

doi: 10.11835/j.issn.1000-582X.2026.06.010

引用格式:王兵,杨青山,蒋有高,等.基于 xLSTM 的大型水资源配置工程多区域电力消耗预测算法[J].重庆大学学报,2026,49(6): 103-116.



基于 xLSTM 的大型水资源配置工程多区域 电力消耗预测算法

王兵¹,杨青山²,蒋有高¹,徐献韬¹,王楷²

(1. 重庆市西部水资源开发有限公司,重庆 400039; 2. 重庆大学自动化学院,重庆 400030)

摘要:随着水资源配置工程的规模不断扩大,准确预测电力消耗对能源节约、成本控制和施工效率至关重要。传统电力消耗预测方法,如 LSTM(long short term memory)和 Transformer,在处理复杂时序数据时,难以同时捕捉短期和长期依赖。为应对这一挑战,本文提出基于扩展长短期记忆网络 xLSTM(extended long short term memory)对多区域电力消耗进行预测。xLSTM 结合了 sLSTM(scalar long short term memory)的短期依赖建模优势与 mLSTM(matrix long short term memory)的长期依赖建模能力,能够有效处理多个区域间电力消耗数据,考虑不同区域的时序关联性。实验结果表明,xLSTM 在多区域电力消耗预测中表现优异,均方误差(mean square error, MSE)为 0.003 0,平均绝对误差(mean absolute error, MAE)为 0.035,优于其他模型。该模型为电力消耗的精准预测提供了有效的技术支持,能够为大型水资源配置工程中的精准决策和智能调度管理提供有力保障。

关键词:xLSTM;电力消耗预测;大型水资源配置工程;多区域预测

中图分类号:TP312

文献标志码:A

文章编号:1000-582X(2026)06-103-14

Multi-regional power consumption forecasting in large-scale construction projects based on xLSTM

WANG Bing¹, YANG Qingshan², JIANG Yougao¹, XU Xiantao¹, WANG Kai²

(1. Chongqing Western Water Resources Development Co., Ltd., Chongqing 400039, P. R. China; 2. College of Automation, Chongqing University, Chongqing 400030, P. R. China)

Abstract: With the continuous expansion of water resource allocation projects, accurate electricity consumption forecasting is crucial for energy conservation, cost control, and construction efficiency. Traditional forecasting methods, such as long short-term memory (LSTM) networks and Transformers, often struggle to capture both short-term and long-term dependencies in complex time-series data. To address this challenge, this paper proposes an xLSTM (extended long Short-term memory) model for multi-regional power consumption forecasting. The

收稿日期:2024-12-22

基金项目:重庆市技术创新与应用发展专项重点项目(CSTB2022TIAD-KPX0127)。

Supported by Chongqing Key Project of Technological Innovation and Application Development (CSTB2022TIAD-KPX0127).

作者简介:王兵(1976—),男,高级工程师,主要从事水利水电工程方向研究,(E-mail)461807612@qq.com。

通信作者:王楷(1981—),男,副教授,(E-mail)kaiwang@cqu.edu.cn。

xLSTM model combines the short-term dependency modeling capability of sLSTM with the long-term dependency learning capacity of mLSTM, enabling effective analysis of power consumption data across multiple regions while considering temporal correlations among regions. Experimental results show that xLSTM achieve superior predictive performance, with a mean square error (MSE) of 0.0030 and a mean absolute error (MAE) of 0.035, outperforming competing models. The proposed model provides effective technical support for precise electricity demand forecasting and offers practical value for decision-making and intelligent scheduling management in large-scale water resource allocation projects.

Keywords: xLSTM; electricity consumption forecasting; large-scale water allocation projects; multi-regional prediction

大型水资源配置工程(如跨流域水利工程、水资源调配项目等)涉及多个子区域,电力消耗受到施工进度、气候变化等多种因素的影响^[1]。准确的电力消耗预测能够为工程建设中的精准决策提供数据支持,确保各项资源能够根据实际需求合理分配,提高工作效率与精度。因此,电力消耗预测不仅是大型水资源配置工程中的核心技术支撑,还在智能调度管理中发挥着重要作用,通过对未来电力需求的精确预测,有助于在施工过程中实时调整计划,减少能源浪费,并在确保施工进度和质量的同时,优化资源的使用和调配^[2]。

近年来,深度学习技术在时间序列预测领域取得了显著突破,尤其是长短期记忆网络(long short term memory, LSTM)和 Transformer 等深度神经网络模型,已被广泛应用于各种预测任务^[3]。在电力消耗预测领域,深度学习模型的引入为复杂模式建模和长时间依赖的捕捉提供了新的解决方案。

传统的监督学习方法(如线性回归,支持向量机等)在面对时间序列数据时,有一定的预测能力,但效果也有限。Ayvaz 等^[4]提出基于线性回归模型的家庭用电量预测方法,通过利用历史用电数据进行建模,提供了一种简便的预测手段。但在大型水资源配置工程中,电力消耗受多个非线性因素的影响,如水资源的调度、气候变化、区域用电差异等,线性回归模型在该场景下的预测精度和适应性不足,无法有效应对复杂的用电模式和长期趋势变化。

LSTM 能够较好地捕捉短期依赖,尤其在处理单一区域的电力消耗时取得了较好的效果。陈家乐等^[5]提出的基于 LSTM 的建筑能耗预测方法,通过结合气象数据和历史能耗数据,成功提高了预测精度。然而, LSTM 在处理多区域电力消耗预测时仍面临显著局限,尤其是在捕捉跨较长时间跨度的长期依赖时。L'Heureux^[6]等提出的基于 Transformer 的电力需求预测模型在这方面表现出了强大的优势。通过自注意力机制,Transformer 能够跨越较长时间跨度地建模电力消耗中的长期依赖关系,但其计算开销较大,且对数据量要求较高,尤其在多区域电力消耗预测任务中,Transformer 的计算复杂度使得训练时间较长,且在短期依赖捕捉上相对不足。

为了弥补 LSTM 和 Transformer 的不足, Wang^[7]等尝试结合 RNN (Recurrent Neural Network) 与 Transformer。用 RNN 来处理短期依赖,通过捕捉较短时间窗口内的短期变化,使用 Transformer 来建模长期依赖。这种结合方式虽然能够在一定程度上改善短期和长期依赖的建模能力,但无法充分实现两者优势的最优互补,二者的模型结构往往存在重复计算,尤其在输入数据具有复杂交互关系时,可能导致信息丢失或冗余。

