



Prophet模型在话单量智能预测中的应用研究

陈勇, 刘贻凤, 王茵, 张梦宇
(中移信息技术有限公司, 广东 深圳 518048)

摘要: 对于电信运营商而言, 话单量预测在业务运营、IT 系统建设规划以及系统运维方面都是至关重要的一环。传统的预测方法采用以人工预测为主, 程序脚本统计为辅的方式来完成, 预测的准确性受人为因素影响较大, 且固定的规则无法表征受到多重因素影响的话单量的变化规律, 因此, 需要引入人工智能模型进行话单量的动态预测。通过研究并测试常用的人工智能预测模型, 采用依据业务特征改进的 Prophet 模型对网间结算系统的话单量进行预测, 预测效果相较于传统预测方法获得了显著提升。

关键词: 话单量预测; Prophet 模型; 时间序列; 人工智能

中图分类号: TN929.5

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024235

Research on the application of Prophet model in intelligent prediction of call volume

CHEN Yong, LIU Yifeng, WANG Yin, ZHANG Mengyu
China Mobile Information Technology Co., Ltd., Shenzhen 518048, China

Abstract: For telecommunications operators, call volume prediction is crucial in business operations, IT system construction planning, and system operation and maintenance. The traditional prediction method is mainly achieved through manual prediction, supplemented by program script statistics. The accuracy of predictions is greatly influenced by human factors, and fixed rules cannot represent the variation pattern of call volume affected by multiple factors. Therefore, it is necessary to introduce artificial intelligence models for dynamic prediction of call volume. Commonly used artificial intelligence prediction models were studied and tested. The Prophet model, improved based on business characteristics, was adopted for forecasting call volume of the inter-network settlement systems. The prediction effect has been significantly improved compared to traditional prediction.

Key words: call volume prediction, Prophet model, time series, artificial intelligence

0 引言

在电信行业, 话单量预测不仅是日常运营的

一项基础工作, 更是制定业务运营策略、开展系统容量规划和架构设计的关键依据。话单量预测的准确与否, 直接关系到电信业务的整体运营效

率和客户服务质量。具体而言,其影响主要体现在以下几个方面。

(1) 话单量预测的准确性直接决定了电信业务运营策略制定的合理性。准确的预测能够帮助运营商提前布局资源,优化网络结构,确保在市场需求增长时能够迅速响应,避免资源不足导致的业务中断或服务质量下降。反之,预测偏差可能导致资源过剩或不足,影响运营效率和成本控制。

(2) 话单量预测对于电信系统容量规划和架构设计的准确性至关重要。合理的容量规划能够确保系统在面对不同业务量时都能保持高效稳定运行,而准确的预测则是实现这一目标的前提。不当的预测可能导致系统容量过剩或不足,进而影响投资效益和用户体验。

(3) 话单量预测在系统运维的容量管理中扮演着重要角色,尤其是在业务高峰期。准确的预测能够帮助运维团队提前做好容量保障,确保在高峰时段系统能够承载突增的业务量,避免系统过载和潜在的服务中断。这对于维护电信运营商的品牌形象和客户满意度具有重要意义。

鉴于话单量预测在电信业务运营中的重要性,本文将深入分析当前话单量预测的现状,探讨存在的问题与挑战,并提出相应的改进措施。通过引入先进的人工智能技术,本文旨在提高话单量预测的准确性和效率,为电信运营商提供更加科学、可靠的决策支持,从而在激烈的市场竞争中保持优势。

1 话单量预测的现状分析

目前,话单量预测工作主要依赖于业务专家和系统专家的个人经验,但这种方法在实际操作中存在以下局限性。

(1) 专家经验差异导致的预测不一致性:资深专家与普通专家之间,以及不同资深专家之间,由于经验积累和业务理解的不同,他们的预

测结果可能存在显著差异。这种主观性较强的预测方法,缺乏统一的标准,降低了预测结果的可靠性。

(2) 多系统预测的复杂性:专家在预测话单量时,需要考虑多个业务系统的数据。每个系统的业务量变化规律和特点各异,专家难以精确捕捉不同系统间的细微差异,导致同一套预测规则在不同系统中的应用效果参差不齐。

