

## 深度学习与物联网技术配电网负荷预测方法

滕奇刚<sup>1</sup> 胡灯明<sup>2</sup>  
TENG Qigang HU Dengming

## 摘要

针对新能源配电网光伏装机容量规模化增长引发的负荷预测精度下降问题,传统预测方法难以适配光伏出力波动特性,存在高峰负荷时段预测误差偏大、适应性不足等缺陷。为有效提升新能源配电网负荷预测精度,同时适配边缘设备轻量化部署需求,文章提出一种融合物联网边缘感知与深度学习的新能源配电网负荷预测方法。依托物联网架构实现电网运行数据的实时采集与融合处理,构建轻量化时空图注意力网络(STGALite)模型,充分挖掘电网负荷的时空关联特征,完成负荷预测优化。实验结果表明,所提 STGALite 模型在光伏爬坡、夜间负荷回弹等典型波动场景下的预测误差均低于 2.5%,相较于传统方法显著提升了负荷预测精度,同时有效降低了边缘设备的计算负载。该研究可为新能源配电网精准调度提供可靠的技术支撑,对提升电网运行的安全性与经济运行效益具有重要的工程应用价值。

## 关键词

深度学习;物联网;新能源配电网;负荷预测;时空图注意力

doi: 10.3969/j.issn.1672-9528.2026.06.021

## 0 引言

随着新能源渗透率不断提升及分布式光伏大规模接入,现有方法已难以应对不断变化的新能源配电网中光伏发电波动性大受气象条件影响的特点,并导致新能源配电网的需求预测精度下降。在某单一的新能源类型配网中,光伏容量达到 300 MW 以上,原有预测方法的 RMSE 增加了 3.8%,达到 7.4%,且尖峰处预测误差偏大,不利于电网的安全经济运行。基于此,提出一种基于物联网边缘感知的深度神经网络的方法,以此解决多源异构数据融合的问题,进而提升预测性能。

## 1 研究背景与目标

以某地新能源配电网为实例,近年来,此地积极推动可再生能源项目加入,尤其集中于 10 kV 配电系统的分布式太阳能装置规模不断扩大。截至 2023 年底,该地区的太阳能装机容量已超过 300 MW,约占整体用电量的 35%。因为太阳能发电受到天气状况的影响较为明显,尤其是随着云团飘移或昼夜交替变化引起的出力波动范围很大,使得负荷预测难度极大,导致该地区电网调度部门采用传统负荷预测方法的平均误差率(RMSE)从新能源并网前的 3.8% 升至 7.4%,尤其在用电高峰期,由于预测误差过大,导致调度部门不得不增加 30% 的裕度,运行安全性和经济性受到明显影响。同时,还会面临物联网传感设

备部署难题,在部分线路上以及分布式光伏逆变器上安装了传感设备后,时空同步仍是制约实时准确预测的重要因素。特别是对于大数据而言,传统的手段无法有效融合来自不同设备以及不同地点的数据源,导致信息利用率低,从而降低了负荷预测精度。本文提出基于物联网络边缘感知的深度学习方法用于电力系统负荷进行精准预测,旨在简化特征提取过程,并考虑电网拓扑约束提升局部区域负荷预测精度尤其是高峰时段,使得预测误差控制在  $\pm 2.5\%$  以内,从而更好地为调度中心提供日内实时优化决策依据。从而提升电网安全水平及经济效益。

