


# 基于 LSTM-GB 的政务云资源预测

文 ◆ 大连市大数据中心 张家勇



## 引言

随着政务信息化发展和数字政府建设的不断深入，国内各省市政务云建设如火如荼。政务云已经成为数字政府建设重要基础支撑，用户对云服务的需求日益增长。然而，这种需求具有动态性，例如在特定时间（如工作日、节假日）或特定事件（如重要业务开展、系统上线）前后，云资源的需求量会显著波动。当前，许多云服务提供商仍依赖于静态或过度分配资源的方式，不仅导致资源浪费，还在需求高峰时出现资源不足的问题。因此，提高云资源的利用率，提高政务云平台的稳定性和连续性以及合理组织和管理政务云预算支出、优化资源配置、降低运营成本具有重要意义。

最初的云资源预测主要采用非智能算法（如线性回归、指数平滑、



【作者简介】张家勇（1978—），男，辽宁大连人，硕士研究生，高级工程师，研究方向：电子政务、云计算、大数据、人工智能。

类比法等), 随着云计算的快速发展和数据规模的爆炸式增长, 非智能算法在处理复杂、非线性和动态变化的云资源需求时遇到了挑战。因此, 开始探索更先进的智能预测算法, 以提高预测的准确性和灵活性。其中, 基于统计和时间序列分析的方法(如 ARIMA 模型、指数平滑等)能够有效捕捉云资源使用的线性趋势和周期性变化, 特别适用于历史数据充足且变化模式相对稳定的场景<sup>[1]</sup>。基于机器学习的方法(如 SVM、LSTM 等模型)能够自动学习数据中的复杂模式和非线性关系, 在处理大规模、高维度的云资源数据方面表现出色, 能够提供更高的预测精度<sup>[2,3]</sup>。基于集成学习的方法, 通过结合多个单一模型的预测结果提高整体预测性能(如 Stacking 等), 在处理复杂和动态变化的云资源需求时表现优异<sup>[4]</sup>, 在启发式算法和元启发式算法(如粒子群优化算法、细菌觅食算法、模拟退火算法)参数优化和模型选择方面表现出色<sup>[5-7]</sup>。此外, 还有综合利用以上多种算法的混合预测模型, 取长补短, 提高预测精度和适应性<sup>[8,9]</sup>。

本研究充分考虑政务信息系统特点, 针对以上 LSTM 预测模型应对快速变化适应性有限以及未充分利用用户主观信息的缺点, 引入用户预测信息, 通过 LSTM 和 Light GBM 模型深入分析历史数据, 捕捉其中的隐藏规律, 最后通过预测残差调整模型权重, 得到最终的云资源预测结果。通过实验表明, 该方法较 LSTM 和 Light GBM 预测模型有较大的改善, 面对突发情况能够发挥更好的特征捕捉能力, 展现出较好的稳定性、适应性和鲁棒性。

## 1 预测模型

### 1.1 LSTM 模型

LSTM 模型即长短时记忆网络模型, 核心思想是通过引入“记忆单元”完成存储、更新和传递信息。LSTM 模型通过输入门、遗忘门和输出门共同控制信息流动, 计算公式如下。

遗忘门 (Forget Gate):  $f_t = \sigma(W_f \cdot [l_{t-1}, x_t] + b_f)$

输入门 (Input Gate):  $i_t = \sigma(W_i \cdot [l_{t-1}, x_t] + b_i)$   $\tilde{C}_t = \tanh(W_c \cdot [l_{t-1}, x_t] + b_c)$

细胞状态更新 (Cell State Update):  $C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$

输出门 (Output Gate):  $O_t = \sigma(W_o \cdot [l_{t-1}, x_t] + b_o)$   $l_t = O_t * \tanh(C_t)$

其中,  $x_t$  为时刻  $t$  的输入,  $l_t$  为时刻  $t$  的输出,  $l_{t-1}$  是上一时刻的隐藏状态,  $C_{t-1}$  是上一时刻的记忆单元状态,  $\sigma$  表示 sigmoid 激活函数,  $*$  代表元素乘积,  $W$  和  $b$  分别为权重矩阵和偏置向量。

