, ConvLSTM)网络双通道融合的 5G 核心网业务模型预测方法。该方法基于人工智能(artificial intelligence, AI)技术以实现高质量的核心网业务模型的智能预测, 形成数据反馈闭环, 实现网络自优化调整, 助力网络智能化建设。

关键词: 核心网业务模型; 5G; LSTM; ConvLSTM; 网络智能化

中图分类号: TN915

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2022046

Research on 5G core network service model intelligent prediction

FENG Nan¹, LIU Helin¹, ZHOU Quan¹, YANG Haijun¹, FU Mineng², ZHONG Daping¹

1. China Mobile Research Institute, Beijing 100053, China

2. China Mobile Communications Co., Ltd., Beijing 100032, China

Abstract: The establishment of core network service model is the basis of 5G network capacity planning and network construction. The theoretical service models obtained by the existing methods are static and immutable, and deviate from the actual network. In order to overcome the problems that the existing 5G core network service model is poorly adapted to the existing network model and the planned equipment cannot meet the actual service needs of users, a 5G core network service model prediction method based on the dual-channel fusion of long short-term memory (LSTM) and convolutional LSTM (ConvLSTM) network was proposed. The method can achieve intelligent prediction of high-quality core network service model based on artificial intelligence (AI) to form a data feedback closed loop. It can promote network self-optimization and help network intelligence.

Key words: core network service model, 5G, LSTM, ConvLSTM, network intelligence

0 引言

当前, 5G 商用部署持续推进, 5G 将步入商

业化应用的快车道。具有“大带宽、广连接、低时延”技术特性的 5G 催生 5G 终端和新应用、新场景的涌现, 促进超高清视频、云游戏、VR/AR、



物联网、车联网、工业互联网等领域快速发展,从而导致来自各行各业不同领域的移动智能通信设备数量以及移动数据流量呈现爆炸式增长^[1]。据统计,2021年前7个月国内移动互联网累计使用数据流量1 228亿GB,同比增长38.1%^[2]。在这种环境下,数据通信以及多媒体业务已远超传统业务,成为5G移动通信网中最主要的承载业务。为了承载激增的数据流量,满足数据密集型服务扩张的需求,5G网络中用以承载数据业务的分组域核心网设备数量急剧增加,新一轮5G核心网建设将迎来高潮。

在核心网建设过程中,分组业务模型的研究是非常必要的。一方面,业务模型是形成网络建设规模的基础。5G核心网建设部署需要依赖国内运营商拟定的5G网络业务模型。运营商通过建立行之有效的业务模型,统计并预测业务量的现状和未来发展方向,为后期网络建设提供更好的容量规划以及延展性,进而提升运营商的网络智能化核心能力;另一方面,业务模型是影响设备硬件处理能力的重要因素之一。网络功能虚拟化(network functions virtualization, NFV)是未来网络发展的重要趋势,进行NFV后,相同配置条件下的硬件处理能力主要取决于业务模型,不同的业务模型往往会导致相同配置条件下的硬件处理能力拥有较大差别^[3-6]。因此,随着5G核心网建设部署节奏的加快,关于5G核心网业务模型的研究也成为当下重中之重的课题。

针对现有核心网业务模型的建模与规划问题,工业界主要基于国内运营商网络建设经验结合实验室数据确定业务模型的关键参数,参数主要包括附着激活比、寻呼次数、鉴权服务器功能(authentication server function, AUSF)鉴权次数等^[7-9];学术界则通过曲线拟合法分析和预测分组域业务模型,该方法基于历史数据,根据其发展规律构建线性曲线、二次曲线、指数曲线以及幂乘曲线等数学拟合曲线,寻求某两个变量或多个

变量之间的合理关系,进而对未来的业务趋势和数据进行预测^[10-12]。

本文认为业务模型参数的取定需要依赖于5G SA各网元侧业务量的统计结果,且会根据现网业务的波动情况实时调整。这是由于业务模型各参数取值由每小时对应参数的业务量总和/注册用户数/3 600所得,故现网业务波动使业务模型各参数的取值不同。通过现有方法得到的理论业务模型是静态不可变的,且缺乏符合各地市网络特征(由于地区经济发展,用户人口结构、定制功能要求、组网等差异造成的与移动性管理及会话管理相关的业务模型参数特征)的业务分析与预测手段,理论业务模型与实际网络存在偏离,从而使5G网络容量规划与实际业务发展不匹配、规划设备不能满足或远大于用户实际业务需求,造成网络负载过大或资源利用率过低。