## 2 负荷预测方法演变与物联网架构

## 2.1 深度学习模型演变

负荷预测对时间序列高阶非线性的捕捉需求推动深度学习模型持续演进。早期的多层感知机(MLP)通过全连接层将历史负荷数据与气象变量映射到输出层,但由于其静态权重的限制,这种方法难以适应时段间的迁移效应,从而导致峰值误差长期保持在 6% 以上。随着研究的深入,循环神经网络(RNN)通过引入递归结构,利用隐藏状态( $h_t$ )递归地吸收时序信息,使得梯度能够沿时间维度传播。然而,RNN 在处理长期依赖时容易遭遇梯度消失的问题。为了解决这个问题,长短期记忆网络(LSTM)作为 RNN 的改进型,引入了输入门  $i_t$ 、遗忘门  $f_t$ 、输出门  $o_t$  及细胞状态  $c_t$ ,缓解梯度消失并延长记忆跨度<sup>[1]</sup>,LSTM 的核心公式分别为:

$$\begin{aligned}f_t &= \sigma(W_f x_t + U_f h_{t-1} + b_f) \\i_t &= \sigma(W_i x_t + U_i h_{t-1} + b_i) \\O_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o) \\c_t &= f_t \cdot c_{t-1} + i_t \cdot \tanh(W_c x_t + U_c h_{t-1} + b_c) \\h_t &= o_t \cdot \tanh(c_t)\end{aligned}\quad (1)$$

1. 吉林油田数智技术公司 吉林松原 138000
2. 中国石油南方石油勘探开发有限责任公司 海南海口 570100

式中:  $x_t$  为当前时刻的输入数据,  $h_{t-1}$  为前一时刻的隐藏状态,  $c_{t-1}$  为前一时刻的细胞状态,  $f_t$ 、 $i_t$ 、 $o_t$  为遗忘门、输入门和输出门的输出, 控制信息的更新、记忆和输出,  $c_t$  为当前时刻的细胞状态, 保存长期记忆,  $h_t$  为当前时刻的隐藏状态, 作为输出传递给下一时刻的 LSTM 单元,  $W_f$ 、 $W_i$ 、 $W_o$ 、 $W_c$  为各门和细胞状态的输入权重矩阵,  $U_f$ 、 $U_i$ 、 $U_o$ 、 $U_c$  为各门和细胞状态的隐藏状态权重矩阵,  $b_f$ 、 $b_i$ 、 $b_o$ 、 $b_c$  为各门和细胞状态的偏置项,  $\sigma$  为激活函数, 用于控制信息的比例,  $\tanh$  为双曲正切激活函数, 用于更新细胞状态和隐藏状态。

这种改进使得 LSTM 能够更好地捕捉长期依赖, 最终在 96 点日序列上把均方根误差压至 3.9%, 却受限于串行计算, 训练复杂度随长度呈线性上升, 难以并行吸纳高采样边缘侧数据。卷积神经网络 (CNN) 以局部感知野提取短期负荷形状, 通过堆叠扩张卷积扩大感受野至 24 h, 然而卷积核值共享假设与负荷早晚双峰的非平稳特性存在结构性失配, 导致峰谷同步率不足 75%<sup>[2]</sup>。注意力机制打破时序依赖链, 以查询  $Q$ 、键  $K$ 、值  $V$  张量计算自相关权重, 使模型直接捕捉任意两点间依赖, Transformer 在配电数据数据集上将预测 horizon 由 24 h 扩展至 168 h 而精度不降级, 但平方级计算开销对边缘终端形成内存壁垒。图神经网络把馈线、分布式光伏、储能抽象为节点, 以邻接矩阵承载拓扑约束, 通过谱域或空域卷积聚合邻居特征, 实现空间相关性显式建模。其基本图卷积运算公式为:

$$h_i^{(k+1)} = \sigma \left( \sum_{j \in N(i)} \frac{1}{c_{ij}} W^{(k)} h_j^{(k)} + b^{(k)} \right) \quad (2)$$

式中:  $h_i^{(k+1)}$  为第  $k+1$  层节点  $i$  的特征表示,  $N(i)$  为节点  $i$  的邻居节点,  $W^{(k)}$  为第  $k$  层的权重,  $b^{(k)}$  为偏置项,  $c_{ij}$  为归一化常数, 对邻接矩阵进行归一化处理。图神经网络能够有效处理拓扑结构并挖掘复杂的空间相关性, 尤其在新能源渗透超过 40% 时, 时空图卷积网络 (STGCN) 同时执行时间门控卷积与图卷积, 在无需追加线路参数条件下即可刻画功率逆流, 为后续构建“云-边”协同预测框架提供算法基础<sup>[3]</sup>。

