

基于 MF-LSTM 的基站自适应节能方案

张庆轩¹, 姜钰磊¹, 赵耀², 王晓雨²

¹南京邮电大学通信与信息工程学院 江苏南京

²中国电信股份有限公司江苏分公司 江苏南京

【摘要】随着 5G 基站大规模部署, 能耗问题日益突出。传统节能方案存在业务流量时间波动性强, 预测精度不足和异构基站场景下节能策略泛化能力差的问题, 难以适应动态业务需求, 易导致网络服务质量下降。为此, 本文提出基于多特征长短期记忆神经网络 (MF-LSTM) 的基站自适应节能方案, 利用 MF-LSTM 融合多维特征, 提升预测准确性; 通过 K-means 聚类算法划分基站能耗模式, 动态匹配最优节能策略。实验表明, MF-LSTM 可解释 92% 以上的流量波动, 基站自适应节能策略可降低 11.71% 的基站能耗, 为绿色通信提供更有效的方法。

【关键词】基站节能; 长短期记忆神经网络; 自适应算法

【基金项目】2025 年中国电信江苏公司基于人工智能的空天地协同网络关键技术与应用系统研发项目 (2025JS4GJSC)

【收稿日期】2025 年 4 月 12 日

【出刊日期】2025 年 5 月 15 日

【DOI】10.12208/j.jeea.20250152

MF-LSTM-based adaptive energy-saving system for base stations

Qingxuan Zhang¹, Yulei Lou¹, Yao Zhao², Xiaoyu Wang²

¹School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu

²China Telecom Stocks Co., Ltd., Jiangsu Branch, Nanjing, Jiangsu

【Abstract】With the large-scale deployment of 5G base stations, energy consumption issues have become increasingly prominent. Traditional energy-saving solutions suffer from strong temporal fluctuations in service traffic, insufficient prediction accuracy, and poor generalization of energy-saving strategies in heterogeneous base station scenarios, making them difficult to adapt to dynamic service demands and prone to degrading network service quality. To address this, this paper proposes an adaptive base station energy-saving system based on Multi-Feature Long Short-Term Memory neural networks (MF-LSTM) and K-means clustering. The MF-LSTM integrates multi-dimensional features integrates temporal features (weekday/hour) and traffic data to enhance prediction accuracy, while K-means clustering categorizes base station energy consumption patterns to dynamically match optimal energy-saving strategies. Experimental results demonstrate that the MF-LSTM explains over 92% of traffic fluctuations, and the adaptive energy-saving strategy achieves an 11.71% reduction in base station energy consumption, providing a more effective approach for green communication.

【Keywords】Base station energy conservation; Long Short-Term Memory neural network; Adaptive algorithm

引言

随着 5G 网络的快速发展和大规模部署, 基站能耗问题日益成为制约通信行业可持续发展的重要因素^[1]。据统计, ICT 行业对全球温室气体排放的直接影响占比约 4%, 其中移动通信网络的影响占比 10% 以上^[2]。如何实现基站节能降耗已成为业界和学界关注的焦点问题。降低通讯网络能耗不仅是运营商和设备商共同关注的重点, 也是维护地球可持续发展的共同责任^[2]。当前, 基站节能技术面临三大挑战: (1) 业务流量具

有显著的时空波动性, 难以准确预测; (2) 传统节能策略缺乏自适应能力; (3) 不同场景下基站能耗特征差异显著, 需要差异化节能方案^[3]。

在流量预测领域, 现有研究主要采用三类方法: 以自回归移动平均模型 (ARIMA) 为代表的统计模型适合线性时序预测, 但难以捕捉复杂非线性特征^[4]; 随机森林等机器学习方法虽能处理非线性关系, 但对特征工程依赖性强, 难以满足不同基站的数据特征要求^[5]; 长短期记忆神经网络 (LSTM) 等深度学习方法具有强

大的时序建模能力,但多数研究仅考虑单一流量特征,忽略了时间特征中的多维性带来的影响。在节能策略方面,主流方法仍采用根据固定业务量阈值启停载波^[4],这类方法实现简单但灵活性不足,难以适应动态变化的流量需求^[6]。