### 1.2 模型改进

LSTM 预测模型经过历史数据训练, 使用细胞链记忆功能处理中长期依赖关系。通过门结构自主保留和更新信息, 根据历史经验对未来云资源进行预测, 并能够适应环境变化, 但该模型应对快速变化适应性有限, 并且未充分利用用户主观信息。同时, 考虑到政务信息系统具有业务导向性, 其系统功能设计会按照业务需求进行定制, 以满足自身业务需求和服务需求为目标。首先, 政务信息系统的时段使用差异明显, 系统在工作时间内往往使用率较高, 而在非工作时间系统使用率会明显降低。其次, 政务信息系统往往是业务部门有计划地推进业务开展(如

新功能上线、网上报名、业务办理等), 业务部门和技术支持团队根据业务开展计划, 提前预知并发量和访问规模以及主要访问的功能点。这些特性是政务信息系统区别于普通信息系统的特点, 也是政务系统资源预测过程中应该充分利用的因素之一, 如果在云资源预测时未充分利用则是一种浪费。同时, 考虑到预测用户中多数为业务人员而非专业技术人员, 其根据业务计划预测的访问并发数据可参考性较强, 而 CPU、内存以及存储相关预测数据则误差较大。

基于以上原因, 融合 LSTM 和 Light GBM 两种预测模型, 建立一种新的预测模型 LSTM-GB。使用 LSTM 模型掌握云资源使用情况的时序依赖性, 预测云资源使用参考量  $\hat{y}_{t,ls}$ , 同时, 引入用户预测机制, 使用 Light GBM 模型学习云资源使用情况与并发量之间的关系; 通过压力测试数据丰富预测模型经验, 并根据并发量预估云资源使用参考量  $\hat{y}_{t,li}$ , 最终通过残差方差计算权重并融合预测结果。

### 1.3 融合模型

#### 1.3.1 权重计算

假设有两种预测方法 LSTM 和 Light GBM, 预测残差  $e_t$  ( $t$  时刻实际值与预测值之间的差异) 的方差分别为  $\sigma_{e,ls}^2$  和  $\sigma_{e,li}^2$ 。根据方差计算每种方法的权重  $w_{ls}$  和  $w_{li}$ , 使组合预测的方差最小化。一种常见的方法是使用方差的倒数作为权重的基础, 即

$$w_{ls} = \frac{1/\sigma_{e,ls}^2}{1/\sigma_{e,ls}^2 + 1/\sigma_{e,li}^2}$$

$$w_{li} = \frac{1/\sigma_{e,li}^2}{1/\sigma_{e,ls}^2 + 1/\sigma_{e,li}^2}$$

因为方差的倒数与预测方法的准确性成正比，即方差越小（即预测越准确），权重越大，因此本研究使用方差的倒数计算权重具有合理性。

### 1.3.2 组合预测

将两种预测方法的预测结果  $\hat{y}_{t,ls}$  和  $\hat{y}_{t,li}$  根据权重进行加权平均，得到最终的组合预测结果  $\hat{y}_{t,lsqb}$ 。

$$\hat{y}_{t,lsqb} = w_{ls} \times y_{t,ls} + w_{li} \times y_{t,li}$$

## 2 实验验证

### 2.1 实验数据

实验数据主要包括历史数据、压测数据和用户预测数据 3 类。

（1）历史数据。从云平台、网络设备和政务信息系统等抓取的相关历史使用数据。实验通过云平台采集了某业务系统服务器一年内的运行数据，采集时间间隔为 30min，共 17520 条数据，作为训练和测试数据。

（2）压测数据。政务信息系统上线前使用压力测试工具对系统进行充分测试，并记录测试数据用于模型的训练及测试，训练数据集如表 1 所示。

（3）用户预测数据。收集用户的预测数据，并记录其身份信息和进行预测的具体时间戳。不仅确保了数据的完整性和可追溯性，还为后续分析用户预测的准确性提供了数据基础。同时，能够更好地把握业务人员的预测能力，进一步优化业务规划和决策过程。

### 2.2 模型训练

表 3 测试结果对比表

序号	算法	RMSE	MAPE
1	LSTM	5.84	0.15
2	Light GBM	8.60	0.21
3	LSTM-GB	3.35	0.09

表 1 训练数据集

序号	变量名	参数描述
1	时间戳	记录数据收集的确切时间点
2	CPU 使用率	服务器 CPU 当前使用百分比
3	内存使用率	服务器内存当前使用百分比
4	存储使用量	已使用的存储空间量
5	用户数量	当前注册或活跃的用户数量
6	并发访问量	同一时间点的访问请求数量
7	网络带宽	数据传输速率反映网络性能