为了克服现有5G网络业务模型与现网模型适配性较差以及规划设备无法满足用户实际业务需求的痛点,及时制定网络预优化策略,确保网络覆盖以及满足容量需求,本文提出了一种基于“AI+大数据”的5G核心网业务模型的动态预测方法。该方法通过现网网管大数据采集、数据分析、构建长短期记忆(long short-term memory, LSTM)网络与卷积LSTM(convolution LSTM, ConvLSTM)网络双通道数据特征提取融合学习网络,对未来网络的运行参数和容量进行预测,根据预测结果进行决策反馈,以优化网络结构,实现网络自动部署,使能5G网络智能化。经验证,本文提出的LSTM与ConvLSTM的融合预测模型可用于15 min、1 h、1天多维度时间粒度指标数据的多步预测,且预测精度较高。

1 5G核心网业务模型

1.1 业务模型参数构成

当前,5G核心网业务模型主要由网元配置要求、用户面(吞吐量)、用户数以及控制面(信令)4类参数组成。

(1) 网元配置要求

网元配置要求主要包括接入和移动性管理功能 (access and mobility management function, AMF) 接入的 5G 节点 (5G node, gNode) 数、每定时提前量 (timing advance, TA) 下的 gNode 数、每用户协议数据单元 (protocol data unit, PDU) 会话数、每会话支持服务质量 (quality of service, QoS) 流等。

(2) 用户面 (吞吐量)

吞吐量参数主要包括 5G PDU 会话数、N3/N6/N9 接口流量等。

(3) 用户数

用户数参数主要包括注册用户数、5G 接入用户数、5G 手机长期演进语音 (voice over long-term evolution, VoLTE) 用户签约比等。

(4) 控制面 (信令)

信令参数可进一步细分为业务信令参数和移动性管理信令参数。

业务信令参数与用户使用业务行为相关, 主要包括忙时平均每用户初始注册/去注册次数、鉴权次数、忙时平均每用户 PDU 会话建立/修改/释放次数、周期性注册更新次数、忙时平均每用户接入网 (access network, AN) 释放/业务请求/寻呼次数等。

移动性管理信令参数与用户移动性相关, 主要包括忙时平均每用户 AMF 内/间移动引起的注册更新、忙时平均每用户系统内 Xn 接口/N2 接口切换次数、忙时平均每用户 4G/5G 系统间基于 N26 接口的切换次数、忙时平均每用户 4G/5G 空

闲态移动切换次数。

1.2 业务模型参数特征

随着 5G 网络建设的加速, 未来 5G 用户数普遍以当前 LTE 用户升级而来。故而未来一段时间内, 5G 用户数呈现稳步增长的趋势。现网中 A 省与 B 省 5G 注册用户数如图 1 所示。A 省、B 省 10 月 5G 注册用户数比 2 月分别增长 242%、976%。当前工程建设和基于此开展的性能测试中, 均采用单一业务模型。而核心网中信令参数以及吞吐量参数的产生, 主要成因在于用户使用业务行为、用户移动性行为, 除此之外还与网络规划组织以及签约业务等相关, 而用户行为普遍受不同省市经济发展差异、用户人口结构差异、地区组网差异等因素的影响。故单一业务模型难以覆盖现网多样差异化场景。A、B 两省部分话务模型参数对比见表 1。以 A、B 两省为例, B 省忙时平均每用户 AMF 内 N2 接口切换次数比 A 省低 60.5%, B 省忙时平均每用户 AN 释放次数比 A 省高 16.21%。结果表明各省市业务模型会呈现多元化差异。




