

基于扩展长短期记忆网络的电力系统短期负荷预测

郁佳杰¹, 付保川^{1,2}, 朱建业¹, 韩雅明¹

(1. 苏州科技大学 电子与信息工程学院, 江苏 苏州 215009;

2. 苏州市智慧城市研究院 电子与信息工程学院, 江苏 苏州 215009)

摘要: 短期负荷预测在电力系统的运行与规划中扮演着至关重要的角色, 准确地预测负荷变化不仅能够有效支持电网的调度优化、提升电网可靠性, 而且可以为决策者提供科学依据以降低运营成本和提高系统效率; 如何构建具有柔性特征的短期负荷预测模型, 成为影响短期负荷预测准确率的关键之所在; 为了较好适应季节变化、外部环境因素以及用户行为的变化, 提出一种由 SLSTM 和 MLSTM 两种架构组成的 XLSTM 短期负荷预测模型, 并利用两种架构的优势捕捉负荷数据中空间和时间的耦合关系, 以有效缓解长时间预测后出现数据漂移而导致预测精度下降的问题; 通过利用跨季节划分的实际电力系统负荷数据进行单步预测和多步预测仿真, 并与独立的 LSTM 和 CNN-LSTM 模型进行了对比分析; 仿真结果表明, XLSTM 模型在单步预测和多步预测中的精度都明显优于其他模型, 验证了其具有较强的模型泛化性与缓解短期负荷预测数据漂移的有效性。

关键词: 短期负荷预测; 电力系统; LSTM; CNN-LSTM; X-LSTM; 模型泛化性; 数据漂移

Short-Term Load Forecasting of Power System Based on XLSTM Network

YU Jiajie¹, FU Baochuan^{1,2}, ZHU Jianye¹, HAN Yaming¹

(1. School of Electronic and Information Engineering, Suzhou University of Science and Technology,
Suzhou 215009, China;

2. School of Electronic and Information Engineering, Suzhou Smart City Research Institute,
Suzhou 215009, China)

Abstract: Short-term load forecasting plays a critical role in the operation and planning of power systems. To accurately predict in load, it can not only effectively optimize power grid dispatching and improve grid reliability, but also provide a scientific basis for decision-makers to reduce operational costs and improve system efficiency. How to construct a short-term load forecasting model with flexible features, it will become the key factor affecting the accuracy of short-term load forecasting. In order to better adapt to changes in seasons, external environments, and user behavior, this paper proposes an extended long short-term memory (XLSTM) model, which integrates stable long short-term memory (SLSTM) and matrix long short-term memory (MLSTM) architectures. Utilizing the advantages of two architectures to capture the coupling relationship between space and time in load data, effectively mitigating prediction accuracy degradation caused by data drift after long-term prediction. Simulations are conducted for both single-step and multi-step forecasting using cross-seasonally partitioned real-world power system load data, and a comparative analysis of single long short-term memory (LSTM) and convolutional neural network (CNN)-LSTM models is made. The results demonstrate that the XLSTM model outperforms other models in single and multi-step forecasting scenarios, validating its robust generalization capability and effectiveness of alleviating data drift challenges in short-term load forecasting.

Keywords: short-term load forecasting; power system; LSTM; CNN-LSTM; XLSTM; model generalization; data drift

收稿日期:2025-02-25; 修回日期:2025-03-31。

基金项目:国家自然科学基金项目(61672371, 61803279, 61876217, 62203316);江苏省高等学校基础科学(自然科学)基金项目(21KJB120010);国家重点研发计划课题(2020YFC2006602)。

作者简介:郁佳杰(1998-),男,硕士研究生。

通讯作者:付保川(1964-),男,博士,教授。

引用格式:郁佳杰,付保川,朱建业,等. 基于扩展长短期记忆网络的电力系统短期负荷预测[J]. 计算机测量与控制, 2025, 33(8):72-78, 136.