表 2 模型参数

算法	参数	参数值
LSTM	学习率 (Learning Rate)	0.001
	迭代次数 (Epochs)	100
	批处理大小 (Batch Size)	32
	LSTM 层数	2
	LSTM 单元数 (Units)	128
	Dropout 率	0.2
LightGBM	学习率 (Learning Rate)	0.1
	树的数量 (Num Trees)	100
	叶子节点数 (Num Leaves)	31
	最大深度 (Max Depth)	5
	特征采样率 (Feature Fraction)	0.8
	数据采样率 (Bagging Fraction)	0.8
	正则化参数 (Lambda L1)	0.0
正则化参数 (Lambda L2)	0.1	

（1）模型训练。使用预处理后的数据集训练 LSTM-GB 模型，模型参数如表 2 所示。

（2）模型评估与调优。为评估模型的预测效果，实验采用均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 进行对比评估。

均方根误差 (RMSE) 公式如下。

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

其中， $n$  是样本数量， $y_i$  是真实值， $\hat{y}_i$  是预测值。

平均绝对百分比误差 (MAPE) 公式如下。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100$$

### 2.3 结果分析

本实验选择 CPU 利用率为预测指标。通过实验发现，经过数据训练后，LSTM 模型、Light GBM 模型以及 LSTM-GB 模型预测值与真实值的走势基本拟合。测试结果对比表见表 3，通过测试结果可以看出，LSTM 模型预测精度较高，RMSE 值为 5.84，MAPE 值为 0.15，低于 0.20，优于 Light GBM 模型的 8.60，MAPE 值为 0.21，大于 0.20，但是 Light GBM




图1 预测结果对比折线图

模型对于并发量增量比较敏感。LSTM-GB模型融合了LSTM模型和Light GBM模型优势,预算精度显著提高, RMSE值降低至3.35, MAPE值降低至0.09, 远优于LSTM和Light GBM。

预测结果对比折线图见图1, LSTM-GB算法在各个时间点的预测结果相对稳定,没有出现极端偏差,在数据在时间序列上存在一定的波动性和变化性。LSTM-GB算法能够较好地适应这种变化, LSTM-GB算法对于异常值或噪声数据也具有一定的鲁棒性。在某些时间点(如08:00, 09:00等),真实值出现了较大波动,但LSTM-GB的预测值并没有受到太大影响,仍然保持了相对稳定的预测性能。表明LSTM-GB算法在处理实际时间序列数据时具有较好的鲁棒性和抗干扰能力。

## 结语

本文深入研究了政务云领域的云资源预测问题,采用LSTM-GB预测模型融合了LSTM和Light GBM模型在云资源预测领域的优势,并根据政务信息系统特点引入用户预测机制的方式提高政务云资源预测能力。经过实验表明,用LSTM-GB预测模型相对单一的LSTM或Light GBM模型预测结果的RMSE、MAPE均有明显降低,预测能力有明显提升。为政务云资源预测问题提供了新的思路,同时也为政务云建设提升服务效率、减少资源浪费以及应对需求高峰时的资源不足等问题提供了参考。

## 引用

- [1] 谢晓兰,张征征,王建伟,等.基于三次指数平滑法和时间卷积网络的云资源预测模型[J].通信学报,2019,40(8):143-150.
- [2] 杨云,闫振国.基于卷积网络与支持向量机的云资源预测模型[J].陕西科技大学学报,2020,38(5):165-172.

[3] 薛宇飞.基于LSTM算法的云资源库存需求预测[J].信息与电脑(理论版),2023,35(10):197-199.

[4] 梁荣华,谢晓兰,翟青海,等.基于改进的Stacking集成模型的容器云负载预测研究[J].计算机应用与软件,2023,40(12):48-55+100.

[5] 杨迪,刘思源,王鹏,等.基于多策略粒子群优化RBF的云资源预测模型[J].计算机工程与设计,2023,44(4):1073-1080.

[6] 邓斌涛,徐胜超.基于改进细菌觅食算法的容器云多维资源均衡调度[J].云南师范大学学报(自然科学版),2021,41(5):28-32.

[7] 高天阳,虞慧群,范贵生.基于模拟退火遗传算法的云资源调度方法[J].华东理工大学学报(自然科学版),2019,45(3):471-477.

[8] 韩峰.基于混合模型的时间序列预测方法研究[D].天津:天津理工大学,2019.

[9] 王骞.云平台下基于混合模型的网络负载资源预测[D].西安:陕西师范大学,2019.