(3) 预测准确度不足:从历史预测结果来看,预测准确度普遍有待提高。在话单量较小的情况下,预测误差的影响尚在可控范围内。但随着业务接入省份的增多和话单量的增加,预测误差的风险和影响也随之加大。

(4) 传统方法的局限性:传统预测方法缺乏灵活性和适应性,难以应对业务量的快速变化。此外,传统预测方法未能有效捕捉不同业务系统间的数据关联性,进一步影响了预测的准确性。

(5) 预测误差的累积效应:随着业务规模的扩大,预测误差的累积可能对企业的经营决策产生不利影响,从而影响企业的长远发展。

鉴于以上分析,当前的话单量预测方法已难以满足不断提高的精确度和效率需求。因此,探索新的预测方法,特别是引入人工智能技术,以提高预测的准确性和效率,已成为业务发展的迫切需求。

引入人工智能除了有可能提高话单量预测的准确度和稳定度,还可能带来以下方面的改进。

一方面,预测的单位时间可以更灵活。由于人力限制,传统预测往往只能以月或者天为单位进行,如果要进行更小时间粒度的预测,则需要人工处理极为庞大的数据量,这在实际情况中往往是难以实现的。人工智能则能够以小时、分钟,甚至以秒为单位进行更小时间粒度的预测。

另一方面,预测的周期长度可以更灵活。传统预测一般都是预测固定周期的话单量,如一年后、两年后的话单量。人工智能则能够预测更多



周期的话单量,并且可给出预测时间段内的话单量分布。此外,人工智能有可能会从历史数据中关注到更多人工预测不易发现到的影响因素,使得预测结果更为贴近实际情况。

2 时间序列预测的主要方法及筛选

2.1 时间序列预测方法

电信业务的话单量分别根据时间间隔统计,一般分为每分钟、每小时、每天、每周、每月、每季度和每年的话单量,这是一种典型的时间序列形式,即根据固定的时间间隔,记录每个时间点对应的数值,从数据上来看,每个数据点和特定的时间点相关联。因此,对话单量的预测可以运用对时间序列的分析和预测方法开展。

目前人工智能进行时间序列预测的方法中,应用比较广泛的有差分自回归移动平均(autoregressive integrated moving average, ARIMA)模型,长短期记忆(long short-term memory, LSTM)神经网络模型和先知(Prophet)模型。

ARIMA模型是一种基于时间序列自回归和移动平均的模型。它用过去观测值的线性组合来预测未来值。ARIMA模型还有一些增强的模型,如季节性自回归综合移动平均(seasonal autoregressive integrated moving average, SARIMA)模型和季节性自回归综合移动平均外生回归(seasonal autoregressive integrated moving average with exogenous variables, SARIMAX)模型,这些模型主要考虑季节性的影响,并根据历史数据中的季节模式进行预测。

LSTM模型是基于递归神经网络的一种预测模型,用于处理具有长期时间依赖关系的序列数据。模型通过学习时间序列中的模式和关联来预测未来的变量值。LSTM使用一种称为“门”的机制来解决传统递归神经网络的梯度爆炸和梯度消失问题,使其能够有效地捕捉长期依赖。LSTM模型具有记忆单元,可以处理和存储先前

的信息,并根据需要更新和使用这些信息。

Prophet模型是一种多变量时间序列预测框架。它适用于具有趋势性、季节性和节假日等复杂特征的预测问题。该模型使用基于分解的方法来捕捉不同的时间组件,并结合回归分析来处理外部影响因素。Prophet模型在预测中提供了可解释性,并且非常适合应用于具有多种时间特征的多变量时间序列数据。与其他机器学习预测算法对比,Prophet有一个显著的优势,即不需要特征工程就可以获得变化趋势、季节性因素和周期性因素。

2.2 预测方案对比分析

本文选取中国移动网间结算系统的话单量数据作为研究样本,通过对ARIMA模型、LSTM模型以及Prophet模型进行实验对比分析,以探讨这3种模型在预测话单量上的性能差异。