0 引言

短期负荷预测对电力系统的运行与规划至关重要,是确保系统稳定性、可靠性和高效性的核心。通过准确预测负荷需求,运营商能够优化发电、储能与配电调度,平衡供需,避免电力中断或过载,从而实现资源的高效配置,降低运营成本,并提升整体系统效率。为了实现有效且准确的负荷预测,学术界对各种短期负荷预测(STLF, short-term load forecasting)方法的研究得到了广泛关注。这些方法主要可以分为统计方法、机器学习方法以及深度学习方法,各类方法在处理负荷预测的精度和适应性方面展现出了不同的优势和挑战,推动了该领域的持续发展与创新。

长期以来,统计模型一直是短期负荷预测的核心方法,其优势在于简单性、计算速度以及利用数学原理识别历史数据中的模式,如线性回归和ARIMA模型^[1]。然而,这些方法依赖于数据平稳性的假设,且在面对高度非线性和动态波动的电力负荷数据时表现不足,从而影响复杂模式的预测准确性。早期的STLF应用主要依赖于指数平滑^[2]、ARIMA^[3]、灰色模型^[4]和卡尔曼滤波器^[5]等传统统计方法,这些模型在处理线性关系时有效,但对复杂非线性数据尤其是大规模数据集的处理能力有限,且随着预测期延长,准确性逐渐下降。近年来人们提出了一些机器学习方法,如反向传播神经网络(BPNN, back propagation neural network)^[5]、支持向量机^[6]、极限学习^[7]、模糊逻辑^[8]。与早期方法相比,这些模型在预测精度上取得了显著提升,且结合模糊C-均值聚类 and 全局优化算法等技术,进一步优化了预测性能。然而,随着负荷数据量和维度的不断增加,传统机器学习方法仍面临处理高维、大容量数据的挑战,这推动了深度学习技术的发展。文献[9]和[10]提出使用长短期记忆网络(LSTM, long short-term memory)来短期电力负荷预测。LSTM网络通过引入存储单元保留历史信息,解决了这一问题,显著提升了负荷预测的准确性。卷积神经网络(CNN, convolutional neural network)在从数据中提取空间特征方面表现突出,为负荷曲线中的模式和上下文信息提供重要洞察。文献[11]和[12]提出了一种使用卷积神经网络-长短期记忆网络(CNN-LSTM)的短期电力负荷预测模型,将CNN与LSTM或GRU(Gated Recurrent Unit)结合,能够有效融合空间和时间特征,进一步优化负荷预测。

深度学习技术面临的挑战之一是数据漂移,这一问题源于历史数据和用户消费模式的变化,导致模型随时间推移而性能下降,尤其在智能电网(SG, smart

grid)、动态模型(DGM, dynamic game model)和其他在线环境学习框架(ELF, executable and linkable format)中尤为突出^[13]。数据漂移的存在加剧了这些环境中的ELF复杂性,使得模型适应和更新的难度增加。模型的泛化能力也是近年来基于深度学习进行短期负荷预测的主要研究内容之一。在实时性与精度要求高的场景中,需要负荷预测的结果更准确,才能满足实时控制的需求。在长期调度与资源规划场景中,例如微电网的应用场景需要直接或间接预测未来多个连续时间点的负荷值,帮助管理者提前制定发电计划(如启停柴油机组)、储能充放电策略(如低谷充电、高峰放电),以及优化与主电网的能量交互(如低价购电时段)。

在上述研究的基础上,本文提出了一种结合稳定长短期记忆网络(SLSTM, stable long short-term memory)和矩阵长短期记忆网络(MLSTM, matrix long short-term memory)模型的扩展长短期记忆网络(XLSTM, extended long short-term memory)短期电力负荷预测方法,通过赋予LSTM修改存储决策的能力和提高了LSTM存储容量,XLSTM能够有效抑制数据漂移的发生从而高效预测电力负荷。实验数据采用中国某地电力系统的实际负荷数据。使用跨季节的划分方式对模型进行训练、验证和测试。同时对该XLSTM模型进行单步和多步预测,以验证XLSTM模型在不同的应用场景下的泛化能力。最后将所提模型的预测结果与CNN-LSTM和LSTM模型的结果进行了单步预测与多步预测综合比较,结果表明所提模型性能更优。