图1 基于 MF-LSTM 的基站自适应节能方案

针对上述问题,本文创新型地提出了一种基于多特征长短期记忆神经网络(MF-LSTM)和自适应聚类的基站节能方案。该方案利用时间、流量多维特征,通过 MF-LSTM 模型实现高精度流量预测,并采用 K-means 聚类算法,根据基站历史能耗特征进行自适应分簇,最后为不同簇别设计差异化节能策略。实验结果表明,在真实基站数据集上,本方案在所有基站上预测精度均达到 92%以上,节能效率达到 11.71%。本研究的主要贡献包括:(1)提出 MF-LSTM 流量预测框架;(2)设计基于聚类的自适应节能策略;(3)构建完整的基站节能决策方案并进行实证验证。

针对上述问题,本文创新型地提出了一种基于多

特征长短期记忆神经网络(MF-LSTM)和自适应聚类的基站节能方案。该方案利用时间、流量多维特征,通过 MF-LSTM 模型实现高精度流量预测,并采用 K-means 聚类算法,根据基站历史能耗特征进行自适应分簇,最后为不同簇别设计差异化节能策略。实验结果表明,在真实基站数据集上,本方案在所有基站上预测精度均达到 92%以上,平均节能效率达到 11.71%。本研究的主要贡献包括:(1)提出 MF-LSTM 流量预测框架;(2)设计基于聚类的自适应节能策略;(3)构建完整的基站节能决策方案并进行实证验证。

1 基于 MF-LSTM 的流量数据预测

1.1 数据预处理

本文所采用的数据集为江苏省部分地区 5G 基站流量数据集(已脱密处理),数据格式为时间-流量数据,其中时间存储格式为年-月-日-小时,即

$$T = [t_{year}, t_{month}, t_{day}, t_{time}] \quad (1)$$

流量存储格式为基站-小区-流量,即

$$D = [f_{enb}, f_{cell}, f_{byte}] \quad (2)$$

在数据预处理部分,首先进行基站流量数据聚合,将同一基站上不同小区使用的流量进行数据聚合,具体表示为 $D_1 = [f_{enb}, f_{allbyte}]$ 。由于原始数据基站数较少,本文采用添加高斯噪声的方式进行数据增强,对于每个基站采用高斯噪声注入方法扩充数据集,噪声强度与流量幅值自适应匹配。在实际的数据获取中,由于基站在部分时间处于关断状态,原始的流量数据集中存在一部分缺失值与异常值。此外,由于数据采集受随机性扰动,部分时间节点上存在离群现象。因此,需要对数据进行离群值检测与修复。离群值检测使用滑动窗口 Z-score 方法对每个基站数据独立检测,检测标准为 $3 - \sigma$ 准则。在修复阶段对离群值采用时间线性插值进行替代,插值所取时间为前后两天同时间段数据,即 $f_{allbyte}(t_{day}, t_{time}) = \frac{1}{2} [f_{allbyte}(t_{day}, t_{time}) + f_{allbyte}(t_{day}, t_{time})]$ 。若连续多日异常,则调用该基站同期历史数据的中位数填充。

1.2 多特征构建

考虑到工作日与周末流量模式不同和日高低峰流量模式的差异^[7],流量数据服从以周为大周期、天为小周期的变化规律。本文将时间从年-月-日-小时转为星期-小时格式,构建了双周期编码的多维度时间特征,从而建模周内与日内差异。具体而言,通过引入星期(0-6)的 one-hot 编码,可以将时间戳转换为星期-小时格式,以捕捉周内、日内流量波动规律,即 $T = [t_{year}, t_{month}, t_{day}, t_{time}] \rightarrow T_1 = [t_{week}, t_{time}]$ 。至此,

经过多特征构建后的数据集可以表示为 $[T_1; D_1] = [t_{week}, t_{time}; f_{enb}, f_{allbyte}]$ 。

1.3 流量预测模型

LSTM 模型是用于预测时间序列数据的循环神经网络 (RNN) 模型, 能够有效捕捉特征之间的长短期依赖关系与非线性关系。LSTM 解决了传统 RNN 中梯度消失或爆炸导致记忆短、简单循环单元难以捕捉复杂模式的问题, 同时又设计了细胞状态提供误差缓冲, 有效防止了过拟合现象。与传统卷积神经网络相比, LSTM 可以显式处理序列前后依赖关系, 自适应调节记忆时长。同时, 由于引入门控机制, 预测结果的解释性更强。相比于 LSTM 模型, 本文提供的 MF-LSTM 模型通过引入多特征输入, 解决了传统 LSTM 难以处理多特征数据的问题。下面介绍本文中所使用的 MF-LSTM 的具体构建方式。