针对上述问题,本文提出了一种基于 xLSTM (extended long short term memory) 的电力消耗预测算法,旨在提高电力消耗预测的精度与效率。xLSTM 结合了 sLSTM (scalar long short term memory) 和 mLSTM (matrix long short term memory) 的优势,能够在同一模型中同时有效处理短期依赖和长期依赖。具体而言, sLSTM 负责捕捉短期依赖,而 mLSTM 则通过建模较长时间跨度的长期依赖,通过这种结构设计, xLSTM 克服了传统的时序预测方法在同时处理长短期依赖时的性能衰减问题。这一方法为工程建设中的精准电力调

度、节能减排方案优化和科学决策提供了强有力的支持,不仅能提高资源配置的效率和合理性,还为智能调度管理提供了精确的数据依据,具有广泛的应用前景。本文主要贡献如下:

1) 本文结合大型水资源配置工程的特点,基于一种新的电力消耗预测算法——xLSTM,将 sLSTM 和 mLSTM 有机结合,通过灵活的层级结构设计,能够有效捕捉多区域电力消耗中的复杂时序依赖关系,提高了预测的精度与稳定性。

2) 考虑到建筑工程通常包含多个子区域,提出的 xLSTM 算法能够同时处理多个区域之间的相互影响和时空依赖,从而更准确地预测不同区域的电力消耗。

3) 本文设计的 xLSTM 算法被成功运用于渝西水资源配置工程的多区域电力消耗预测,实现了对工程中各区域电力需求的精准预测,为工程建设中的精准决策与智能调度管理提供了重要支持。

1 多区域电力消耗预测算法架构设计

本文采用 xLSTM 模型来预测大型水资源配置工程中多区域的短期电力消耗,如图 1 所示。xLSTM 模型由 sLSTM 与 mLSTM 堆叠而成,sLSTMBlock 用于提取短期时序特征,mLSTMBlock 负责捕捉数据的长期动态特征。每个模块之间通过残差连接实现信息传递,缓解梯度消失问题并提高特征建模能力。首先收集多区域的电力消耗历史数据,并进行数据清洗、重采样和归一化处理,随后将预处理后的数据输入 xLSTM 模型,通过前向传播和反向传播完成模型训练与预测。最终,利用预测结果与传统 LSTM 和 Transformer 模型的结果进行对比,通过计算均方误差(mean square error, MSE)、平均绝对误差(mean absolute error, MAE)等指标评估模型性能,验证 xLSTM 模型在复杂时序数据建模中的有效性。研究思路如下:

1) 收集大型水资源配置工程中多区域电力消耗的历史数据,对数据进行异常值处理、缺失值填补、时间重采样以及归一化操作;

2) 构建 xLSTM 模型,使用不同数量的 sLSTM 和 mLSTM 堆叠并通过残差连接提高建模深度和预测性能;

3) 将处理后的多区域电力消耗数据输入 xLSTM 模型,预测各区域的电力消耗值;

4) 分别构建 LSTM 和 Transformer 预测模型,将 xLSTM 模型实验结果与其进行对比,评估其有效性和预测精度;

5) 通过实验分析,为大型水资源配置工程的电力消耗管理提供数据支撑和优化决策依据。

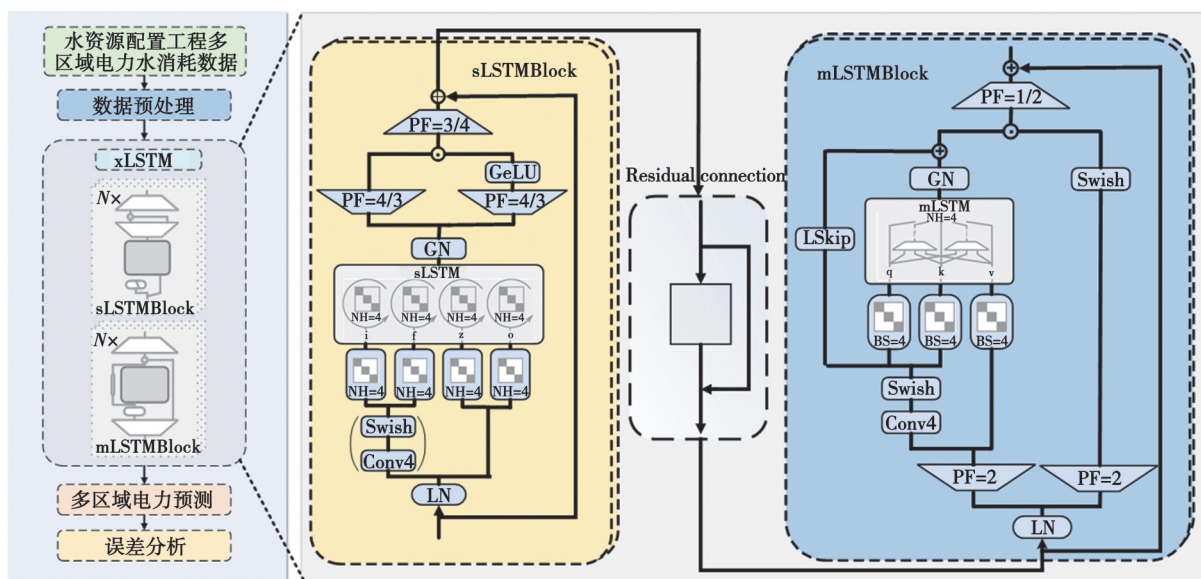


图 1 xLSTM 预测模型架构图

Fig. 1 Architecture diagram of xLSTM prediction model

2 研究方法

2.1 sLSTM 残差块

水资源配置工程往往涉及广泛的区域、复杂的系统和大量的环境变量,因此,如何精准地预测各个区域的电力消耗成为实现优化调度和资源配置的关键。传统的 LSTM 虽然在捕捉时间依赖性上表现出色,但在长序列数据和大规模数据处理时,仍然存在梯度消失、训练不稳定等问题。传统的 LSTM 结构^[8]如图 2 所示。