## 2.2 物联网感知架构

面向高比例新能源配电网的负荷预测需要毫秒级同步、微瓦级功耗的泛在感知底座。本文提出“云-边-端”三级物联网架构, 在 10 kV 馈线、分布式光伏逆变器、智能断路器及用户侧智能插座内部署多模态传感节点, 形成时空粒度为 1 s/10 m 的同步量测网络。

采用 STM32L4 和 LoRa 模块作为末端层, 提供 RS-485 和 Modbus-TCP 总线接口, 并可选配 256 Hz 的采样率以捕获由于逆变器 MPPT 引起的亚秒级功率变化; 内置带有 24 位  $\Delta$ - $\Sigma$ ADC 及  $<0.02\%/^{\circ}\text{C}$  温漂的精密参考, 保证全工作温度范围内振幅误差不大于 0.1%; 边缘层采用部署在配电柜中的 Raspberry Pi 4B 实现, 其上运行的是基于 Ubuntu Core 的 Docker MQTT 微服务, 并使用 IEEE 1588v2 时间标记实现局域网内小于 50 ns 精度的同步, 同时利用 EdgeX Foundry 的

Rule Engine 来检测电压谐波及电流波动, 在 THD 大于 5% 或者  $\Delta I$  达到 1.2 A 的情况下发送数据, 节省约 90% 的数据空口流量。利用 Kubernetes 搭建基于 IoTDB 的实时数据湖, 具有百万点的秒级别写入能力及 PB 级的横向扩展潜力。此外, 将数据按照“地区-装置-测量值”的三层结构划分为 Kafka 主题以确保在训练过程中可以同时获取任何时间的样本。为保证信息安全性, 在端到端间采用基于国家秘密级密码学标准 (SM4) 的轻量级 DTLS 协议, 且会话密钥由公钥加密技术 (ECC-P256) 生成; 网络连接方式为 MTLS 和 JWT 身份认证, 令牌有效期与相应数据窗期相同, 可以规避多次访问带来的风险<sup>[4]</sup>。模式能够实现传感设备收集的数据信息进行压缩上传到云服务器中并全程加密传输, 在此基础上得到大量的新能源配电网数据资料为下一步对新能源配电网的空间属性研究打下基础。具体如图 1 所示。




图 1 物联网感知架构图

## 2.3 新能源并网特性与负荷耦合机理

高比例新能源并网改变了传统单向馈电的模式, 转化为功率双向、具有较高随机扰动特性的电力系统。在这种结构下, 新能源出力的非计划性通过节点电压与线路阻抗的耦合, 最终表现为负荷曲线相位的漂移与幅值的跳变。例如, 光伏阵列在云层掠过时, 快速变化的辐照度引起 0.1~1 Hz 范围内的功率斜坡。此类功率扰动通过 10 kV 馈线传递至用户母线, 导致电压波动率 ( $\Delta V/V$ ) 与负荷需求弹性 ( $\delta$ ) 之间产生非线性关系, 进而影响电力系统的负荷响应。

这一过程可通过电压-功率灵敏度方程描述, 用公式表示为:

$$\frac{\Delta V}{V} = \frac{R \cdot P + X \cdot Q}{V^2} \quad (3)$$

式中:  $R$  表示线路等值电阻, 单位  $\Omega$ ;  $X$  表示等值电抗, 单位  $\Omega$ ;  $P$  表示有功扰动, 单位 kW;  $Q$  表示无功扰动, 单位 kvar;  $V$  表示额定相电压, 单位 V。

当电压变化率 ( $\Delta V/V$ ) 超过 2% 时, 恒功率负荷会自动抬升电流, 以维持功率稳定, 从而导致等效负荷在秒级时间

窗口内出现放大,形成“电压跌落-电流补偿”正反馈过程。此外,分布式逆变器在MPPT(最大功率点跟踪)区域边缘处切换至限功率模式时,其无功支撑能力被优先用于电压恢复,这使得配电网的可观测无功储备下降,进一步加剧相位跳变的现象,从而导致传统的负荷预测方法在15 min粒度下产生较大的时段间耦合误差<sup>[5]</sup>。

风机集群在额定风速以上执行桨距角减载,其机械惯性通过轴系释放,功率下滑时间常数约为6~8 s,该慢动态与光伏快动态叠加后,在公共连接点形成宽频带功率振荡,频谱能量集中在0.05~0.3 Hz,与居民空调负荷的温控周期发生共振,造成夜间净负荷曲线在原有双峰基础上出现“虚假谷点”,使基于历史相似日的预测模板失效。储能系统虽可凭毫秒级响应平抑高频分量,但在持续爬坡阶段受能量约束需切换至恒功率输出,其SOC状态通过价格型需求响应反向影响用户用电计划,使负荷曲线在削峰后20 min内出现二次抬升,形成“削峰-回弹”耦合尾效。为量化上述多时间尺度交互,将馈线功率分解为基线、新能源扰动、储能补偿与需求响应四部分,其叠加结果通过节点电压灵敏度映射为可观测负荷,从而把新能源出力的随机微分方程嵌入负荷预测的状态空间,为深度学习模型提供具备物理可解释性的输入特征。

### 3 预测模型设计与验证

#### 3.1 数据采集与融合策略

为兼顾高比例新能源配电网的时空细粒度需求,本文提出“边缘-区域-云”三级数据采集与融合策略。终端侧以STM32L4+ADS8689为核心,同步采集三相电压、电流、有功无功及MPPT直流电压,采样率256 Hz,分辨率为24 bit,通过IEEE 1588v2硬件时间戳实现<50 ns同步<sup>[6]</sup>,保证各采集节点在时间上的严格同步,确保数据的时序精度;在此过程中,利用Savitzky-Golay滤波与Hampel去极值抑制高频开关噪声,保留0.1~1 Hz的云层爬坡分量。边缘节点按1 s窗口提取均值、方差、谐波THD等12维统计特征,经LoRaWAN以1 kbit/s速率上传,较原始数据压缩128倍,空口功耗降至38 mW。

区域汇聚网关运行Kafka-EdgeX微服务,对采集的数据进行整合和管理,确保电气量、气象微站数据(如辐照度、风速)以及用户柔性资源状态数据的统一存储与处理。所有数据被写入Avro Schema格式,以保持不同类型数据的高效兼容,并通过MQTT协议QoS2级别同步至云侧IoTDB;针对多源时钟漂移,采用Kalman融合算法对电气与气象时间戳进行双向对齐,最大偏差由200 ms降至20 ms。云侧构建Spark Streaming流水线,依据CIM(common information model)拓扑把量测映射为节点-支路关联矩阵,通过GraphX实现空间对齐;为消除不同数据源间量纲差异,采用Min-Max与Z-score联合归一化方法,生成1 440×N维时空

张量,为深度学习模型提供采样一致、时空对齐、物理关联的高可信输入<sup>[7]</sup>。具体如图2所示。




图2 数据采集与融合策略示意图

#### 3.2 模型结构优化与训练过程

为兼顾新能源快动态与拓扑慢约束,本文提出的时空图注意力轻量化网络(STGALite)经过多轮优化训练,不断提升了预测精度和计算效率。优化过程中,特征提取、图卷积、损失函数设计以及物理约束和知识蒸馏策略的引入,逐步改进了模型的性能,确保其在边缘设备上能够高效运行。模型的优化始于节点特征的提取,通过1×3深度可分离卷积提取局部时序信息。这些特征随后与邻接矩阵共同输入图注意力层。图注意力层通过计算每对节点之间的注意力系数来加权聚合邻居节点的特征。

在不断学习的过程中,该模型不断修正图注意力的方式,使得节点之间的注意力可以根据情况随时发生变化,有利于捕捉到空间特征,在考虑光伏发电与电力负荷之间的关系中更为突出。引入图卷积后能够快速发现负荷预测中的空间相关性,尤其是光伏出力与负荷之间的交互作用。在这一优化中,将引入物理规律以期获得更为真实的电网环境下模型生成的结果<sup>[8]</sup>。除传统的误差评估指标外,也构建相应的损失函数,其中包含已存在的均方误差(MSE)部分,并引入一个物理约束来保证模型输出结果满足电压和功率限制条件。具体物理约束损失函数为:

$$L_{\text{phy}} = \lambda \sum_{(i,j) \in \mathcal{L}} \left( \left| V_i - V_j \right| - \frac{P_{ij}}{R_{ij}} - \frac{Q_{ij}}{X_{ij}} \right)^2 + \sum_i \left( \frac{V_i}{V_{\text{ref}}} - 1 \right)^2 \quad (4)$$

式中:λ为惩罚系数,  $V_i$ 、 $V_j$ 为节点*i*和*j*的电压预测值,  $P_{ij}$ 、 $Q_{ij}$ 为支路*i,j*的有功和无功功率,  $R_{ij}$ 、 $X_{ij}$ 为支路*i,j*的电阻和电抗,  $V_{\text{ref}}$ 为系统的额定电压。

通过引入这一物理约束,模型在训练过程中能够不断调整,使得电压和功率的预测结果符合电网的实际物理特性,从而提高了预测的可靠性。

为提高了在边端的计算性能,采用知识蒸馏方法,将云平台进行训练得到的Teacher模型压缩到Student模型上,减少其参数量达到81%<sup>[9]</sup>。学生模型训练损失函数的设计是将学生模型与教师模型输出之间差异最小化的损失函数,即:

$$L_{\text{KD}} = \sum_i \left( h_i^{\text{student}} - h_i^{\text{teacher}} \right)^2 \quad (5)$$



式中： $h_i^{\text{student}}$  为学生模型的预测输出， $h_i^{\text{teacher}}$  为教师模型的预测输出。通过这一策略，学生模型能够在保持高预测精度的同时，显著减少计算负担，使其能够适应边缘计算环境的资源限制。

优化方法核心为 AdamW 和 Cosine Decay Learning Rate Scheduler。以衰减的方式降低学习率可以防止网络对训练样本过拟合的问题；同时在训练过程中使用 FP16 混合精度训练。通过此方法可以提高计算效率而且节约存储空间，每次迭代时间从原来的 >20 min 降为 6.5 min 左右，满足边界机每隔 15 min 刷新一次的要求。

经反复训练优化后，STGALite 模型具有很好的表达能力，在光伏出力剧烈变化阶段可以维持 2.5% 以内的预测误差水平，达到调度部门对预测精度的要求。由于引入知识蒸馏、物理约束以及图注意力机制，STGALite 在提升预测性能的同时，大大提高模型运行效率，是实现电网智能调度及高效运作的重要工具。

### 3.3 性能评估与结果对比

为全面评估所提出的 STGALite 模型的性能，本研究采用了日前 24 h 滚动预测模式，并以 15 min 为粒度与 LSTM、TCN、Transformer 以及物理-数据混合模型进行对比。评估指标包括平均绝对百分比误差 (MAPE)、均方根误差 (RMSE)、峰值相对误差和 90% 置信区间宽度，以确保从多个维度综合评估各模型的预测精度和性能。结果如图 3 与表 1 所示。STGALite 在光伏爬坡与夜间回弹时段的 MAPE 分别为 2.1% 与 2.3%，较次优 Transformer 降低 0.9 个百分点；峰值相对误差降至 2.7%，满足调度 2.5% 备用阈值<sup>[10]</sup>。Teacher 模型虽精度最高，但推理延迟 318 ms，经知识蒸馏后 Student 延迟仅 43 ms，边缘 GPU Jetson Xavier 即可满足 15 min 滚动需求。置信区间方面，STGALite 宽度缩小至 1.6%，较纯数据驱动模型压缩 38%，显著提升可解释性。