2.2.1 数据选取与预处理

实验数据集来源于中国移动网间结算系统,涵盖了2022—2024年年初的日话单量历史数据。在数据预处理阶段,本文首先对数据进行了清洗,排除了异常值和缺失值。其次,为了确保模型训练的稳定性,对数据进行了归一化处理。

2.2.2 模型参数配置

为了保证预测结果的公正性和准确性,实验为ARIMA、LSTM和Prophet这3种预测模型分别设置了合理的参数。对于ARIMA模型,本文通过自相关函数(autocorrelation function, ACF)和偏自相关函数(partial autocorrelation function, PACF)图来确定模型参数。对于LSTM模型,本文通过网格搜索和交叉验证来优化网络结构和学习率等参数。对于Prophet模型,本文调整了季节性参数和趋势灵活性参数以适应话单量数据的特性。

2.2.3 预测准确度评价与结果分析

实验采用均方误差(mean square error, MSE)、均方根误差(root mean square error, RMSE)和平

均绝对误差 (mean absolute error, MAE) 作为评价指标, 以比较不同预测模型的性能。

ARIMA 模型的实验结果如图 1 所示。根据评价指标, ARIMA 模型在短期波动预测方面的表现: MSE 为 0.05, RMSE 为 0.224, MAE 为 0.04。然而, 对于长期预测, 误差则显著增加: MSE 为 0.8, RMSE 为 0.894, MAE 为 0.75。从实验结果来看, ARIMA 模型对网间结算系统话单量的短期波动预测效果较好, 但其预测结果受到近期数据的影响较大, 随着预测周期的拉长, 对远期数据的遗忘明显, 导致长期走势的预测出现较明显的偏离, 明显不如短期预测的效果好。

LSTM 模型的实验结果如图 2 所示。LSTM

模型在长期趋势预测上的表现: MSE 为 0.03, RMSE 为 0.173, MAE 为 0.02。然而, 在短期预测中, 误差相对较高: MSE 为 0.7, RMSE 为 0.837, MAE 为 0.65。LSTM 模型的表现恰好与 ARIMA 模型相反, 对长期趋势的预测表现较好, 短期内抖动预测则表现欠佳。

Prophet 模型的实验结果如图 3 所示。Prophet 模型在短期和长期预测中的表现: 在短期预测中, MSE 为 0.02, RMSE 为 0.141, MAE 为 0.015; 在长期预测中, MSE 为 0.03, RMSE 为 0.173, MAE 为 0.02。通过这些数据可以看出, Prophet 模型在所有预测周期中都保持了较低的误差值, 显示出较好的综合预测能力。考虑对网间结算系统话单量的预测需求, 既要满




图1 ARIMA模型的实验结果




图2 LSTM模型的实验结果




图3 Prophet模型的实验结果

足系统运营运维的短周期预测需求,也要满足系统规划建设的长期预测需求,本文选择采用Prophet模型进行预测,在准确度上是一个更好的选择。

2.2.4 结构特性比较

从模型复杂度来看,ARIMA模型的复杂度相对较低,适合快速实现预测。LSTM模型则由于其深度神经网络结构的复杂度较高,需要较长的训练时间。Prophet模型在复杂度上则介于ARIMA和LSTM之间,它通过简化的模型结构实现了高效的预测。

从灵活性与扩展性进行评估,ARIMA模型在处理线性时间序列时较为灵活,但扩展性有限。LSTM模型则具有很强的扩展性,可以通过增加网络层数和节点数来进一步提高模型性能。Prophet模型在处理季节性和节假日效应方面表现出极高的灵活性,且易于调整模型参数以适应不同的数据特征。

在计算效率方面进行对比,Prophet模型表现最佳,适合快速预测。ARIMA模型次之,而LSTM模型由于训练过程较为复杂,其计算效率相对较低。

从预测稳定性角度来看,本文经过多次实验发现,Prophet模型在处理不同时间段的话单量数据时表现出较高的稳定性,而ARIMA和LSTM模型则在数据波动较大时稳定性较差。