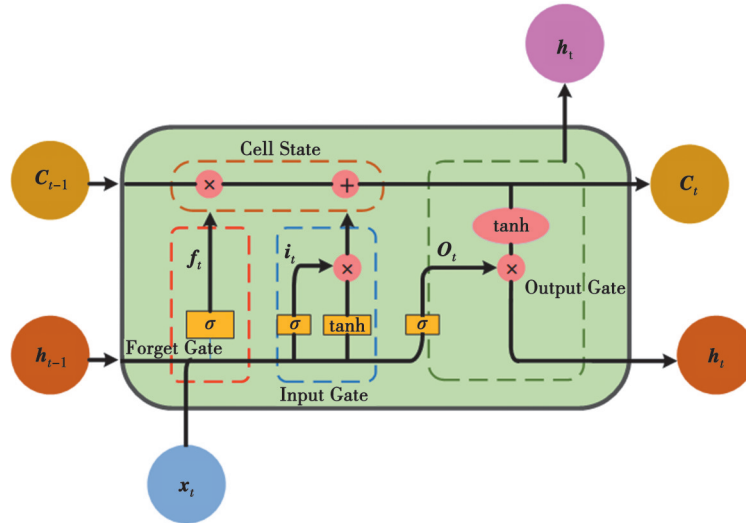


图 2 LSTM 结构图

Fig. 2 Structure diagram of LSTM

在本研究中,输入 x_t 来自某大型水资源配置工程的传感器数据,包含温度、湿度、风速、总散射辐射量、散射辐射量,以及 3 个区域的历史电力消耗(区域 1、区域 2、区域 3),输入形状为 (t, n) ,其中, t 表示时间步长, n 表示特征数量, LSTM 对于输入的处理过程如下:

1) 输入门(input gate)

输入门控制当前时刻输入 x_t 有多少新信息更新到细胞状态

$$i_t = \sigma(W_{\text{Input}} \cdot [h_{t-1}, x_t] + b_{\text{Input}}), \quad (1)$$

式中: i_t 表示第 t 时刻输入门的输出; 决定当前输入信息对细胞状态的影响; W_{Input} 表示输入门的权重矩阵; b_{Input} 表示输入门的偏置项。

同时需要计算候选细胞状态

$$\tilde{C}_t = \tanh(W_{\text{Cell}} \cdot [h_{t-1}, x_t] + b_{\text{Cell}}), \quad (2)$$

式中: \tilde{C}_t 为候选细胞状态, 表示当前时刻的候选信息; \tanh 表示 \tanh 激活函数, 将数据压缩到 $-1 \sim 1$ 之间, 这些候选信息结合输入数据的环境特征(如温度、湿度)和历史电力消耗特征, 为细胞状态提供更新依据。

2) 遗忘门(forget gate)

遗忘门控制当前时刻是否保留之前的记忆单元状态

$$f_t = \sigma(W_{\text{Forget}} \cdot [h_{t-1}, x_t] + b_{\text{Forget}}), \quad (3)$$

式中: f_t 表示遗忘门的输出, 值在 $0 \sim 1$ 之间, 决定需要遗忘多少前一时刻的细胞状态; σ 表示 sigmoid 激活函数, 将输入压缩到 $0 \sim 1$ 之间; W_{Forget} 表示遗忘门的权重矩阵; h_{t-1} 表示前一时刻的隐藏状态(输出); x_t 表示当前时刻的输入数据; b_{Forget} 表示遗忘门的偏置项。对于水资源配置场景中, 不同区域的电力消耗历史数据和环境特征可能对当前预测的相关性不同, 因此需要灵活选择保留哪些信息。

3) 细胞状态更新

根据遗忘门和输入门, 细胞状态的更新公式为

$$C_t = f_{\text{Cell}} \cdot C_{t-1} + i_t \cdot \tilde{C}_t \tag{4}$$

式中: C_t 表示当前时刻的细胞状态; C_{t-1} 表示前一时刻的细胞状态; $f_{\text{Cell}} \cdot C_{t-1}$ 表示遗忘门决定的遗忘部分; $i_t \cdot \tilde{C}_t$ 表示输入门决定的添加到细胞的新信息。这种细胞状态的更新可以捕捉历史电力消耗对未来变化的长期影响,同时结合当前环境条件(如风速或散射辐射量)的即时作用。

4) 输出门(output gate)

输出门控制当前时刻的隐藏状态输出

$$o_t = \sigma(W_{\text{Output}} \cdot [h_{t-1}, x_t] + b_{\text{Output}}), \tag{5}$$

式中: o_t 表示输出门的输出,决定当前细胞状态有多少信息需要输出; W_{Output} 表示输出门的权重矩阵; b_{Output} 表示输出门的偏置项。

5) 隐藏状态更新

最终,当前时刻的隐藏状态(即输出)由细胞状态和输出门一起控制

$$h_t = W_{\text{Output}} \cdot \tanh(C_t), \tag{6}$$

式中: h_t 表示当前时刻的隐藏状态(即 LSTM 的输出); C_t 表示当前时刻的细胞状态。 h_t 结合了多个区域的环境变量和电力消耗历史信息,能够有效捕捉其中的依赖关系,为电力消耗的预测提供支持。

sLSTM 针对 LSTM 的门控设计和记忆机制进行了优化,从而增强了模型在动态信息过滤过程中的灵活性^[9]。

sLSTM 用指数门控替代传统的 Sigmoid 函数,在处理短期依赖时,传统 LSTM 的 Sigmoid 门控机制可能因梯度范围的收缩,导致对局部动态变化响应较慢。sLSTM 针对这一问题优化了输入门和遗忘门,增强了模型对短时间动态信息的捕获能力

$$i_t = \exp(W_{\text{Input}} \cdot [h_{t-1}, x_t] + b_{\text{Input}}), \text{ input gate} \tag{7}$$

$$f_t = \sigma(W_{\text{Forget}} \cdot [h_{t-1}, x_t] + b_{\text{Forget}}) \text{ or } \exp(W_{\text{Forget}} \cdot [h_{t-1}, x_t] + b_{\text{Forget}}), \text{ output gate} \tag{8}$$

引入指数激活函数后,增强了动态信息过滤的灵活性,但也可能导致数值范围的快速增长,从而引发数值不稳定的问题。sLSTM 引入了归一化状态,该机制通过将输入门与所有未来遗忘门的乘积相乘并累加,确保了记忆更新过程的平衡性和稳定性,避免了输入门和遗忘门在数值范围扩展时引发的信息丢失,提供一种“缓冲机制”,将短期信息的快速变化平滑融入记忆更新中,公式如下

$$n_t = f_t \cdot n_{t-1} + i_t, \text{ normalizer state} \tag{9}$$

隐藏状态的更新过程优化为

$$h_t = o_t \left(\frac{c_t}{n_t} \right), \text{ hidden state} \tag{10}$$

sLSTM 残差块结构如图 3 所示,输入首先嵌入到一个预层归一化(Pre-LayerNorm)残差结构中,并通过窗口大小为 4 的因果卷积进行处理,因果卷积通过窗口大小为 4 的卷积操作捕获短时间范围内的动态模式,进一步增强了对局部上下文信息的感知。其中包括用于输入门和遗忘门的 Swish 激活函数,Swish 激活函数在输入门和遗忘门中的使用,提供了更平滑的非线性转换,优化了短期信息的提取能力。接下来,所有的输入门、遗忘门、输出门(input, forget, output)以及单元状态更新都会通过一个带有 4 个对角线块(即“头”) (NH=4)的块对角线性层进行处理。这些对角线块与最终隐藏状态的递归门预激活相匹配,形成一个具有 4 个头的 sLSTM,递归连接通过圆形箭头表示。经过这些步骤后,得到的隐藏状态会通过 GroupNorm 层进行标准化,每个头都

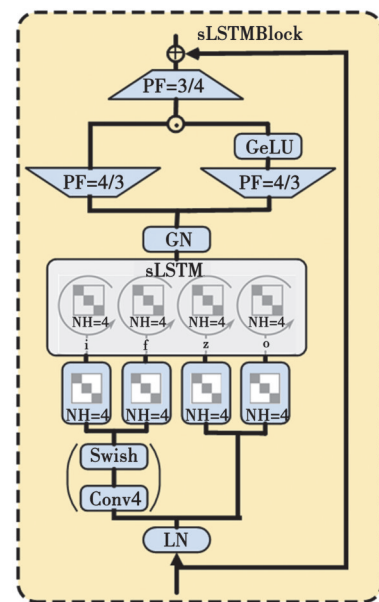


图 3 sLSTM 残差块示意图

Fig. 3 Schematic representation of an sLSTM Block

进行独立的头向层归一化(head-wise layernorm)。最后,通过门控的多层感知机(multilayer perceptron, MLP)对输出进行上投影和下投影。在投影过程中,使用 GeLU 激活函数,并采用投影因子 PF=4/3 来调整参数规模,以确保与模型的其他参数一致。

2.2 mLSTM 残差块

在大型水资源配置工程中,电力消耗预测涉及多区域的时序数据,且这些数据通常具有长时间的依赖性和复杂的空间关系^[10]。传统的 LSTM 虽然能够捕捉短期和长期依赖,但在处理复杂的多维数据时,尤其是在数据量庞大和计算需求高的场景下,可能面临一定的性能瓶颈^[11]。mLSTM 针对 LSTM 在复杂场景中,对长期依赖建模的不足,将传统 LSTM 中的向量操作扩展为矩阵操作,通过矩阵形式的存储和运算,mLSTM 能够在每个时间步同时捕获多个依赖关系,提高对长期依赖的表达力,并且在处理数据时具备更强的并行计算能力,这样的设计不仅提升了模型对长时间依赖的记忆能力,还能在每个时间步捕捉到更加丰富的模式和关系^[12]。

为了增强 LSTM 的存储能力,mLSTM 将传统 LSTM 的记忆单元扩展为矩阵记忆单元,通过矩阵运算实现对更复杂时间模式的捕捉。mLSTM 将传统 LSTM 的记忆单元从标量替换为了矩阵 $C \in \mathbb{R}^{d \times d}$ 。通过矩阵运算执行记忆存储与检索,mLSTM 可以捕获更复杂的数据关系。

$$q_t = W_{\text{query}} x_t + b_{\text{query}}, \text{ query input} \quad (11)$$

$$k_t = \frac{1}{\sqrt{d}} W_{\text{key}} x_t + b_{\text{key}}, \text{ key input} \quad (12)$$

$$v_t = W_{\text{value}} x_t + b_{\text{value}}, \text{ value input} \quad (13)$$

在每个时间步 t , mLSTM 的目标是存储一对向量:键向量 k_t 和值向量 v_t , 这种设置类似于 Transformer 中的键值对机制^[13]。在未来的时间步 $t + \tau$, 模型通过查询向量 $q_{t+\tau}$ 检索出与之相关的值 v_t , 键和值的存储机制让模型具备了将过去信息编码并存储为状态的能力,而查询机制则使模型能够有效定位这些信息,进而实现对长期依赖的捕捉,与传统 LSTM 逐步传递信息的方式相比,这种键值对机制能直接关联远距离的时间步,提高了对长期依赖的建模效率。

mLSTM 的记忆更新基于协方差更新规则,更新公式为

$$C_t = C_{t-1} + i_t v_t k_t^T, \text{ cell state} \quad (14)$$

式中: C_t 表示时间步 t 的记忆矩阵, $v_t k_t^T$ 是当前键值对的外积。通过这种更新方式, mLSTM 实现了记忆的高效存储。

同时,为解决长时间依赖中的数值稳定性问题,mLSTM 引入归一化状态,其定义为键向量的加权和,其中每个键向量的权重由输入门和所有未来的遗忘门共同决定。该归一化状态用于衡量门控机制的强度,防止数值不稳定。

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

其中: n_{t-1} 上一时间步的归一化状态; f_t 是当前时间步的遗忘门; i_t 是输入门; k_t 是当前时间步的键向量。

隐藏状态 h_t 是通过对记忆矩阵 C_t 和查询向量 q_t 的乘积进行处理得到的。为了提高稳定性, mLSTM 在计算时将查询向量和归一化状态的点积取绝对值,并对其进行下限处理,通常取 1 作为下限,避免除以零或出现过小的值。更新公式如下

$$h_t = o_t \odot \left(\frac{C_t \cdot q_t}{\max \{ |n_t^T q_t|, 1 \}} \right), \text{ hidden state} \quad (16)$$

其中: h_t 是当前时间步的隐藏状态; C_t 是记忆矩阵; q_t 是查询向量; $\max \{ |n_t^T q_t|, 1 \}$ 确保了数值稳定性。

最后,输出门 o_t 被用来生成当前时间步的输出,它的更新公式为

$$o_t = \sigma(W_{\text{Output}} x_t + b_{\text{Output}}), \text{ output gate} \quad (17)$$

其中: σ 是 sigmoid 激活函数; W_{Output} 是输出门的权重矩阵; b_{Output} 是输出门的偏置项。

通过这种机制, mLSTM 在时间序列任务中能够有效捕捉长期依赖并保持稳定的数值更新过程,从而提高模型的预测性能。mLSTM 残差块结构如图 4 所示:

输入首先嵌入到一个预层归一化(Pre-LayerNorm)残差结构中,并通过投影因子 PF=2 进行上投影,一边

用于外部输出,另一边作为 mLSTM 单元的输入。mLSTM 单元的输入经过大小为 4 的因果卷积(卷积核大小为 4),然后进入可学习的跳过连接(Skip Connection)。输入的查询(q_t)、键(k_t)和值(v_t)通过大小为 4 的块对角线投影矩阵进行处理。其中值(v_t)直接被传递,跳过了卷积部分。在序列混合之后,输出会通过 GroupNorm 层进行标准化,对每个头进行独立的层归一化(Head-wise LayerNorm)。最后,通过学习的跳过连接将结果与外部输出进行门控处理,再经过一次下投影,得到最终输出^[14]。

2.3 xLSTM 混合模型

xLSTM 模型通过将 sLSTM 和 mLSTM 堆叠在一起(如图 5 所示),其中 sLSTM 负责捕捉短期依赖关系, mLSTM 则处理长时间序列中的复杂模式。通过这种堆叠结构, xLSTM 能够同时应对不同时间尺度上的依




图 4 mLSTM 结构图

Fig. 4 Schematic representation of a mLSTM block

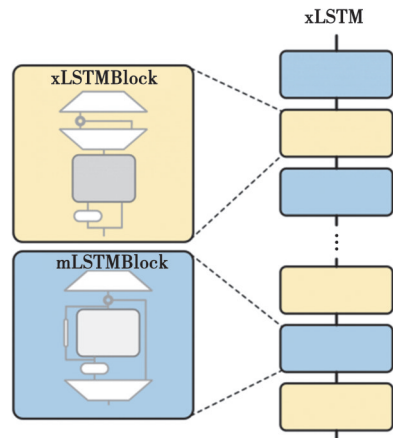


图 5 xLSTM 中 sLSTM 与 mLSTM 堆叠结构图

Fig. 5 Stacked structure diagram of sLSTM and mLSTM in xLSTM

赖性,从而提供更精确和稳定的预测结果。

在大型水资源配置工程中,电力消耗受到多种因素的影响,涉及不同时间跨度和区域间的交互效应。sLSTM 和 mLSTM 各自擅长的短期和长期依赖关系的建模能力,使得 xLSTM 模型在面对这种复杂的时序预测任务时,展现出其独特的优势。

具体而言, xLSTM 模型通过堆叠的方式,能够在以下几个方面发挥优势:

1)长短期依赖的综合建模: sLSTM 捕捉短期动态变化, mLSTM 则负责处理长期时间依赖,堆叠后的 xLSTM 能够同时关注两者的影响,有效提高了对电力消耗波动和趋势的预测精度。

2)增强的稳定性: xLSTM 结合了 sLSTM 和 mLSTM 的优点,在稳定性和鲁棒性上表现突出。sLSTM 能够在捕捉短期依赖时维持较高的计算效率,而 mLSTM 则通过矩阵操作增强了对长期依赖的记忆能力,使得模型在长时间序列数据中保持较好的稳定性。

3)适应复杂数据模式的能力:大型水资源配置工程涉及的电力消耗数据往往具有高度的时序性和复杂性, xLSTM 能够通过其堆叠结构灵活地适应这些复杂的时序模式,提升模型对不同区域间电力需求的预测能力。

4)计算效率与扩展性:由于 mLSTM 的矩阵形式支持并行计算, xLSTM 不仅提高了大规模数据集的处理效率,还增强了模型的扩展性,能够在更复杂的环境和更长时间跨度的预测任务中保持高效的计算性能。

3 实验设计与模型训练

3.1 实验方案

本实验以大型水资源配置工程中一年的电力消耗数据为例,将其划分为 3 个主要施工区域,通过分析包括温度、湿度、风速和太阳辐射等多种气象特征^[15],结合各区域的历史电力消耗数据,利用 xLSTM 模型在长

短时间依赖和多因素耦合问题上的优势^[16],针对多区域动态特性对多区域电力消耗进行精准预测,为施工进度管理和能源调度提供数据支撑。

本实验使用的数据集来源于大型水资源配置工程的多区域电力消耗监控系统,包含以下特征^[17-18]: Datetime:时间戳,表示电力消耗数据的采样时间;Temperature:温度,单位为摄氏度;Humidity:湿度,单位为百分比;WindSpeed:风速,单位为m/s;GeneralDiffuseFlows:太阳总辐射量(直接加权的总辐射量),单位为W/m²;DiffuseFlows:太阳辐射量(漫射辐射),单位为W/m²;PowerConsumption_Zone1:区域1的电力消耗,单位为千瓦时(kWh);PowerConsumption_Zone2:区域2的电力消耗,单位为千瓦时(kWh);PowerConsumption_Zone3:区域3的电力消耗,单位为千瓦时(kWh)。为保证数据的质量和适用性,本实验对原始数据进行了以下处理:

1)时间重采样:由于原始数据的采样间隔为10 min,本实验将数据重新采样为每4 h一个数据点。采样后,电力消耗数据(每个子区域)采用总和形式表示,而气象数据(温度、湿度、风速和辐射等)则取平均值。

2)缺失值处理:使用sklearn提供的填充方法SimpleImputer对缺失值进行处理,采用均值(mean)策略进行填补,确保数据的连续性和完整性。对于每个特征 x ,当出现样本值缺失时,计算该特征的均值 μ 并用 μ 填补缺失值:

$$x_i = \mu = \frac{\sum_{j=1}^n x_j}{n}, \quad (18)$$

其中: n 为该特征值非缺失值的总数量; x_j 为已知值。

3)标准化处理:为了避免不同特征之间量级差异对模型训练造成影响,使用scikit-learn的StandardScaler对所有特征进行标准化处理,对数据进行均值为0、标准差为1的转换,对于特征 x ,标准化计算公式如下

$$z = \frac{x - \mu}{\sigma}, \quad (19)$$

式中: μ 为特征 x 的均值; σ 为特征 x 的标准差; z 为标准化后的值。

3.2 模型训练与验证

本节详细介绍电力消耗预测模型的训练与验证过程,包括数据预处理、模型训练。

1)数据读取与归一化

使用了一个包含环境因素(如温度、湿度、风速等)和多区域电力消耗的多变量时间序列数据集。原始数据采样频率为10 min,经过重新采样为4 h后进行训练。为确保训练稳定性和模型性能,使用MinMaxScaler将所有特征归一化至[0,1]范围。

2)数据集划分与序列生成

数据集按照80%训练集、10%测试集和10%验证集进行划分,验证集用于在训练过程中监控模型的性能,避免过拟合,并根据验证集的结果调整模型的超参数。

构建时间序列样本过程采用滑动窗口方法生成每个样本的输入和输出数据。具体地,每个样本包含seq_len=8个时间步的数据作为输入,用于预测下一个时间步的目标值。此方法的核心思想是通过滑动窗口在时间序列中逐步提取子序列,使得每个样本能够包含历史信息,模型则利用这些历史数据进行预测。

窗口大小与步长设置:滑动窗口的大小设置为seq_len=8,表示每个样本包含8个时间步的数据。步长设置为1,即每次窗口向前移动一个时间步,生成新的样本。

输入与输出:每个输入样本包括seq_len=8个时间步的数据,输出为下一个时间步的目标值(即电力消耗)。对于给定的时间序列数据 $[x_1, x_2, \dots, x_n]$,使用滑动窗口方法,生成的样本为:输入: $[x_1, x_2, \dots, x_8]$,输出: $[x_9]$ 接下来,窗口向前滑动一位,生成新的样本:输入: $[x_2, x_3, \dots, x_9]$,输出: $[x_{10}]$,以此类推,直到滑动窗口遍历完整个时间序列。

数据结构与张量转换:生成的输入和输出数据将被组织成张量形式,以便于模型的训练。每个样本的输入为一个二维数组(大小为seq_len=8×feature_num),输出为一维数组(大小为feature_num),其中feature_num表示特征的数量(温度、湿度、风速等)。

最终,所有生成的序列样本将被转化为PyTorch张量,并组织成训练、验证和测试集,以便后续模型训

练和评估。为了高效地进行模型训练和评估,数据被转化为PyTorch中的TensorDataset,并通过DataLoader进行批量加载。DataLoader可以自动进行批次划分、数据洗牌(训练集)以及多线程加载,极大提高了训练的效率。

本实验选用LSTM模型、transformer模型以及sLSTM和mLSTM单独处理作为对比试验。为了优化模型性能并提高预测精度,本研究采用了网格搜索法(grid search,GS)对超参数进行调优。超目标是最小化模型在测试集上的平均绝对误差(MAE),从而选择最佳的超参数组合,具体实现如下:

1) 根据参考文献[19-20]及经验设置超参数搜索空间为:批量大小(batch size)候选值为32,64,128;学习率(learning rate)候选值为0.001,0.01,0.1,训练轮次(Epochs)候选值为20,30,40。

2) 对每组超参数组合,使用相同的训练集(大小为1748)和测试集(大小为437)进行模型训练和评估。

3) 在每次训练中,分别使用不同的批量大小、学习率和训练周期数训练模型,评估其在测试集上的MAE。

4) 记录每组超参数的MAE值,并更新最优超参数组合。

最终确定超参数如表1所示:

表1 模型参数表
Table 1 Model parameter table

模型	超参数	尺寸
LSTM	训练集	1748
	测试集	437
	Batch Size	64
	Epoch	30
	Learning rate	0.001
sLSTM	训练集	1748
	测试集	437
	Batch Size	64
	Epoch	30
	Learning rate	0.001
mLSTM	训练集	1748
	测试集	437
	Batch Size	64
	Epoch	30
	Learning rate	0.001
xLSTM	训练集	1748
	测试集	437
	Batch Size	64
	Epoch	30
	Learning rate	0.001
Transformer	训练集	1748
	测试集	437
	Batch Size	64
	Epoch	45
	Learning rate	0.005

3.3 评价指标

本实验选用均方误差MSE和平均绝对误差MAE作为评价指标。

MSE反映了模型预测值与真实值之间偏差的平方的平均值。公式如下

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (20)$$

其中: y_i 表示第*i*个真实值; \hat{y}_i 表示第*i*个预测值; n 为样本总数。

MSE通过对误差平方加权的方式放大了较大的误差,因此能够较敏感地捕捉预测中显著偏差的问题。对于多区域电力预测中的局部极端值波动,MSE提供了更高的惩罚。

MAE表示预测值与真实值之间绝对误差的平均值,公式如下

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|, \quad (21)$$

MAE通过直接计算预测误差的绝对值,更直观地反映了模型整体预测的平均误差大小。相比MSE,MAE对异常值不敏感,更能反映模型在普通预测任务中的实际表现。

4 实验结果与分析

4.1 模型性能对比分析

为了全面评估不同模型在多区域电力消耗预测任务中的表现,对LSTM、sLSTM、mLSTM、xLSTM和Transformer 5种模型进行了比较。各模型的实验结果如表2所示,使用均方误差MSE和平均绝对误差MAE作为评估指标,以反映模型在预测精度和误差控制方面的表现。

表2 所有模型预测误差对比
Table 2 All models prediction error

Models	LSTM		sLSTM		mLSTM		xLSTM		Transformer	
	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
Metrics	0.009 3	0.075	0.004 5	0.049	0.004 3	0.047	0.003 0	0.035	0.004 1	0.042

注:加粗数据表示最优指标。

从表1中可以看出,xLSTM模型在所有对比模型中表现最佳,具有最低的MSE(0.003 0)和MAE(0.035),表明其在多区域电力消耗预测中具有较高的准确性和较低的预测误差。与其他模型相比,xLSTM能够更好地捕捉时间序列数据中的复杂依赖关系,特别是在多区域预测任务中,充分发挥了其结构优势。

与之相比,Transformer模型虽然表现不错,MSE为0.004 1,MAE为0.042,优于传统的LSTM(MSE为0.009 3,MAE为0.075)和mLSTM(MSE为0.004 3,MAE为0.047),但其预测精度仍不及xLSTM。这表明Transformer在捕捉长期依赖关系和处理复杂特征时具有一定优势,但xLSTM在模型结构上更具针对性,能够更有效地优化预测效果。

此外,sLSTM和mLSTM在实验中的表现较为接近,分别表现出较低的MSE和MAE值(sLSTM的MSE为0.004 5,MAE为0.049;mLSTM的MSE为0.004 3,MAE为0.047),相较于LSTM有所提升,但仍不及xLSTM。

为了更加直观地展示各模型的预测效果,展示不同模型的预测结果图如图6~10所示。从预测结果图中可以明显看出,xLSTM模型在拟合实际电力消耗数据的过程中,具有更精确的预测曲线,并在多个区域的电力消耗预测上展现了较好的适应性和鲁棒性。

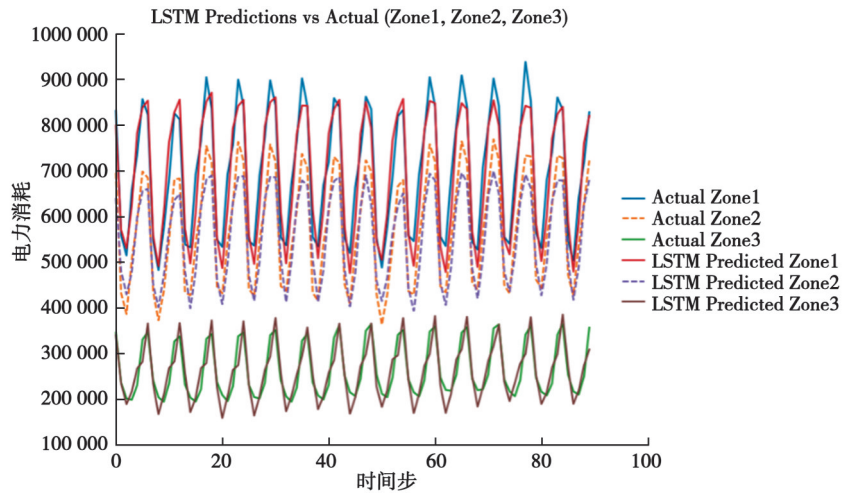


图 6 LSTM 模型预测结果图

Fig. 6 The prediction results of the LSTM model




图 7 sLSTM 模型预测结果图

Fig. 7 The prediction results of the sLSTM model




图 8 mLSTM 模型预测结果图

Fig. 8 The prediction results of the mLSTM model

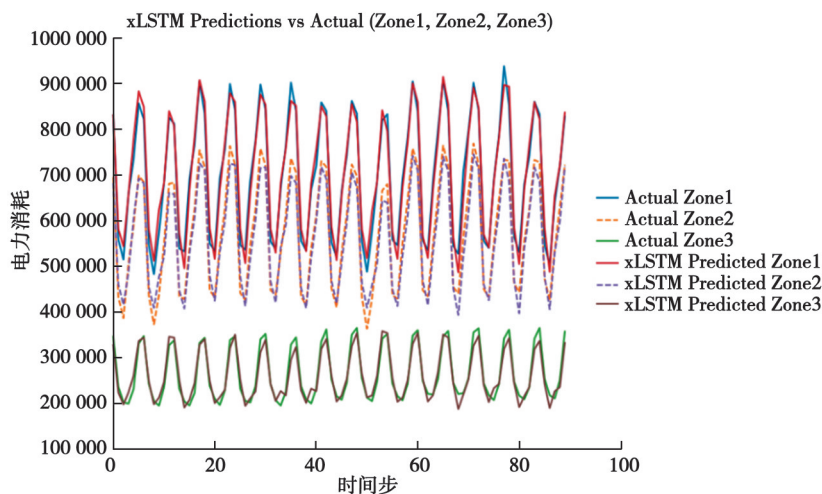


图9 xLSTM模型预测结果图

Fig. 9 The prediction results of the xLSTM model




图10 Transformer模型预测结果图

Fig. 10 The prediction results of the Transformer model

4.2 消融实验与优化

在本实验中,针对 xLSTM 模型中的不同层组合,进行消融实验,评估各层组合对多区域电力消耗预测任务的影响。xLSTM 是由 sLSTM 和 mLSTM 相结合的模型架构,本文设计了不同的层组合结构来进行实验。

本文选择了以下几种不同的层组合配置来进行消融实验:

- 1)smm:第1层为 sLSTM,后面2层为 mLSTM。
- 2)smmm:第1层为 sLSTM,后面3层为 mLSTM。
- 3)msm:第1层为 mLSTM,第2层为 sLSTM,第3层为 mLSTM。
- 4)msmm:第1层为 mLSTM,后面3层为 mLSTM。

通过对这些不同配置的 xLSTM 模型进行训练和验证,我们希望能够找到最优的层组合,从而提高多区域电力消耗预测的准确性和稳定性。

对于每一种 xLSTM 层组合配置,研究使用相同的训练集和测试集进行训练与评估。实验中的所有模型均使用相同的超参数进行训练,包括学习率(0.001)、批次大小(64)以及训练轮次(30)。模型的评估指标采用 MSE 和 MAE,以便对模型性能进行全面的分析。

不同 xLSTM 层组合配置的实验结果如表 3 所示,表中列出了每个模型在测试集上的表现,包括 MSE 和 MAE。

表3 xLSTM模型不同层组合机构预测误差

Table 3 Prediction error of different layer combination mechanisms in xLSTM model

层组合结构	MSE	MAE
msm	0.005 7	0.038
mshm	0.004 8	0.029
smmm	0.003 0	0.035
smmmm	0.005 2	0.031

注:加粗数据表示最优指标。

从实验结果可以看出,不同的层组合结构对模型的性能有一定影响。尤其是 smmm 配置在 MSE 和 MAE 上都表现出了最好的效果,分别为 0.003 0 与 0.035,该配置具有最佳的预测性能和稳定性,能够有效地处理复杂的多区域电力消耗预测问题。

5 结 论

本文针对大型水资源配置工程中的多区域电力消耗预测问题,基于 xLSTM(扩展长短期记忆网络)模型的方法,并与传统的 LSTM 和 Transformer 模型进行了对比分析。通过对电力消耗的多区域时序数据进行深入分析,本研究能够有效处理复杂的时序关系,并在准确性和计算效率上超越了传统模型,展现了其在实际应用中的潜力。

首先,理论分析表明,xLSTM 结合了 sLSTM 和 mLSTM 的优势,能够更好地捕捉不同区域之间的时序依赖关系,解决了传统 LSTM 模型在多区域预测任务中的局限性。通过对电力消耗数据进行建模,xLSTM 能够在多个区域间共享信息,提高预测的准确性和鲁棒性。其次,实验结果显示,xLSTM 模型在预测精度方面具有明显优势,均方误差(MSE)为 0.003 0,平均绝对误差(MAE)为 0.035,明显优于 LSTM 和 Transformer 模型,证明了该方法在多区域电力消耗预测中的有效性。

最后,本文的研究成果为大型水资源配置工程中的能源管理提供了创新的技术支持。xLSTM 的应用不仅提高了电力消耗预测的准确性,也为其他类似的时序预测任务提供了新的思路和方法。未来,本文还将进一步优化 xLSTM 模型的结构,探索更多数据源和改进算法,以提升模型的泛化能力和应用广度。

参考文献

- [1] 李国锋.大型复杂建筑工程项目进度管理研究与实践[J].城市建设理论研究(电子版),2024(25):48-50.
Li G F. Research and practice on schedule management of large-scale complex construction projects[J]. Theoretical Research in Urban Construction, 2024(25): 48-50. (in Chinese)
- [2] 李勇.南水北调工程运行管理成效与推进后续工程高质量发展的思考[J].中国水利,2024(20):6-9.
Li Y. Consideration on the effect of operation and management of the South-to-North Water Diversion Project and the promotion of high-quality development of follow-up projects[J]. China Water Resources, 2024(20): 6-9. (in Chinese)
- [3] 杨雷,罗雪红,韩鹏,等.基于人工智能算法的电力系统负荷预测研究综述[J].电工技术,2024(12):57-60.
Yang L, Luo X H, Han K, et al. A review of power system load forecasting based on artificial intelligence algorithms[J]. Electric Engineering, 2024(12): 57-60. (in Chinese)
- [4] Ayvaz B, Kusakci A O. Electricity consumption forecasting for Turkey with nonhomogeneous discrete grey model[J]. Energy Sources, Part B: Economics, Planning, and Policy, 2017, 12(3): 260-267.
- [5] 陈家乐,张芸芸,崔红伟.基于LSTM神经网络的办公建筑逐日能耗预测研究[J].建筑节能(中英文),2024,52(9):74-78.
Chen J L, Zhang Y Y, Cui H W. Daily energy consumption prediction of office building based on LSTM neural networks[J]. Building Energy EFFICIENCY, 2024, 52(9): 74-78. (in Chinese)
- [6] L'Heureux A, Grolinger K, Capretz M A M. Transformer-based model for electrical load forecasting[J]. Energies, 2022, 15(14): 4993.
- [7] Wang Z, Ma Y, Liu Z, et al. & Tang, J. R-Transformer: recurrent neural network enhanced transformer[EB/OL]. (2019-07-12) [2024-11-20]. <https://arxiv.org/abs/1907.05572>.

- [8] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [9] Beck M, Poppel K, Spanring M, et al. xLSTM: extended long short-term memory[EB/OL]. (2024-05-07) [2024-10-28]. <https://arxiv.org/abs/2405.04517>.
- [10] Klyuev R V, Morgoev I D, Morgoeva A D, et al. Methods of forecasting electric energy consumption: a literature review[J]. *Energies*, 2022, 15(23): 8919.
- [11] 周磊, 竺筱晶. 基于 MA-CNN-LSTM 和自注意力机制的单变量短期电力负荷预测[J]. *科学技术与工程*, 2024, 24(22): 9408-9416.
Zhou L, Zhu X J. Univariate short-term electrical load based on MA-CNN-LSTM-Self attention [J]. *Science Technology and Engineering*, 2024, 24(22): 9408-9416.
- [12] Fan X J, Tao C L, Zhao J Y. Advanced stock price prediction with xLSTM-based models: improving long-term forecasting[C]// 2024 11th International Conference on Soft Computing & Machine Intelligence (ISCMI). November 22-23, 2024. Melbourne, Australia. IEEE, 2024: 117-123.
- [13] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[EB/OL]. (2017-06-12) [2024-11-10]. <https://arxiv.org/abs/1706.03762>.
- [14] Kraus M, Divo F, Dhami D S, et al. xLSTM-Mixer: multivariate time series forecasting by mixing via scalar memories[EB/OL]. (2024-10-22) [2024-11-5]. <https://arxiv.org/abs/2410.16928>.
- [15] 郑征, 谭磊, 周楠, 等. 基于多头注意力卷积网络的电力负荷预测[J]. *南京信息工程大学学报*, 2022, 14(5): 535-542.
Zheng Z, Tan L, Zhou N, et al. Power load prediction based on multi-headed attentional convolutional network[J]. *Journal of Nanjing University of Information*, 2022, 14(5): 535-542. (in Chinese)
- [16] Zhu Q, Cai Y, Fan L. Seg-LSTM: performance of xLSTM for semantic segmentation of remotely sensed images[EB/OL]. (2024-06-20) [2024-11-02]. <https://arxiv.org/abs/2406.14086>.
- [17] 王晨艺, 许玉凤, 黄娟. 珠江三角洲电力消耗及其影响因素的空间计量模型分析[J]. *中国资源综合利用*, 2022, 40(10): 52-56.
Wang C Y, Xu Y F, Huang J. Spatial measurement model analysis of power consumption and its influencing factors in the Pearl River Delta[J]. *China Resources Comprehensive Utilization*, 2022, 40(10): 52-56. (in Chinese)
- [18] Qosja A, Dharmo E G, Georges D, et al. Comparative analysis of neural network and radial basis functions approaches for electricity consumption forecasting in five different regions in Albania[C]//2024 International Conference on INnovations in Intelligent SysTems and Applications (INISTA). September 4-6, 2024. Craiova, Romania: IEEE, 2024: 1-6.
- [19] Ibrahim I A. Improved grid search algorithm for optimal LSTM performance: a case study on Australian electricity price forecasting[C]//2024 IEEE Power & Energy Society General Meeting (PESGM). July 21-25, 2024. Seattle, WA, USA: IEEE, 2024: 1-5.
- [20] Zhang C Y, Ma L D, Luo Z W, et al. Forecasting building plug load electricity consumption employing occupant-building interaction input features and bidirectional LSTM with improved swarm intelligent algorithms[J]. *Energy*, 2024, 288: 129651.

(编辑 侯 湘)