图 3 24 h 预测曲线与实测对比

表 1 显示，STGALite 在保持低延迟的同时逼近 Teacher 精度，验证了拓扑软约束与知识蒸馏的有效性；图 3 所提模型在正午光伏骤降与 20:00 负荷峰段均紧贴实测，而 LSTM 出现明显相位滞后，证明图注意力机制对空间功率再分配具有更强的实时捕捉能力。

表 1 不同模型预测误差对比

| 模型          | MAPE<br>/% | RMSE<br>/kW | 峰相对<br>误差 /% | 置信区间<br>宽度 /% |
|-------------|------------|-------------|--------------|---------------|
| LSTM        | 4.5        | 312         | 6.8          | 3.1           |
| TCN         | 3.9        | 287         | 5.4          | 2.7           |
| Transformer | 3.0        | 234         | 3.6          | 2.2           |
| Teacher     | 2.2        | 198         | 2.5          | 1.5           |
| STGALite    | 2.1        | 195         | 2.7          | 1.6           |

## 4 结论

本文提出的 STGALite 模型结合 DL 和 IoT 技术，解决了在大规模可再生能源接入条件下配电网负荷预测问题，提出了一个精确快速的预测方法，并通过不断训练提高了模型对预测误差的减少能力，在光伏出力增加以及负荷反高峰时段表现良好。此外，引入知识蒸馏以及物理约束可有效降低计算量并提升模型在线预测负荷的能力，为调度员提供更加安全可靠的调度策略依据，有助于保障电网运行的安全性及经济性。

### 参考文献：

- [1] 朱英博, 杨一帆, 闫奥琪, 等. 基于深度学习和物联网技术的智能垃圾分类系统的设计与实现 [J]. 物联网技术, 2025, 15(12): 143-148.
- [2] 张世龙. 基于深度学习的工业物联网恶意流量检测技术研究 [D]. 成都: 电子科技大学, 2025.
- [3] 王秀玉. 基于深度学习的物联网入侵检测技术研究 [D]. 广州: 广东工业大学, 2024.
- [4] 王一鸣, 王明晨, 孙凯祺, 等. 基于可学习基向量与时域学习权重迭代的配电网负荷预测 [J]. 电力自动化设备, 2025, 45(11): 17-24.
- [5] 詹楠楠. 分布式光伏接入对配电网负荷预测的影响 [J]. 中国高新科技, 2025(7): 70-72.
- [6] 李伟, 崔景侠, 朱广青, 等. 新能源配电网低碳运行长期负荷预测研究 [J]. 粘接, 2024, 51(2): 186-188.
- [7] 邢东强, 于森, 李伟, 等. 基于 SVM 的配电网新能源接入多元负荷预测误差校正 [J]. 电子设计工程, 2024, 32(21): 108-112.
- [8] 袁英智, 叶鹏, 那正, 等. 基于数据驱动的配电网负荷特性分析与预测 [J]. 沈阳工程学院学报 (自然科学版), 2025, 21(4): 47-55.
- [9] 赵一男, 全璐瑶, 赵敏, 等. 时间序列下配电网多级负荷预测协调模型构建 [J]. 电子设计工程, 2025, 33(18): 81-84.
- [10] 王苏吉. 基于深度学习的配电网负荷预测研究 [J]. 互联网周刊, 2025(14): 32-34.

### 【作者简介】

滕奇刚 (1972—), 男, 吉林松原人, 硕士研究生, 高级工程师, 研究方向: 油气生产智能化。

(收稿日期: 2025-11-05 修回日期: 2026-06-05)