从实际应用场景的适配性来看,Prophet模型由于其自动处理季节性和节假日效应的能力,更适用于预测具有这些特征的话单量数据。ARIMA模型则更适用于简单的线性预测场景,而LSTM模型则更擅长于捕捉数据中的复杂非线性关系。针对话单量数据的季节性和趋势性,Prophet模型展现出了良好的适应性,而ARIMA和LSTM模型在处理这些特征时则需要更多的手动调整。

2.2.5 综合评价与建议选择

不同模型的特性对比见表1。

综合考虑模型的预测性能、计算效率和稳定性,Prophet模型在预测话单量数据方面具有最优的综合性能。因此,本文建议在实际应用中选择Prophet模型进行话单量预测。

3 基于Prophet模型的话单量智能预测

3.1 Prophet算法研究

对于一个典型的时间序列 $y(t)$,一般可分解为趋势项 $g(t)$ 、季节项 $S(t)$ 和随机波动项 $R(t)$,即对于所有的 $t \geq 0$,都存在加法模型:

$$y(t) = g(t) + S(t) + R(t) \quad (1)$$

由于话单量除了受到长期趋势、季节性波动以及短期波动的影响,还具有一个明显特征,即受节假日的影响显著,特别是在法定假期的大型节假日前后,话单量会有明显的突增现象,这就

表1 不同模型的特性对比

模型特性	ARIMA 模型	LSTM 模型	Prophet 模型
短期预测	较好	较差	较好
长期预测	差	较好	较好
模型复杂度	低	高	中
训练时间	短	长	短
扩展性	有限	强	中
计算效率	中	低	高
预测稳定性	差	差	高
季节性和节假日效应处理	手动调整	手动调整	自动处理
实际应用场景适配性	简单线性预测	复杂非线性关系	季节性和趋势性预测

需要选用季节项加入预测模型。

Prophet 算法增加了节假日的效应作为可选项,即节假日项 $h(t)$,对时间序列分解方法进行了改进,通过拟合这 4 项得到了时间序列的预测值:

$$y(t) = g(t) + S(t) + h(t) + R(t) \quad (2)$$

3.1.1 趋势项模型

Prophet 算法的趋势项有两个重要的函数,即逻辑回归函数和分段线性函数。由于电信业务的用户数较为稳定,话单量从数据分布上看,具有明显的上限和下限,不具备长期的线性趋势,因此,选用非线性的逻辑回归函数来预测话单量趋势。随着电信业务的发展和变化,话单量的走势不会一直保持不变,在某些特定的时间或有着某种潜在的周期,导致话单量曲线发生变化,这时就需要研究引入变点检测。加入变点检测后,得到分段逻辑回归函数:

$$g(t) = \frac{C(t)}{1 + \exp(-(k + a(t)^T \delta) \cdot (t - (m + a(t)^T \gamma)))} \quad (3)$$

其中, $a(t) = (a_1(t), \dots, a_S(t))^T$, $\delta = (\delta_1(t), \dots, \delta_S(t))^T$, $\gamma = (\gamma_1(t), \dots, \gamma(t))^T$ 。 $C(t)$ 代表预测的容量,此处代表话单量的上限, s 表示第 s 个趋势变化点, k 表示基础变化速率, m 表示偏置量, δ 表示变化速率的变化量, $a(t)$ 表示时间戳 t 上的增变化速率, γ 是为了处理好线段边界引入的偏置量调整。

3.1.2 季节项模型

季节性变化即周期性变化,可以通过正弦函数和余弦函数来表示区间内的周期性变化,以此

模拟出时间序列的季节项:

$$s(t) = \sum_{n=1}^N \left(a_n \cos \frac{2n\pi t}{P} + b_n \sin \frac{2n\pi t}{P} \right) \quad (4)$$

其中, P 是时间序列的周期取值。例如,对于话单量来说,最显著的周期是周,此时 P 为 7。

3.1.3 节假日项模型

由于不同的节假日对时间序列带来的影响程度不同,因此,需要对每个节假日单独建立模型。同时,每个节假日的时间长短不同,该节假日的前后对时间序列造成影响的时间长度也不同,因此,需要为每个节假日独立设定时间窗口值。节假日效应可以表示为一年内所有节假日模型之和,表达式为:

$$h(t) = Z(t)k = \sum_{i=1}^L k_i \cdot 1_{\{t \in D_i\}} \quad (5)$$

其中, k_i 表示节假日的影响范围, D_i 表示该节假日的前后时段。

3.1.4 模型拟合

在构建完时间序列的趋势项、季节项、节假日项的基础上,本文利用 PyStan (一个用于概率编程的 Python 库) 工具集中的限制内存 BFGS (limited-memory Broyden-Fletcher-Goldfarb-Shanno, L-BFGS) 算法来拟合模型,从而得到最后的预测结果。