图 1 现网中 A 省与 B 省 5G 注册用户数

由于用户在一段时间内的行程或使用移动网络上网的行为相对规律, 个人用户行为在一段时

表 1 A、B 两省部分话务模型参数对比

参数类别	参数类型	话务模型	
		A 省	B 省
移动性管理信令参数	AMF 内移动引起的注册更新	3.782 410 50	2.257 466 72
	忙时平均每用户系统内 Xn 接口切换次数	12.163 17	22.339 45
	忙时平均每用户 AMF 内 N2 接口切换次数	4.412 468	1.741 47
业务信令参数	忙时平均每用户 AN 释放次数	28.620 82	33.260 66
	忙时平均每用户 PDU 会话修改次数	2.248 356	0.701 742



间内是存在规律性和延续性的,例如,一个外卖送餐小哥每日在 11:00—20:00 的行为可以概括为“送餐—接单—送餐—接单—……”,该行为循环往复,对网络层面的触发也存在一定的规律,即“AN 释放—业务请求—AN 释放—业务请求—……”。类似地,以上班族为例,大部分上班族在工作日的 7:00—9:00、17:00—20:00(上下班路上)会打开手机流量开关浏览网页或追剧,故而工作日该时间段用户面吞吐量相对其他时间段偏高。所以可以认为核心网中的控制面信令和用户面吞吐量也是存在同样的规律性和延续性。而业务模型预测的前提是一段时期内数据之间是存在时间相关性的。所以本文认为可以通过用户行为的历史数据分析、叠加从而对网络中的业务模型参数进行一定的周期预测分析。A 省单资源池 7—8 月忙时平均每用户业务请求次数如图 2 所示,该信令参数在时间上呈周期震荡趋势,具有统计规律。因此,业务模型预测可以看作时间序列预测任务。




图2 A 省单资源池 7—8 月忙时平均每用户业务请求次数

2 5G 核心网业务模型智能化预测

2.1 LSTM 与 ConvLSTM 融合预测模型

由于核心网业务模型对应各参数在时间上具有统计规律,因此,核心网业务模型预测可以看作时间序列预测任务。在时间序列预测任务中,LSTM 擅长提取长时序特征,而卷积神经网络(convolutional neural network, CNN)在短时序特征提取上更有优势^[13-16]。本文提出使用 LSTM 与基于 CNN 的卷积 LSTM 模型 ConvLSTM 双通道

融合预测模型来对业务模型指标进行预测,通过该双通道融合预测模型,可以尽可能挖掘时间序列中隐藏的特征信息,这些特征同时包含了长时序和短时序两类特征。

2.1.1 LSTM 网络模型

早期,时间序列建模主要采用回归模型、自回归滑动平均模型(auto-regressive moving average model, ARMA)、差分自回归滑动平均模型(auto-regressive integrated moving average model, ARIMA)。ARMA 和 ARIMA 常用于周期性平稳序列预测,对历史数据要求较高^[17-19]。随着深度学习的发展,大部分研究人员通过循环神经网络(recurrent neural network, RNN)对时间序列建模,以提高在数据趋势预测中的准确性。RNN 在许多领域都有较好的表现^[20]。但 RNN 每一个输入值均只与其自身的路线建立权连接,不会与其他神经元连接,这样的结构缺陷会导致历史信息在反向传播中丢失,导致梯度消失和梯度爆炸现象的出现。为了解决 RNN 的弊端,LSTM 被提出。LSTM 和 RNN 的不同之处在于,LSTM 在隐藏层中使用了 3 个门控单元,分别为输入门、遗忘门和输出门,用来更新或丢弃历史信息,以控制历史信息的流动,这也使 LSTM 更擅长应对时间序列预测任务^[21-22]。LSTM 网络结构如图 3 所示。其中, σ 、 $\otimes$ 、 $\oplus$ 分别表示 sigmoid 函数、两个相同维度对应元素的乘积组成新的向量、两个相同维度对应元素求和组成新的向量,对数据信息进行过滤运算和叠加运算。




图3 LSTM 网络结构

假设一个时间序列 $X = \{x_1, x_2, x_3, \dots, x_n\}$, $x_1, x_2, x_3, \dots, x_n$ 表示每一个时间点,其中包含该时

间点的特征信息。

对于 LSTM 块中遗忘门 f_t ，通过 Sigmoid 函数激活上一层隐状态 h_{t-1} 和当前输入状态 x_t ，该激活值在 $[0,1]$ 。遗忘门计算式如式 (1) 所示。

$$f_t = \sigma(W_f \times h_{t-1} + W_{f'} \times x_t + b_f) \quad (1)$$

对于 LSTM 块中的输入门 i_t ，则是控制当前层哪些信息作为新增记忆 $\tilde{C}$ 加入当前记忆状态 C_t ， i_t 同样由 Sigmoid 函数激活上一层隐状态 h_{t-1} 和当前输入状态 x_t 生成，但权重与 f_t 的权重不同。输入门计算式如式 (2)、式 (3) 所示。

$$i_t = \sigma(W_i \times h_{t-1} + W_{i'} \times x_t + b_i) \quad (2)$$

$$\tilde{C} = \tanh(W_c \times h_{t-1} + W_{c'} \times x_t + b_c) \quad (3)$$

记忆状态更新是通过 f_t 控制的上一层历史记忆状态 C_{t-1} 与 i_t 控制的新增记忆 $\tilde{C}$ 共同生成当前记忆状态 C_t ，如式 (4) 所示。

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C} \quad (4)$$

对于 LSTM 块中输出门 o_t ，则是输出当前层的隐状态 h_t ，该隐状态由 $\tanh$ 函数激活记忆状态 C_t 生成。输出门计算式如式 (5)、式 (6) 所示。

$$o_t = \sigma(W_o \times h_{t-1} + W_{o'} \times x_t + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

在模型训练结束后，除了隐藏状态会记忆一部分历史信息，记忆状态还会记忆整个序列的高维隐信息，如序列的变化率、衰减率等信息。

2.1.2 ConvLSTM 网络模型

ConvLSTM 网络可以较好地提取时间序列任务中的短时序特征。ConvLSTM 网络模型主要通过卷积层对时序中的权值进行计算，将时序图中

的特征提取出来，并且通过将上一层的输出当作下一层 LSTM 层的输入提取静态时序图的短时序特征。ConvLSTM 网络的主要计算式如式 (7) ~ 式 (11) 所示。

$$i_t = \sigma(W_{xi} * x_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i) \quad (7)$$

$$f_t = \sigma(W_{xf} * x_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f) \quad (8)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tanh(W_{wc} * x_t + W_{hc} * H_{t-1} + b_c) \quad (9)$$

$$o_t = \sigma(W_{xo} * x_t + W_{ho} * H_{t-1} + W_{co} \circ C_t + b_o) \quad (10)$$

$$H_t = o_t \circ \tanh(C_t) \quad (11)$$

其中， $*$ 表示卷积运算， $\circ$ 表示 Hadamard 乘积。

2.1.3 双通道融合

针对 LSTM 以及 ConvLSTM 模型在时间序列提取方面的特点，本文提出了使用 LSTM 与 ConvLSTM 双通道融合预测模型来对业务模型指标进行预测。ConvLSTM 与 LSTM 双通道融合网络结构如图 4 所示。LSTM 与 ConvLSTM 输入相同的数据源，但 LSTM 通道提取时间序列的长时序特征，输出长时序特征张量 $P_1 = \{h_1, h_2, \dots, h_k\}$ ；ConvLSTM 通道提取时间序列的短时序特征，输出短时序特征张量 $P_2 = \{h'_1, h'_2, \dots, h'_k\}$ 。其中，为了平衡两通道所提取特征对最终测试结果的影响，需要保证 P_1 与 P_2 的维度相同，均为 k ，最后将两通道经提取的时间特征张量拼接，得到一个维度为 $2k$ 的张量 P ，如式 (12) 所示。

$$P = \{P_1, P_2\} = \{h_1, h_2, \dots, h_k, h'_1, h'_2, \dots, h'_k\} \quad (12)$$

最后将张量 P 输入全连接网络层 (Dense)，将张量进行维度变换，从而得到预测结果。

与上述提到的 LSTM 与 ConvLSTM 神经网络不同的是，LSTM 与 ConvLSTM 双通道融合预测




图4 ConvLSTM 与 LSTM 双通道融合网络结构



模型分别通过 LSTM 模型提取时间序列的长时序特征,通过 ConvLSTM 提供时间序列的短时序特征,将两通道提取的特征进行向量拼接融合作为一个整体再输入全连接网络层中,而 LSTM 或 ConvLSTM 均通过对应模型提取时间序列特征,随后将特征直接输入全连接网络层进行输出。

2.2 实验分析

2.2.1 数据集

通过采集现网业务统计数据得到原始性能数据,包含 5G SA 网元 (AMF、SMF、PCF、UDM、NRF、UPF、CHF 等) 各项性能统计指标及虚拟池位置信息,单网元相关性能统计存为单个数据表,数据周期为 2021 年 1 月—8 月的 8 个月,采样的时间间隔为 15 s,其中,前 80% 的数据序列用于训练数据,后 20% 的数据用于测试数据。本文使用平均绝对百分比误差 (mean absolute percent error, MAPE) 衡量模型的优劣^[23]。MAPE 用来衡量评估预测值的准确程度,MAPE 是相对值,不是绝对值,MAPE 越小,说明模型预测准确度越高。

2.2.2 实验配置

本文提出的 LSTM 与 ConvLSTM 融合预测模型经多次实验验证,LSTM 与 ConvLSTM 融合预测模型配置见表 2。LSTM 通道与 ConvLSTM 通道中的 LSTM 层互相独立,且两通道的输出维度相同,以平衡两通道所提取特征对最终测试结果的影响。

表 2 LSTM 与 ConvLSTM 融合预测模型配置

通道	网络层	参数
LSTM 通道	LSTM	隐藏层: 38
	Dropout	丢失率: 20%
	全连接 (full connection, FC)	输出维度: 36×4, 激活函数: elu
ConvLSTM 通道	ConvLSTM2D	filters=30, kernel_size=(1,3)
	LSTM	隐藏层: 38
	FC	输出维度: 36×4, 激活函数: elu
融合通道	FC	输出维度: 36×2
	FC	输出维度: 1~6

2.2.3 实验结果

基准算法结果对比如图 5 所示,对比了 15 min 粒度下,传统时间序列模型 S-ARIMA、LSTM 与本文提出的 LSTM 与 ConvLSTM 融合预测模型的初始注册 (amf_attinitreg)、寻呼 (amf_pagatt)、鉴权 (amf_auth)、周期性注册更新 (amf_regupdreql)、服务请求 (amf_attservicereq) 多个业务指标单步预测的 MAPE 值。一般而言,本文认为当 MAPE<10% 时,该预测模型质量较高,可利用该模型进行具体应用场景和具体数据集的后续预测。由图 5 可知,针对 15 min 小颗粒度业务指标,3 种模型均可达到较好的业务模型指标预测效果,但融合预测模型由于 LSTM 通道与 ConvLSTM 通道在数据特征提取方面的优势互补,因此,融合预测模型在整体业务指标的预测上更稳定、更准确,多指标的 MAPE 值均保持在 5% 以下。




图 5 基准算法结果对比

1 h 粒度各指标预测值所属区间统计见表 3,其为 1 h 粒度下,5G SA 网元的共计 22 个业务模型对应信令指标单步预测的 MAPE 值所属范围区间个数统计。22 个指标通过使用融合预测模型进行预测,可达到 100% 数量的 6% 以下精度的预测。1 h 粒度数据由 4 个 15 min 粒度叠加生成,所以 1 h 粒度的数据对应波动性更大,S-ARIMA 适用于周期性明显的业务指标,对数据本身周期性特征要求较高,因此,S-ARIMA 仅适用于小颗粒度业务模型指标预测;而 LSTM 擅长提取长时序特征,对短期波动剧烈的业务指标预测精度较差,因此,S-ARIMA、LSTM 模型在预测时,分别有 68.18%、45.45% 数量的指标预测精度大于 10%。

表 3 1 h 粒度各指标预测值所属区间统计

预测模型	MAPE 区间		
	小于 6%	6%~10%	大于 10%
S-ARIMA	5	2	15
LSTM	6	6	10
LSTM&ConvLSTM	22	0	0

两模型多时间粒度下的对比如图 6 所示, 对比了 15 min、1 h、1 天 3 种时间粒度下 LSTM 与 LSTM & ConvLSTM 模型基于 Xn 接口的切换 (amf_at-intraamfxn) 指标多步预测的 MAPE 值, 与 LSTM 相比, LSTM & ConvLSTM 可实现多时间粒度下该指标的高精度预测, 且预测准确度更高。在 1 h 粒度下, LSTM&ConvLSTM 模型的预测精度可达 4.8%, 相较于 LSTM, 该融合模型将预测准确率提高了 55%。




图 6 两模型多时间粒度下的对比

1 h 粒度下两模型不同输出步长的 MAPE 对比如图 7 所示, 1 h 粒度下, 对于多步预测, 相较于 LSTM, LSTM&ConvLSTM 的平均 MAPE 更小, 预测结果更好, 当输出步长大于 6 时, 对应 LSTM&ConvLSTM 预测精度明显下降, 故在 1 h 粒度下, LSTM&ConvLSTM 可用于预测未来最多 6 个颗粒度输出的预测。




图 7 1 h 粒度下两模型不同输出步长的 MAPE 对比

不同时间颗粒度下 LSTM&ConvLSTM 输出步长结果见表 4, LSTM&ConvLSTM 模型可实现未来 4 天指标容量的高精度预测。可根据输出的预测值, 及时制定网络预优化策略, 确保网络覆盖以及容量需求。

表 4 不同时间颗粒度下 LSTM&ConvLSTM 输出步长结果

LSTM&ConvLSTM	预测输入时长	预测指标容量输出长度
15 m 粒度	2 天	6 个 15 min 颗粒度
1 h 粒度	2 天	6 个 1 h 颗粒度
1 天粒度	6 天	4 个 1 天颗粒度

3 智能化预测的应用建议

当前, 5G、NFV 迎来大规模部署期, 网络云化重构、网络切片等技术创新的加速发展促使一张网络赋能千行百业, 网络带宽、连接规模、传输时延等关键性能指标大幅度提升, 网络性能和灵活性发生了根本性改变^[24-25]。与此同时, 5G 网络的灵活性和复杂性给网络的运营、运维带来了前所未有的挑战, 传统运维模式已无法满足成本和效率的需求, 采用人工智能技术实现网络智能化成为必然趋势。

核心网业务模型是 5G 网络容量规划和网络建设的基础。业务模型各参数的预测结果可使维护人员迅速掌握网络流量的规律、趋势以便及时调控网络资源。具体而言, 业务模型智能化预测可考虑应用于网管监测系统中。利用长期 (季度、年度) 业务模型智能化预测, 对网络建设方案进行精准规划, 利用短期 (分、时) 业务模型智能化预测, 实现网络的自动化弹性扩缩容。具体实现方法为: 通过采集北向网管各网元侧的数据, 对数据进行异常识别、丢弃、异常处理, 生成训练数据, 根据需求将数据进行拆分, 将数据进行资源池维度、省份维度、单网元维度、时间粒度/维度进行划分, 训练对应维度数据, 构建基于 AI 的多时间维度预测模型, 将预测值上报给网管系统, 基于预测值, 网络进行决策判定, 将实际业务与 5G 网络容量规划匹配, 执行弹性扩缩容操作, 实现网络自动部署, 以



避免网络负载过大或资源利用率过低情况的发生,保证系统运行效率。

4 结束语


5G 时代需要一个高度智能化的网络,将 AI 引入通信网络将是 5G 网络规划、建设、维护、优化、运营的必然选择。本文提出使用 LSTM 与 ConvLSTM 双通道融合预测模型来对业务模型指标进行预测。该方法通过现网网管大数据采集、数据分析、构建 LSTM 与 ConvLSTM 双通道数据特征提取融合学习网络,对未来网络的运行参数和容量进行预测,根据预测结果提供更加智慧、灵活的网络策略,进而实现人工智能赋能通信网络,推动网络智能化持续演进。结果表明,本文提出的 LSTM 与 ConvLSTM 的融合预测模型可用于 15 min、1 h、1 天多维度时间粒度指标数据的多步预测,预测精度可达 4.8%。相较于传统时间序列 S-ARIMA 模型以及 LSTM 模型,该模型的预测准确度更高。

参考文献:


- [1] ALUIGI L, ORECCHINI G, LARCHER L. A 28 GHz scalable beamforming system for 5G automotive connectivity: an integrated patch antenna and power amplifier solution[C]//Proceedings of 2018 IEEE MTT-S International Microwave Workshop Series on 5G Hardware and System Technologies. Piscataway: IEEE Press, 2018: 1-3.
- [2] 运行监测协调局. 2021 年 1—7 月通信业经济运行情况[EB]. 2021.
Operational Monitoring and Coordination Bureau. Economic operation of the communications industry from January to July 2021[EB]. 2021.
- [3] 石红晓, 程永志. 基于 5G 核心网的网络演进及策略研究[J]. 通信与信息技术, 2020(4): 39-41, 50.
SHI H X, CHENG Y Z. Research on network evolution and strategy based on 5G core network[J]. Communication & Information Technology, 2020(4): 39-41, 50.
- [4] BEEREDDY S, SIRUPA K. NFV use case—Delivering virtual CPE with multi-vendor VNF orchestration[C]//Proceedings of 2015 IEEE Conference on Network Function Virtualization and Software Defined Network. Piscataway: IEEE Press, 2015: 25-27.
- [5] MA L, WEN X M, WANG L H, et al. An SDN/NFV based framework for management and deployment of service based 5G core network[J]. China Communications, 2018, 15(10): 86-98.
- [6] 梁雪梅, 方晓农, 朱林. 3GPP R15 冻结后的 5G 核心网关键技术[J]. 通信与信息技术, 2018(6): 33-35, 70.
LIANG X M, FANG X N, ZHU L. Research on key technologies of 5G core network after 3GPP R15 freeze[J]. Communication & Information Technology, 2018(6): 33-35, 70.
- [7] 嵇夏. 基于大数据的分组域容量分析系统设计与实现[J]. 电信快报, 2018(11): 28-32.
JI X. System designing and implementing of packet switch domain capacity analysis based on big data[J]. Telecommunications Information, 2018(11): 28-32.
- [8] 吕红卫, 冯征. 核心网分组域引入 EPC 架构分析[J]. 电信科学, 2010, 26(6): 116-120.
LYU H W, FENG Z. Analysis of the introduction of EPC into the core network packet domain[J]. Telecommunication Science, 2010, 26(6): 116-120.
- [9] 雒江涛, 李晴川. 基于云存储的分组域监测系统[J]. 重庆邮电大学学报(自然科学版), 2012, 24(6): 675-681.
LUO J T, LI Q C. Packet domain monitoring system based on cloud storage[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2012, 24(6): 675-681.
- [10] 3GPP. General packet radio service (GPRS) enhancements for evolved universal terrestrial radio access network (E-UTRAN) access Release 8: TS 23.401[S]. 2015.
- [11] 黄海, 周灵. 基于曲线拟合的分组域业务分析模型及算法实现[J]. 现代计算机(专业版), 2016(23): 16-19.
HUANG H, ZHOU L. Model and algorithm for capacity analysis in packet switch based on curve fitting[J]. Modern Computer, 2016(23): 16-19.
- [12] 袁野, 孙迪科, 张荣. 网络融合背景下的移动分组域网络负荷指标关联模型研究[J]. 移动通信, 2015, 39(2): 34-39.
YUAN Y, SUN D K, ZHANG R. Research on correlation model of network load index in mobile packet domain for integrated network[J]. Mobile Communications, 2015, 39(2): 34-39.
- [13] ISTIAKE SUNNY M A, MASWOOD M M S, ALHARBI A G. Deep learning-based stock price prediction using LSTM and Bi-directional LSTM model[C]//Proceedings of 2020 2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES). Piscataway: IEEE Press, 2020: 87-92.
- [14] KUMAR S D, SUBHA D. Prediction of depression from EEG signal using long short term memory(LSTM)[C]//Proceedings of 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI). Piscataway: IEEE Press, 2019: 1248-1253.
- [15] DAOUD N, ELTAHAN M, ELHENNAWI A. Aerosol optical depth forecast over global dust belt based on LSTM, CNN-LSTM, CONV-LSTM and FFT algorithms[C]//Proceedings of IEEE EUROCON 2021 - 19th International Conference on Smart Technologies. Piscataway: IEEE Press, 2021: 186-191.