1 改进长短期记忆网络模型

1.1 传统 LSTM

LSTM是一种RNN架构,旨在捕获序列数据中的长期依赖关系,克服了传统RNN的缺点。LSTM可以解决消失梯度问题的挑战,在传统RNN中,当梯度在时间反向传播过程中呈指数级减少时,就会出现消失梯度问题。这个问题阻碍了RNN有效捕获远程依赖关系的能力。LSTM架构的核心是存储单元,它可以长时间存储信息。这些存储单元具有独特的结构,允许它们根据输入序列的上下文选择性地学习和忘记信息。这种选择性内存管理是通过以下3个主要组件实现的:输入门、遗忘门和输出门。LSTM的数学运算可以用以下方程式给出:

$$z_t = \varphi(\tilde{z}_t), \tilde{z}_t = \mathbf{w}^T \mathbf{z}_t + r_z h_{t-1} + b_z \quad (1)$$

$$i_t = \sigma(\tilde{i}_t), \tilde{i}_t = \mathbf{w}_i^T x_t + r_i h_{t-1} + b_i \quad (2)$$

$$f_t = \sigma(\tilde{f}_t), \tilde{f}_t = \mathbf{w}_f^T x_t + r_f h_{t-1} + b_f \quad (3)$$

$$o_t = \sigma(\tilde{o}_t), \tilde{o}_t = \mathbf{w}_o^T x_t + r_o h_{t-1} + b_o \quad (4)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot z_t \quad (5)$$

$$h_t = o_t \tilde{h}_t, \tilde{h}_t = \psi(c_t) \quad (6)$$

权重向量 w_z^x, w_i^x, w_f^x 和 w_o^x 分别为输入 x_t 和单元输入、输入门、遗忘门和输出门之间的输入权重向量。权重 r_z, r_i, r_f 和 r_o 分别对应于隐藏状态 h_{t-1} 和单元输入、输入门、遗忘门和输出门之间的循环权重。 b_z, b_i, b_f 和 b_o 是相应的偏差项。 ψ 是单元输入和隐藏状态激活函数（通常是 $\tan$ ）。 ψ 用于归一化或压缩细胞状态，门激活函数 $\sigma(x) = 1/[1 + \exp(-x)]$ 。

1.2 扩展长短期记忆网络 (X-LSTM)

尽管 LSTM 取得了巨大成功，但在进行负荷预测时仍然存在 3 个主要局限性：1) 无法修正存储决策。当找到更相似的向量时，LSTM 难以修正已存储的值；2) 存储容量有限，即信息必须压缩为标量单元状态；3) 由于内存混合（即从一个时间步到下一个时间步的隐藏状态之间的隐藏—隐藏连接）导致缺乏并行性，这使得处理必须按顺序进行。由于这些局限性导致短期负荷预测时频繁出现漂移，降低了预测模型的准确性和稳定性，使其难以适应动态变化的负荷模式。数据分布的时变性导致模型训练时所依赖的历史统计特性失效，从而引发预测误差累积、模型退化以及泛化能力下降。此外，漂移可能削弱模型对异常值和突发变化的适应性，增加负荷管理和调度的不确定性，最终影响能源系统的优化调度和运行效率。而 XLSTM 通过指数门控和矩阵记忆有效解决了这些局限性所带来的主要问题，从而提升预测模型的准确性和稳定性。

XLSTM 架构由基础单元层、指数门控层、残差块层、堆叠架构层组成，如图 1 所示。




图 1 扩展长短期记忆网络 (XLSTM) 架构

1) 基础单元层：具有常数误差回旋和门控机制的原始 LSTM 记忆单元，提供基本的时间依赖建模能力，通过门控机制（输入门、遗忘门、输出门）控制信息流动。

2) 指数门控层：引入指数门控机制的新 SLSTM 和 MLSTM 记忆单元。SLSTM 将门控函数替换为指数激活，增强梯度传播和非线性表达能力；通过新记忆混

合生成动态权重，优化长期依赖建模。MLSTM 具有新颖的矩阵记忆单元状态和新的协方差更新规则，捕捉特征间协方差关系，提升模型对复杂模式的表征能力。矩阵运算天然适配 GPU 加速，避免传统 LSTM 的顺序依赖实现完全可并行化。

3) 残差块层：在残差块的设计中，MLSTM 与 SLSTM 的协同机制通过三步递进实现高效融合。首先，输入序列并行输入至 MLSTM 和 SLSTM 单元，MLSTM 以矩阵化状态和协方差更新规则聚焦多维特征的局部协方差结构（如时序周期性片段），而 SLSTM 通过指数门控动态混合长程记忆权重，强化跨时间步依赖建模；随后，二者的输出（矩阵与向量）经线性变换对齐维度后，通过残差融合，既保留原始输入信息以缓解梯度消失，又整合 MLSTM 的高维协方差特征与 SLSTM 的长程动态记忆；最终，残差结构使梯度可直接回传至浅层网络，解决传统 LSTM 堆叠时的梯度退化问题，从而在深层架构中实现局部模式捕捉与全局依赖建模的协同优化。

4) 堆叠架构层：按顺序堆叠的 XLSTM 块形成 XLSTM 架构。浅层聚焦局部时序波动，深层通过残差梯度传播整合全局依赖，形成兼顾并行效率、长程建模与复杂特征表达的时序网络，显著提升了在长序列预测、多变量分析等任务中的性能。

1.2.1 稳定长短期记忆网络 (SLSTM)

赋予 LSTM 修改存储决策的能力，引入了指数门以及规范化和稳定化。特别是，输入门和遗忘门可以具有指数激活函数。为了规范化，引入一个规范化器状态，该状态将输入门与所有未来遗忘门的乘积相加。SLSTM 的数学运算可以用以下方程式给出：

$$z_t = \varphi(\tilde{z}_t), \tilde{z}_t = w_z^T x_t + r_z h_{t-1} + b_z \quad (7)$$

$$i_t = \exp(\tilde{i}_t), \tilde{i}_t = w_i^T x_t + r_i h_{t-1} + b_i \quad (8)$$

$$f_t = \sigma(\tilde{f}_t) \text{OR} \exp(\tilde{f}_t), \tilde{f}_t = w_f^T x_t + r_f h_{t-1} + b_f \quad (9)$$

$$o_t = \sigma(\tilde{o}_t), \tilde{o}_t = w_o^T x_t + r_o h_{t-1} + b_o \quad (10)$$

将原始的 LSTM 门控技术，即输入和/或隐藏依赖的门控加上偏置项，推广到新的架构中。指数激活函数可能导致大值，从而导致溢出。因此用额外的状态 m_t 来稳定门控：

$$m_t = \max[\log(f_t) + m_{t-1}, \log(i_t)] \quad (11)$$

$$i'_t = \exp[\log(i_t) - m_t] = \exp(\tilde{i}_t - m_t) \quad (12)$$

$$f'_t = \exp[\log(f_t) + m_{t-1} - m_t] \quad (13)$$

1.2.2 矩阵长短期记忆网络 (MLSTM)

使用双向联想记忆 (BAM, bidirectional associative memory) 提高 LSTM 的存储容量，使用 BAM 的设置^[14-15]。将 LSTM 存储单元从标量 $C \in R$ 增加到矩阵 $C \in R^{d \times d}$ 。因此，检索是通过矩阵乘法进行的。在时间

t , 存储一对向量, 键 $\mathbf{K}_t \in R^d$ 和值 $\mathbf{V}_t \in R^d$ 。稍后在时间 $t+\tau$, 值 $\mathbf{V}_t$ 应通过查询向量 $\mathbf{Q}_{t+\tau} \in R^d$ 检索。用于存储键值对的协方差更新规则为:

$$C_t = f_t C_{t-1} + i_t \mathbf{V}_t \mathbf{K}_t^\top \quad (14)$$

MLSTM 的数学运算可以用以下方程式给出:

$$n_t = f_t n_{t-1} + i_t k_t \quad (15)$$

$$h_t = o_t \odot \tilde{h}_t, \tilde{h}_t = C_t q_t / \max\{|n_t^\top q_t|, 1\} \quad (16)$$

$$q_t = W_q x_t + b_q \quad (17)$$

$$k_t = \frac{1}{\sqrt{d}} W_k x_t + b_k \quad (18)$$

$$v_t = W_v x_t + b_v \quad (19)$$

$$i_t = \exp(\tilde{i}_t), \tilde{i}_t = \mathbf{w}_i^\top x_t + b_i \quad (20)$$

$$f_t = \sigma(\tilde{f}_t) O \operatorname{Rexp}(\tilde{f}_t), \tilde{f}_t = \mathbf{w}_f^\top x_t + b_f \quad (21)$$

$$o_t = \sigma(\tilde{o}_t), \tilde{o}_t = \mathbf{w}_o^\top x_t + b_o \quad (22)$$

MLSTM 可以像原始的 LSTM 一样拥有多个记忆单元。对于 MLSTM 而言, 由于不存在记忆混合, 多头和多单元是等效的。为了稳定 MLSTM 的指数门, 采用与 SLSTM 相同的稳定技术, 见公式 (11)。

2 基于 XLSTM 的预测模型

2.1 数据收集

从历史数据中收集负载消耗的时间序列数据, 然后检查空值以确认可靠性和准确性。

2.2 特征提取

负荷数据受时间 (小时、星期、季节)、气象 (温度、湿度)、社会活动 (节假日、事件) 等多维度因素影响。特征提取需将原始数据转化为模型可理解的形式。

本文创建了新的特征, 其中包括月份索引 $\{M = 1, 2, \dots, 12\}$: 夏季空调用电和冬季供暖用电呈现显著差异, 月份是强季节性指标;

工作日指数 $\{M = 0, 1, 2\}$: 工作日与周末的工商业活动强度不同 (如工厂周末停工、居民周末用电晚高峰延后), 考虑工作时间不同 0 为周一至周五, 1 为周六, 2 为周日;

小时指数 $\{H = 0, 2, \dots, 23\}$: 是指每个时段负荷的变化幅度, 例如上海居民区晚高峰 (18:00~20:00) 负荷可达谷值的 3 倍。

2.3 归一化处理

对提取的特征使用 min-max 技术对特征进行归一化, 如下所示:

$$x_{\text{nom}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (23)$$

在短期负荷预测中, 归一化处理可以消除特征量差异统一数据尺度, 避免梯度优化震荡并加速模型收敛; 将输入约束至激活函数敏感范围, 防止梯度饱和以增强

波动捕捉能力; 同时剥离绝对数值依赖、抑制异常值干扰, 提升跨场景泛化性, 并平衡多模态特征 (连续变量与离散编码) 的交互权重, 确保模型精准融合时序、环境等多维信息, 最终实现高鲁棒性负荷预测。

2.4 时间序列构造

为输入序列确定一个长度 T 。在对输入特征进行归一化处理后, 序列可以按以下方式构建: 前 T 个时间步的每小时负荷消耗; 前 T 个时间步的月份索引; 前 T 个时间步的工作日索引; 前 T 个时间步的小时索引。归一化处理后, 输入特征被转换为 [样本数, 时间步数, 特征数] 的形状。

2.5 预测模型

XLSTM 模型由两个核心模块构成。在残差 SLSTM 模块中, 输入数据首先通过 SLSTM 层进行处理, 随后接入带有门控机制的多层感知器 (MLP, multi-layer perceptron) 进行特征提取。另一个残差 MLSTM 模块采用预投影结构, 该模块通过单层一维卷积操作进行预处理, 其卷积核尺寸设定为 2, 并配置由 100 个神经元构成的单层网络, 同时引入可学习的跳跃连接机制和按分量作用的输出门控制, 整个结构被封装在两个 MLP 之间。为避免神经元数量设置不当引发的训练问题, 模型在卷积层后接入扁平化层将特征转换为一维向量, 继而通过两个全连接层完成数据整合。其中初始全连接层配置 50 个神经元, 末层作为输出层形成最终预测结果 (过多神经元数量会导致训练时间剧增, 且可能过拟合历史噪声, 导致未来预测波动大; 过少的神经元数量会使模型欠拟合, 无法捕捉负荷突变)。在训练过程中, 使用 Adam 优化器最小化均方误差 (MSE) 损失函数。为平衡训练稳定性与收敛速度, 特别设计学习率热启动策略: 前 10 个 epoch 从 1×10^{-5} 线性增至 1×10^{-3} , 该机制既能有效缓解梯度爆炸风险, 又可避免模型陷入局部最优解而丧失对负荷突变的捕捉能力 (过高的学习率会导致训练不稳定, 预测结果在相邻时刻出现剧烈抖动; 过低的学习率会使模型收敛至局部最优, 无法适应负荷快速变化)。

本文针对不同的应用场景使用不同的预测手段, 有效增强模型的泛化力, 单步预测与多步预测的结果可以全面体现 XLSTM 模型在负荷预测中的优势。

单步预测为下一时间步创建一个输出值 $Y_t = \{d_{t+1}\}$ 。单步预测模型通常基于最新数据 (如当前天气、设备状态等), 结果更准确, 适用于实时性与高精度场景, 适合实时控制。

多步预测创建输出序列 $Y_t = \{d_{t+1}, d_{t+2}, \dots, d_{t+N}\}$ 用于以下 N 个时间步长。直接或间接预测未来多个连续时间点的负荷值, 适用于长期调度与资源规划, 帮助微

电网管理者提前制定发电计划（如启停柴油机组）、储能充放电策略（如低谷充电、高峰放电），以及优化与主电网的能量交互（如低价购电时段）。

3 仿真结果

本节采用真实的电力负荷需求数据，对 XLSTM 短期负荷预测模型进行单步预测和多步预测仿真实验，将仿真结果与其他模型的单步预测和多步预测结果进行综合对比分析，验证 XLSTM 短期负荷预测模型在不同应用场景中的泛化能力，能否缓解负荷预测中出现数据漂移导致的预测精度下降问题。

3.1 仿真条件设置

图 2 为电力负荷需求数据，实验数据来源于中国华东地区某城市电网运营中心提供的 2023 年 1 月至 2024 年 1 月完整年度电力负荷数据，原始数据通过智能电表采集系统（AMI, advanced metering infrastructure）^[16-18] 以每小时为采样间隔实时上传至电网数据中心。数据集包含 8 760 个样本。训练数据来自 2023 年 1~4 月（共 2 880 个样本），而验证数据来自 2023 年 5~8 月（共 2 880 个样本）。2023 年 9~12 月的数据（共 2 928 个样本）用于测试所开发的预测模型的性能。跨季节的划分方式虽使模型面临季节性挑战，但通过特征工程、模型架构优化和验证策略调整，能有效提升预测系统的工程泛化性。其本质是将“季节性差异”转化为模型必须克服的预测障碍，而非回避的干扰因素，更符合电力系统对跨周期稳定预测能力的核心需求。




图 2 某市 2023~2024 年电力负荷需求数据

数据预处理采用邻近时段加权平均插补缺失值（0.35%）、改进 Z-score 法（阈值 3.5σ ）修正异常值^[19]、Savitzky-Golay 滤波器降噪^[20]、Min-Max 归一化标准化，并融合气象数据及节假日特征，同时通过 NTP 协议实现毫秒级时间对齐。数据集经国家电网 DL/T 645-2007 认证设备采集（精度 0.5S 级），确保数据可靠性

及可复现性。

3.2 性能指标

本研究使用以下性能指标来评估预测结果：

$$RMSE = \sqrt{\frac{1}{K} \sum_{k=1}^K (y_k - \hat{y}_k)^2} \tag{24}$$

$$MAE = \frac{1}{K} \sum_{k=1}^K |y_k - \hat{y}_k| \tag{25}$$

$$MAPE = \frac{1}{K} \sum_{k=1}^K \left| \frac{y_k - \hat{y}_k}{y_k} \right| \tag{26}$$

RMSE 为均方根误差，对大幅误差敏感，RMSE 的高敏感性可帮助识别模型在尖峰负荷（如突增/突降）时的表现。

MAE 为平均绝对误差，MAE 直接计算预测值与实际值的平均绝对偏差，比较直观，适合日常运营中的快速决策。

MAPE 为平均百分比误差，MAPE 以百分比形式表达误差，便于横向比较不同规模微电网（如社区级 vs. 工业级）或不同时间段的预测性能。

3.3 单步预测

对 XLSTM 使用不同长度的输入序列进行测试，以确定单步超前预测的合适输入序列长度。如表 1 所示，通过选择 48 步序列，XLSTM 模型在平均绝对误差（MAE）、平均绝对百分比误差（MAPE）和均方根误差（RMSE）指标上取得了最低值的最佳结果。这表明跨越 48 个时间步的回溯窗口可以为模型提供最相关的历史信息，以进行准确预测。

表 1 不同输入序列长度下单步预测的结果

时间步长	RMSE/MW	MAE/MW	MAPE/%
2	46.185 1	30.855 5	1.543 4
4	44.673 0	30.260 9	1.524 7
8	43.680 1	29.467 9	1.482 0
12	42.869 3	28.937 3	1.450 4
16	42.724 7	28.374 3	1.415 7
20	42.359 1	28.409 5	1.427 0
24	42.449 3	28.061 5	1.450 4
48	42.429 3	27.739 8	1.436 5
72	43.871 4	30.223 0	1.504 5
120	43.097 0	28.300 1	1.432 1
144	42.587 9	28.870 3	1.451 3
168	43.171 9	29.287 7	1.459 7

表 2 展示了 2023 年 9~12 月的预测准确率。值得注意的是，2023 年 11 月取得了最佳预测结果。这意味着该模型在捕捉和预测该特定月份的模式方面表现出色。图 3 展示了 2023 年最后 4 个月的单步预测结果。从这些图中，可以观察到每个月预测值与实际值。此分

析为该特定期模型的预测性能提供了有价值的见解。可以看出, 预测的负荷值与实际数据非常吻合, 展示了该预测模型准确预测单步负荷的有效性。

表 2 同月份单步预测结果

时间步长	RMSE/MW	MAE/MW	MAPE/%
九月	42.116 9	29.954 9	1.585 3
十月	51.259 0	28.178 3	1.437 4
十一月	35.131 9	25.225 8	1.225 8
十二月	39.597 3	27.593 8	1.371 2




图 3 10~12 月份的单步预测结果

3.4 多步预测

在本节中, 使用 XLSTM 进行 24 步超前预测。图 4 展示了 2023 年最后 4 个月的单步预测结果。从这些图中, 可以观察到每个月预测值与实际值。此分析为该特定期模型的预测性能提供了有价值的见解。表 3 展示了考虑不同输入序列长度时, XLSTM 模型在多步预测中的性能比较。对不同输入序列长度的分析凸显了选择合适回溯窗口大小的重要性, 因为它直接影响所提出模型的有效性。从表 4 可以看出, 通过使用 24 步输入序列来预测 24 步的时间范围, 在多步预测中实现了最




图 4 10~12 月份的多步预测结果

高的准确率。

表 3 不同输入序列长度下的多步预测结果

时间步长	RMSE/MW	MAE/MW	MAPE/%
24	86.616 6	61.552 8	3.114 3
48	92.694 1	67.626 7	3.395 7
72	93.945 6	66.311 6	3.313 6
120	94.230 6	65.910 3	3.378 0
144	90.447 3	63.156 6	3.258 0
168	96.615 5	69.443 5	3.494 7

表 4 不同月份的多步预测结果

时间步长	RMSE/MW	MAE/MW	MAPE/%
九月	100.895 9	74.265 4	4.073 3
十月	74.086 1	53.452 5	2.735 6
十一月	79.476 0	58.740 0	2.754 8
十二月	89.864 0	60.091 7	2.914 6

3.5 性能比较

表 5 比较了 XLSTM、LSTM 和 CNN-LSTM 模型的预测结果。可以观察到，在这 3 个模型中，XLSTM 模型的平均绝对误差（MAE）、平均绝对百分比误差（MAPE）和均方根误差（RMSE）值最小。XLSTM 模型结合了两种架构的优势，结合 SLSTM 和 MLSTM 模型的 XLSTM 短期电力负荷预测方法，通过赋予 LSTM 修改存储决策的能力和提高了 LSTM 存储容量，提高了预测性能。XLSTM 电力负荷模型同时在单步预测和多步预测中都获得最佳预测误差这一事实表明，在该数据集中它优于其他两个模型，验证了其具有较强的模型泛化性与缓解短期负荷预测数据漂移的有效性。

表 5 不同模型的预测性能比较

预测方法	单步预测			多步预测		
	RMSE /MW	MAPE /MW	MAE /%	RMSE /MW	MAPE /MW	MAE /%
XLSTM	42.49	27.73	1.40	86.61	61.55	3.11
LSTM	46.24	32.49	1.62	90.12	64.73	3.32
CNN-LSTM	43.54	28.61	1.45	93.33	64.16	3.23

4 结束语

本文提出了一种结合 SLSTM 和 MLSTM 的 XLSTM 短期电力负荷预测模型。使用跨季节划分的真实电力系统的负荷需求数据集，跨季节划分通过特征工程与模型架构优化将季节性差异转化为预测障碍，契合电力系统对跨周期稳定预测能力的核心需求。同时从单步预测和多步预测验证 XLSTM 的预测性能，单步预测适用于实时性与高精度场景，适合实时控制；多步预测适用于长期调度与资源规划。

预测结果表明，XLSTM 模型成功捕捉到了每小时

负荷需求数据集的潜在模式和动态。此外，通过与其他模型的对比分析，所开发的模型无论是在单步预测中还是在多步预测中均获得了最佳的平均绝对误差、平均绝对百分比误差和均方根误差。因此所提出的 XLSTM 负荷预测模型可以有效缓解负荷预测出现数据漂移与模型泛用性不强的问题，对于提升短期电力负荷预测的准确性展现出一定潜力，在需要单步预测的高精度科研领域和需要多步预测的并网型微电网优化调度等应用中均有不错的表现。

未来研究可以聚焦于短期负荷预测模型的自适应性。构建时空图神经网络与 XLSTM 的混合架构以解析多能源耦合动态，开发在线变分增量学习框架实现漂移自适应。

参考文献：

[1] LEE C M, KO C N. Short-term load forecasting using lifting scheme and ARIMA models [J]. Expert Systems with Applications, 2011, 38 (5): 5902 - 5911.

[2] EREN Y, KÜ ÇÜKDEMIRAL İ. A comprehensive review on deep learning approaches for short-term load forecasting [J]. Renewable and Sustainable Energy Reviews, 2024, 189: 114031.

[3] JIANG Y, GAO T, DAI Y, et al. Very short-term residential load forecasting based on deep-autoformer [J]. Applied Energy, 2022, 328: 120120.

[4] LIU Y, ZHENG R, LIU M, et al. Short-term load forecasting model based on time series clustering and transformer in smart grid [J]. Electronics, 2025, 14 (2): 230.

[5] ELMENSHAWY M S, MASSOUD A M. Short-term load forecasting in active distribution networks using forgetting factor adaptive extended Kalman filter [J]. IEEE Access, 2023, 11: 103916 - 103924.

[6] PAN L, FENG X, SANG F, et al. An improved back propagation neural network based on complexity decomposition technology and modified flower pollination optimization for short-term load forecasting [J]. Neural Computing and Applications, 2019, 31: 2679 - 2697.

[7] 江 伟, 马 光, 涂卫平, 等. 基于云边协同的微电网自动控制系统 [J]. 计算机测量与控制, 2023, 31 (12): 117 - 122.

[8] YANG A, LI W, YANG X. Short-term electricity load forecasting based on feature selection and least squares support vector machines [J]. Knowledge-Based Systems, 2019, 163: 159 - 173.

[9] WANG X, WANG H, LI S, et al. A reinforcement learning-based online learning strategy for real-time short-term load forecasting [J]. Energy, 2024, 305: 132344.

(下转第 136 页)