3.2 Prophet 模型预测话单量的实现

3.2.1 数据建模

数据建模的第 1 步是把话单量历史数据转换



成标准的时间序列形式, 然后加入容量特征, 得到历史话单量数据集。首先在网间结算系统采集每分钟的话单量数据, 然后根据话单量预测的时间单位需求合并出每小时、每天、每周、每年的数据, 同时给每个数据点配置相应的时间戳, 构成标准时间序列, 最后加入容量特征。容量特征是由业务特点来决定的, 一般是一个固定的数值。以网间结算系统的日话单量数据为例, 历史话单量时间序列形式见表2。

表2 历史话单量时间序列形式

日期	数据	上限
2024年2月7日	$2.261\ 426 \times 10^7$	60 000 000.0
2024年2月8日	$2.336\ 614 \times 10^7$	60 000 000.0
2024年2月9日	$2.275\ 808 \times 10^7$	60 000 000.0
2024年2月10日	$2.263\ 451 \times 10^7$	60 000 000.0
2024年2月11日	$2.254\ 240 \times 10^7$	60 000 000.0

第2步是构造节假日特征数据集。节假日特征即在标准时间序列基础上再增加两个特征列, 即节假日名称和对应的日期戳, 记录每个出现的节假

日。然后, 设置一个起始时间点和结束时间点, 从而形成一个时间窗口, 将节假日的影响范围扩展到一个时间区间。不仅是历史数据集中需要有节假日特征数据, 在待预测的日期中也应包含节假日特征数据, 即在待预测的日期里, 应预先指定所有出现的节假日。节假日特征数据集见表3。

表3 节假日特征数据集

节假日名称	日期	假期影响上限	假期影响下限
Yuandan	2022年1月1日	0	3
Yuandan	2023年1月1日	-1	2
Yuandan	2024年1月1日	2	1
Spring	2022年2月1日	-1	6
Spring	2023年1月22日	-1	6
Spring	2024年2月10日	0	8
I antern	2022年2月15日	0	1

3.2.2 算法模型实例化与学习拟合

本文采用Python代码实现模型的创建。首先创建一个Prophet对象, 然后对历史数据进行学习拟合, 学习拟合示意图如图4所示。




图4 学习拟合示意图

学习拟合过程主要对历史数据的长期趋势、转折点和突变点进行学习和推演，进而发现潜在的趋势、转折点和突变点。在拟合的过程中，如果发现趋势的变化被过度拟合或者拟合不足，需要调整趋势变化点的密度参数来改变拟合的灵活性。模型在趋势变化点的密度参数允许的范围内，尽可能寻找出潜在的突变点和转折点。如果拟合过程中出现拟合出的突变点位置明显不正确的情况，可以通过调整参数直接指定特定的突变位置，避免拟合出现重大偏差。此外，如果发现历史数据中有明显的异常值或错误值，需要将其移除，避免异常值或错误值一起被拟合到趋势中，进而影响预测的准确性。

3.2.3 预测验证

模型对历史数据学习拟合完成后，就可以根据历史话单量来预测未来各个时间点对应的的话单量，预测数据结果见表4。

预测的结果中除了预测的具体数值，还包括预测值的上下限、预测的趋势、预测的不同周期的波动上下限等信息。根据话单量预测的业务需求，本文选取预测值和预测值的上下限作为预测的结果。

本文通过不断变更训练集数据和预测的时间长度，与测试集数据进行回测比对，在比对过程中进行参数调优，优化后的预测效果如图5所示。

从图5中可以看出，模型准确地预测出了网间结算系统话单量的下降趋势，同时对于春节等节假日前后业务量的突增和突减也做出了较为准确的预测。最终的预测结果在RMSE和MAE的指标上均控制在8%以内，相较于传统的预测方法，该模型的准确度提高了40%以上，且超过96%的真实数据点落在了预测的上下限以内。

表4 预测数据结果

日期	趋势分量	上限	预测值下限	预测值上限	趋势成果下限	趋势成果上限	附加项	附加项下限	附加项上限
2024年5月27日	$2.419\ 648\times 10^7$	60 000 000.0	$2.080\ 572\times 10^7$	$3.110\ 985\times 10^7$	$1.867\ 318\times 10^7$	$2.885\ 750\times 10^7$	$1.894\ 773\times 10^6$	$1.894\ 773\times 10^6$	$1.894\ 773\times 10^6$
2024年05月28日	$2.418\ 199\times 10^7$	60 000 000.0	$2.007\ 748\times 10^7$	$3.147\ 597\times 10^7$	$1.855\ 872\times 10^7$	$2.894\ 078\times 10^7$	$1.791\ 814\times 10^6$	$1.791\ 814\times 10^6$	$1.791\ 814\times 10^6$
2024年05月29日	$2.416\ 750\times 10^7$	60 000 000.0	$2.128\ 272\times 10^7$	$3.220\ 020\times 10^7$	$1.843\ 044\times 10^7$	$2.897\ 502\times 10^7$	$2.796\ 523\times 10^6$	$2.796\ 523\times 10^6$	$2.796\ 523\times 10^6$
2024年05月30日	$2.415\ 301\times 10^7$	60 000 000.0	$2.008\ 583\times 10^7$	$3.166\ 209\times 10^7$	$1.836\ 475\times 10^7$	$2.904\ 982\times 10^7$	$1.892\ 704\times 10^6$	$1.892\ 704\times 10^6$	$1.892\ 704\times 10^6$




图5 优化后的预测效果




4 结束语

本文应用 Prophet 模型预测网间结算系统的话单量,相较于以往的人工预测和程序预测的方式,预测的准确性和灵活性都有了大幅提高,为系统运营运维、系统规划建设以及经营决策提供了可靠的业务量依据。本文实现的架构相对于其他的大部分机器学习算法也更为简洁、高效,可以用于电信运营商大部分语音、短信、流量类的业务量预测。


参考文献:

- [1] 赵珂一. 基于 ARIMA 模型的云南省第三产业发展预测[J]. 价值工程, 2023, 42(33): 44-48.
ZHAO K Y. Forecasting the service industry development in Yunnan Province based on ARIMA model[J]. Value Engineering, 2023, 42(33): 44-48.
- [2] 王晓, 揣锦华, 张立恒. 基于 Prophet 算法的铁路客流量预测研究[J]. 计算机技术与发展, 2020, 30(6): 130-134, 150.
WANG X, CHUAI J H, ZHANG L H. Research on railway passenger flow forecast based on Prophet time series algorithm[J]. Computer Technology and Development, 2020, 30(6): 130-134, 150.
- [3] 钱嫣然, 何慧之, 仇海英, 等. 基于 ARIMA 模型的区域用电量预测方法[J]. 信息技术, 2023, 47(1): 180-185.
QIAN Y R, HE H Z, QIU H Y, et al. Regional electricity consumption forecasting method based on ARIMA model[J]. Information Technology, 2023, 47(1): 180-185.
- [4] 郭斌, 熊显名. 基于 SARIMA-LSTM 的区域用电消耗预测研究[J]. 工业控制计算机, 2024, 37(5): 109-111, 114.
GUO B, XIONG X M. Research on regional electricity consumption forecasting based on SARIMA-LSTM[J]. Industrial Control Computer, 2024, 37(5): 109-111, 114.
- [5] 曹还君, 李长云. 基于 SSA-LSTM 模型的空气质量预测研究[J]. 现代信息技术, 2024, 8(4): 142-146, 152.
CAO H J, LI C Y. Research on air quality prediction based on SSA-LSTM model[J]. Modern Information Technology, 2024, 8(4): 142-146, 152.
- [6] 史业照, 郭斌, 郑永军. 基于 LSTM 网络的 IGBT 寿命预测方法研究[J]. 中国测试, 2024, 50(2): 54-58, 65.
SHI Y Z, GUO B, ZHENG Y J. Research on IGBT life prediction based on LSTM network[J]. China Measurement & Test, 2024, 50(2): 54-58, 65.
- [7] 朱宝, 罗孝文, 吴自银. 基于 ARIMA 与 LSTM 的海岸带地面沉降预测方法: 以杭州湾地区为例[J]. 海洋学研究, 2022, 40(2): 53-61.
ZHU B, LUO X W, WU Z Y. ARIMA- and LSTM-based forecasting method of land subsidence in coastal zone: a case study from the Hangzhou Bay and its adjacent area[J]. Journal of Marine Sciences, 2022, 40(2): 53-61.
- [8] 周源, 魏国富, 李亚锦, 等. 基于 LSTM 的换流站直流测量系统状态趋势预测方法[J]. 电气自动化, 2022, 44(4): 67-70.
ZHOU Y, WEI G F, LI Y J, et al. State trend prediction method of DC measurement system of converter station based on long short-term memory[J]. Electrical Automation, 2022, 44(4): 67-70.
- [9] 谢辉, 江雄, 王武. 基于 LSTM 的电网区域线损预测方法研究[J]. 电气自动化, 2023, 45(1): 47-49.
XIE H, JIANG X, WANG W. Research on LSTM-based regional line loss prediction method of power grid[J]. Electrical Automation, 2023, 45(1): 47-49.
- [10] TAYLOR S J, LETHAM B. Forecasting at Scale [J]. The American Statistician, 2018, 72(1): 37-45.
- [11] 张新禹. 基于 ARIMA 和指数平滑算法对磁盘占用率的预测分析[J]. 现代信息技术, 2023, 7(24): 67-71.
ZHANG X Y. Prediction analysis of disk utilization rate based on ARIMA and exponential smoothing algorithms[J]. Modern Information Technology, 2023, 7(24): 67-71.
- [12] 李衡, 朱理, 郑洁, 等. 基于 Prophet 算法的配电网线路峰值负荷预测[J]. 浙江电力, 2022, 41(3): 20-26.
LI H, ZHU L, ZHENG J, et al. Peak load forecasting of distribution network lines based on Prophet algorithm[J]. Zhejiang Electric Power, 2022, 41(3): 20-26.
- [13] 刘天, 吴杨, 陈琦, 等. SARIMA 模型与 Prophet 模型对手足口病周发病率拟合及预测效果比较[J]. 预防医学情报杂志, 2022, 38(10): 1346-1350.
LIU T, WU Y, CHEN Q, et al. Comparison of SARIMA model and Prophet model on the weekly incidence of hand, foot and mouth disease[J]. Journal of Preventive Medicine Information, 2022, 38(10): 1346-1350.
- [14] 马晓琴, 厉娜, 罗红郊, 等. 基于 Prophet 的用户用电量短期预测方法[J]. 信息技术, 2023, 47(8): 29-34.
MA X Q, LI N, LUO H J, et al. Prophet-based short-term forecasting method of user electricity consumption[J]. Information Technology, 2023, 47(8): 29-34.
- [15] 刘夏雨. 基于 Prophet 时间序列的 5G 通信网络潮汐效应预测方法[J]. 中国宽带, 2023, 19(9): 10-12.
LIU X Y. Prediction method of tidal effect in 5G communication network based on Prophet time series[J]. China BroadBand, 2023, 19(9): 10-12.


[作者简介]



陈勇 (1980—), 男, 中移信息技术有限公司工程师, 主要研究方向为智能运维 (AIOps)、系统运维大模型。



王茵 (1993—), 女, 中移信息技术有限公司工程师, 主要研究方向为智能化、自动化运维。



刘贻凤 (1980—), 男, 中移信息技术有限公司工程师, 主要研究方向为清结算系统技术架构演进及相关领域 AIOps 运维技术。



张梦宇 (1989—), 男, 中移信息技术有限公司工程师, 主要研究方向为 IT 云、数据库、人工智能、大数据。