- [16] 王艺霏, 于雷, 滕飞, 等. 基于长-短时序特征融合的资源负载预测模型[J]. 计算机应用, 2021.
WANG Y F, YU L, TENG F, et al. Resource-load prediction model based on long-short time series feature fusion[J]. Journal of Computer Applications, 2021.
- [17] ZHU H X, LU X H. The prediction of PM2.5 value based on ARMA and improved BP neural network model[C]//Proceedings of 2016 International Conference on Intelligent Networking and Collaborative Systems (INCoS). Piscataway: IEEE Press, 2016: 515-517.
- [18] NARENDRA BABU C, ESWARA REDDY B. Predictive data mining on Average Global Temperature using variants of ARIMA models[C]//Proceedings of IEEE-International Conference on Advances In Engineering, Science and Management (ICAESM -2012). Piscataway: IEEE Press, 2012: 256-260.
- [19] NOUREEN S, ATIQUE S, ROY V, et al. Analysis and application of seasonal ARIMA model in Energy Demand Forecasting: a case study of small scale agricultural load[C]//Proceedings of 2019 IEEE 62nd International Midwest Symposium on Circuits and Systems. Piscataway: IEEE Press, 2019: 521-524.
- [20] CHOI D J, HAN J H, PARK S U, et al. Comparative study of CNN and RNN for motor fault diagnosis using deep learning[C]//Proceedings of 2020 IEEE 7th International Conference on Industrial Engineering and Applications. Piscataway: IEEE Press, 2020: 693-696.
- [21] 王振业, 叶成绪, 王文韬, 等. 基于 LSTM-Att 方法的音乐流行趋势预测[J]. 计算机技术与发展, 2020, 30(9): 188-193.
WANG Z Y, YE C X, WANG W T, et al. Music trend forecast based on LSTM-att method[J]. Computer Technology and Development, 2020, 30(9): 188-193.
- [22] AKANDEH A, SALEM F M. Slim LSTM networks: LSTM_6 and LSTM_C6[C]//Proceedings of 2019 IEEE 62nd International Midwest Symposium on Circuits and Systems. Piscataway: IEEE Press, 2019: 630-633.
- [23] 任君明. 基于数据挖掘技术的移动通信话务预测模型[J]. 电信工程技术与标准化, 2015, 28(6): 79-82.
REN J M. Discussion on mobile communication traffic forecasting model based on data mining technology[J]. Telecom Engineering Technics and Standardization, 2015, 28(6): 79-82.
- [24] 欧大春. 5G 时代利用人工智能提升运营商网络竞争力的研究[J]. 邮电设计技术, 2020(10): 1-4.
OU D C. Research on using artificial intelligence to improve network competitiveness of operators in 5G era[J]. Designing Techniques of Posts and Telecommunications, 2020(10): 1-4.
- [25] 韩炳涛, 屠要峰, 王永成, 等. 人工智能技术助力通信网络智能化升级[J]. 人工智能, 2021, 8(1): 107-116.
HAN B T, TU Y F, WANG Y C, et al. Artificial intelligence technology helps the intelligent upgrade of communication networks[J]. AI-View, 2021, 8(1): 107-116.

[作者简介]



冯楠 (1994-), 女, 中国移动通信有限公司研究院助理工程师, 主要研究方向为移动通信分组核心网架构演进、测试解决方案研究等。



刘贺林 (1979-), 男, 中国移动通信有限公司研究院资深研究员, 主要研究方向为移动通信分组核心网架构演进、业务研究以及测试解决方案研究等。




周泉 (1975-), 男, 中国移动通信有限公司研究院高级工程师, 主要研究方向为网络领域测试技术和测试工具开发。



杨海俊 (1984-), 男, 中国移动通信有限公司研究院高级工程师, 主要研究方向为 IP、核心网设备技术及测试。



付蜜能 (1989-), 男, 中国移动通信集团有限公司工程师, 主要研究方向为 4G/5G 核心网运维管理、网络演进和网络自智能能力研究。



钟大平 (1979-), 男, 中国移动通信有限公司研究院高级工程师、资深研究员, 主要研究方向为移动核心网网络架构技术、核心网性能测试方法及测量仪表技术等。