定义 t 时刻的输入数据为 x_t , 隐状态为 h_t , 记忆单元状态为 c_t 。MF-LSTM 各层结构对于数据的运算过程如下:

(1) 遗忘层: 决定 c_t 中需要遗忘的数据, 该层输出可以表示为:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (3)$$

其中 W_f 和 U_f 表示遗忘权重矩阵, σ 为 sigmoid 激活函数, b_f 为遗忘直流偏置项。

(2) 输入门: 决定 x_t 对于 c_t 的更新系数, 输入门的输出可以表示为:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (4)$$

其中 W_h 和 U_h 表示输入权重矩阵, b_i 为输入直流偏置项。

(3) 预记忆单元状态: 对 t 时刻记忆单元状态的估计值, 可以表示为:

$$\hat{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (5)$$

其中 W_h 和 U_h 表示预记忆权重矩阵, $\tanh$ 为双曲正切函数, b_i 为预记忆直流偏置项。

(4) 输出门: 决定 x_t 对于 c_t 的更新系数, 输出门的输出可以表示为:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (6)$$

其中 W_o 和 U_o 表示输出权重矩阵, b_o 为输出直流偏置项。

(5) 记忆单元状态更新: t 时刻的记忆单元状态 c_t 由记忆单元状态 c_{t-1} 、遗忘层输出 f_t 、预记忆单元状态 $\hat{c}_t$ 和输入门输出 i_t 计算得到, 其更新方式如下:

$$c_t = f_t c_{t-1} + i_t \hat{c}_t \quad (7)$$

(6) 隐状态更新: t 时刻的隐状态 h_t 由输出门输出 o_t 和记忆单元状态 c_t 计算得到, 具体更新方式如下:

$$h_t = o_t \tanh(c_t) \quad (8)$$

多维度输入尺度为使得 MF-LSTM 能够处理多特征数据。MF-LSTM 通过学习历史数据中的多维度时间特征与流量特征, 能够有效捕捉流量数据中的周内差异与日内差异带, 准确获取双周期性变化与非线性变化, 并捕捉多特征之间的依赖关系, 有效地提高了对流量数据的预测能力, 从而为后续自适应节能策略提供了基础数据。

2 基于 K-means 聚类算法的自适应节能策略

2.1 K-means 聚类算法

在基站节能方法中, 可以根据预测结果判断是否需要开启节能模式。传统方法通过设定固定的流量阈值进行判断, 该方法虽然实现简单, 但是由于阈值需人工调整, 无法适应不同基站的流量分布变化。除此之外, 由于仅依赖单一流量指标进行判决, 传统方法对突发流量敏感, 所设计的策略在实际应用中难以起到稳定的效果。

本文采用 K-means 聚类算法将预测结果区分为两簇, 基于流量数据分布得到自适应判决门限, 同时通过簇心距离过滤异常点。算法具体实现流程如下:

(1) 从数据集 X 中随机均匀选择一个观测值。所选观测值是第一个簇心, 表示为 e_1 。

(2) 计算从每个观测值到 e_1 的距离。将 e_i 和观测值 n 之间的距离表示为 $d(x_n, e_i)$ 。

(3) 从 X 中随机选择下一个簇心 e_2 , 选择概率为:

$$\frac{d^2(x_n, e_1)}{\sum_{n=1}^N d^2(x_n, e_1)} \quad (9)$$

其中, x_n 是第 n 个观测值, e_1 是第一个簇心, $d(\cdot)$ 表示欧氏距离函数。

(4) 计算从每个观测值到每个簇心的距离, 并将每个观测值分配给其最近的簇心。

(5) 从 X 中随机选择质心 q , 选择概率为:

$$\frac{d^2(x_n, e_q)}{\sum_{(h; x_h \in C_q)} d^2(x_h, e_q)} \quad (10)$$

其中, e_q 表示第 q 个候选簇心, C_q 表示当前分配给 e_q 的观测值集合。选择每个后续簇心时, 其选择概率与它到已选最近簇心的距离成比例。

(6) 重复步骤 (4), 直到选择了 k 个簇心。

在上述实现流程中, K-means 使用两阶段迭代算法来最小化点到簇心的距离总和, 该距离总和覆盖所有 k 个簇心。为了判断基站在该时间段是否需要节能, 本文

中设置簇心个数为 2, 并将聚类后得到的两类分别解释为需要节能与无需节能两个状态。

2.2 自适应节能策略

由于现阶段基站关断与开启需要大功率支持, 如果仅依赖于聚类得到的结果进行节能判断, 可能导致基站关断和开启过于频繁, 降低节能效率。同时, 在节假日或大型活动期间, 为了保证服务质量, 基站有必要维持恒定开启状态。因此, 需要通过计算一天中需要节能状态的最长连续时间段, 并通过运营商提供的节假日日程表以及活动预告数据确定该日期是否为节假日或存在大型活动, 综合制定节能策略。具体流程如下:




图2 自适应节能策略算法流程

3 实验结果与分析

3.1 数据集与实验环境

本文所用数据集为江苏省部分地区 5G 基站流量数据集, 时间跨度为 2025 年 6 月 5 日 0 时至 2025 年 6 月 23 日 5 时。数据预处理后基站 1 数据可视化如下:




图3 基站1历史流量数据

表1 实验环境

配置类别	实验配置
开发环境	Python3.8.20
处理器	AMD Ryzen 9 7945HX
显卡	NVIDIA GeForce RTX 4060 Laptop GPU
关键库文件	Torch 1.7.1
内存	2*16GB DDR5 Samsung

3.2 流量预测结果分析

为了验证基于 MF-LSTM 的流量数据预测方法的有效性, 下文给出流量数据预测结果, 并对本文中的 MF-LSTM 进行对比实验与消融实验。




图4 基站1整体流量数据预测值与真实值（基于前24小时预测）

图 4 中从历史预测数据与真实流量数据的整体预测趋势匹配度来看, 数据具有趋势一致性, 即历史预测曲线与真实曲线在大部分时段呈现相似波动趋势。

图 5 展示了 2025 年 6 月 21 日(周六)内流量数据预测值与真实值。在 0-6 时凌晨低谷期和 14-16 时午间平缓期拟合良好, 表明模型成功捕捉到基站的昼夜周期模式。由于周六为休息日, 流量相对于前 24 小时工作日偏高, 所以历史数据与预测流量的周内特

征不同, 模型通过对周内特征学习, 发掘了周内数据的周期性, 从而保证了预测的精度。以上结论表明模型通过 72 小时历史数据有效学习了基站流量的双周期特征。然而, 模型仍然存在一定程度的偏差, 主要表现在 8-10 时与 17-19 时的持续高估, 这两段时间分别为早通勤高峰与晚通勤高峰, 这表明模型可能难以捕捉用户通勤习惯等特征, 需要在进一步的工作中研究。




图 5 2025 年 6 月 21 日(周六)流量数据预测值与真实值

表 2 MF-LSTM 在不同基站上的实验结果			
基站类别	MSE	RMSE	R^2
基站 1	0.0031	0.0559	0.9415
基站 2	0.0033	0.0577	0.9383
基站 3	0.0039	0.0627	0.9280
基站 4	0.0034	0.0585	0.9355
基站 5	0.0036	0.0598	0.9333

表 2 中基站 1 位于商场, 基站 2、基站 4、基站 5 位于住宅, 基站 3 位于工业园区。所有基站的决定系数 R^2 均大于 0.92, 表明模型可解释 92% 以上的流量波动, 实现了较为精准的预测。同时, 在不同场景下 MF-LSTM 具有误差一致性, 其中归一化 MSE 稳定在 0.0031~0.0039 区间, 归一化 RMSE 稳定在 0.0559~0.0627 区间, 这表明了模型跨基站泛化能力优异。由于基站 1 位处商场, 用户行为规律性强, 周期特征显著, 所以预测精度在所测场景中达到最优。基站 2、4、5 位处住宅, 预测精度指标相近, 这表明了 MF-LSTM 对一般场景的有效性 with 稳定性。基站 3 位处工业园区, 可能产生交接班等突发情况导致流量局部波动, 从而影响模型的预测精度。

表 3 对比实验	
预测方法	R^2
MF-LSTM	0.9326
ARIMA	0.8327
RNN	0.7924

表 3 中展示 MF-LSTM 的对比实验数据。从该表中可以发现, MF-LSTM 方法取得了最优的预测精度。由于 ARIMA 难以捕获时间特征信息, 在工作日与休息日交接时流量误差激增, 导致预测精度较 MF-LSTM 下降 10.01%。而 RNN 因梯度消失问题, 难以建模基站流量的周内、天内双周期特征, 导致预测精度较 MF-LSTM 下降 14.02%。

表 4 消融实验	
预测方法	R^2
MF-LSTM	0.9326
LSTM	0.8783

表 4 内容为 MF-LSTM 的消融实验数据。移除多特征机制后, MF-LSTM 模型退化为单输入 LSTM。经

过对比 MF-LSTM 与 LSTM 方法后, 可以发现加入多特征机制后的 MF-LSTM 可以解决传统 LSTM 时序模型特征单一问题, 通过引入多维时间数据, 提升对双周期特征的捕获能力, 预测精度较 LSTM 提升 5.43%。

3.3 基站节能结果分析

在现有技术方案中, 一般认为流量是影响能耗的重要指标^[8]。本文中假设基站能耗与该时间段流量成正

比关系, 并基于此分析基站自适应节能策略效果。

图 6 展示了每日的节能效果。可以看到, 自适应节能策略每天为基站节约 7%以上的能耗。由于采用自适应方式进行节能标准制定, 考虑到了历史数据的变化方式, 所以自适应节能策略可以一定程度上保证用户服务质量, 解决了传统方案中依赖人工设定阈值, 忽视服务质量的问题。




图 6 日节能效果对比图

表 5 基站节能效果指标

节能指标	指标数据
原始总能耗	11,709,156
节能后总能耗	10,337,888
节约能耗	1,371,267
平均节能效率	11.71%

表 5 中计算了基站节能效果指标, 其中节能方式为基站关闭, 基站在关闭时段的能耗设置为 0。原始总能耗为未启用节能策略时, 基站系统的总能耗消耗(即基准值), 节能后总能耗为采用自适应节能策略后的实际能耗消耗。节约能耗为节能策略减少的能耗消耗, 计算公式为原始能耗-节能后能耗, 平均节能效率为节能效果的归一化评估, 计算公式为节约能耗/总原始能耗 $\times 100\%$ 。上述数据表明, 本文中所提出的基站自适应

节能策略实现了基站能耗降低 11.71%。

4 结语

本文提出的基于 MF-LSTM 的基站自适应节能方案具有显著的理论价值, 同时为基站节能实践提供了完整的设计流程。所提方法通过引入多特征方法, 丰富了 LSTM 的预测特征, 有效发掘了流量数据中的双周期特征, 实现了预测精度达 92%以上, 通过自适应节能策略有效地解决了传统节能策略中由于固定阈值导致的局限性, 提高了节能策略的泛用性。本文通过对比实验、消融实验证明了所提出的 MF-LSTM 预测神经网络的有效性, 即较传统方法提高了 10.01%的性能, 对比单特征 LSTM 方法提高了 5.43%的性能。同时, 所提出的基站自适应节能策略解决了传统方法中的局限性, 使得节能门限的设计有了理论支撑, 并且可以根据历史数据变化自适应调节, 在本文使用的数据集上

的可以实现 11.71% 的平均节能效率。上述实验数据证明了本文提出的基于 MF-LSTM 的基站自适应节能方案的有效性, 并为实际设计提供了具体的性能指标。

参考文献

- [1] 付博涵, 刘思成, 廖光正, 等. 基于 T-GCN 的 4G/5G 基站节能减排智能决策系统[J]. 无线电通信技术, 2024, (04): 631-639.
- [2] 中兴通讯股份有限公司. PowerPilot 4G/5G 网络节能降耗技术白皮书[R]. 2020.
- [3] 罗鹏举, 王彪, 闫林, 等. 基于 AI 大数据的无线基站节能系统的设计与应用[J]. 数字通信世界, 2024, (03): 114-117.
- [4] PERVAIZ H, ONIRETI O, MOHAMED A, et al. Energy-efficient and load-proportional eNodeB for 5G user-centric networks: A multilevel sleep strategy mechanism[J]. IEEE Vehicular Technology Magazine, 2018, 13(4): 51-59.
- [5] 曾德泽, 李跃鹏, 赵宇阳, 等. 基于强化学习的高能效基站动态调度方法[J]. 计算机科学, 2021, 48(11): 363-371.
- [6] 周承诚, 杨明夷, GEERA 算法在 5G 基站节能的研究和实践[J]. 电信工程技术与标准化, 2025, (04): 57-62.
- [7] 王旭, 陈柯羽. 基于 5G 建网初期资源整合方案的探讨[J]. 信息技术与信息化, 2020(9): 181-184.
- [8] 毛翊君, 陆敏, 陈国军. 利用软关断功能的 5G 智能节能方法的研究与应用[J]. 通信世界, 2020(26): 32-34.

版权声明: ©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS