

基于 LSTM 方法能源需求预测方法及其在能源调度中的应用

雷宇, 张亚, 丁燕, 刘红, 林鹏, 罗永彬

国网重庆市电力公司江津供电分公司, 重庆 404000

摘 要： 本文研究基于长短期记忆网络（LSTM）的能源需求预测方法，解决传统预测方法难以处理复杂非线性和长期依赖性的问题。通过美国 PJM 电力市场数据实验验证，LSTM 模型在预测准确性和稳定性上显著优于传统方法。提出的模型在能源调度中展现出提升电力系统效率与稳定性的潜力，特别在智能化能源管理和可再生能源利用方面。未来研究将优化算法并结合更多影响因素，以增强其在复杂能源系统中的适应性和应用范围。

关 键 词： LSTM 网络；能源调度；能源管理

Energy Demand Prediction Based on LSTM and Its Application to Energy Dispatching

Lei Yu, Zhang Ya, Ding Yan, Liu Hong, Lin Peng, Luo Yongbin

State Grid Chongqing Electric Power Company Jiangjin Power Supply Branch, Chongqing 404000

Abstract： This study proposes an LSTM-based energy demand forecasting method to address the limitations of traditional models in capturing complex nonlinearity and long-term dependencies. Validation using PJM electricity market data demonstrates that the LSTM model significantly outperforms traditional approaches in accuracy and stability. The model shows strong potential for energy scheduling, enhancing system efficiency and stability, particularly in intelligent energy management and renewable energy integration. Future work will focus on algorithm optimization and incorporating additional factors to improve adaptability in complex energy systems.

Keywords： LSTM Network; energy scheduling; energy management

引言

在能源管理领域，负载预测是一个十分重要的议题。准确的负载预测可以帮助电力公司和用户合理分配电力供应和使用，实现能源调度的目标^[1]。随着全球能源消耗的不断增长，提高能源利用效率、减轻电网负担，已成为各国政府和电力企业面临的重要挑战。许多国家制定了与可再生能源和能源管理相关的大政方针，如中国的“碳达峰、碳中和”目标^[2]，以及欧洲的能源转型政策，均强调通过智能电网和负载优化提升能源效率，减少化石能源依赖和碳排放。负载预测在能源管理中至关重要，例如，通过准确预测用电高峰，可以提前采取能源调度措施，合理调整电力的分配，降低供电成本。同时，负载预测还能帮助电力公司更好地管理分布式能源接入，提高电力系统的稳定性和可靠性，指导用户合理安排用电，降低用电成本^[3]。

传统的负载预测方法，如时间序列分析、线性回归和支持向量机（SVM）等^[4-6]，虽然在一定程度上能够提供负载预测的参考，但由于其难以应对时间序列中的长期依赖特性，无法准确捕捉用电负载的变化趋势。因此，近年来人工智能技术被广泛应用于负载预测中。其中，长短期记忆网络（Long Short-Term Memory, LSTM）作为一种特殊的递归神经网络（Recurrent Neural Network, RNN），因其在处理时间序列数据上的优势，受到了广泛关注^[7]。LSTM通过引入记忆单元（Memory Cell）和多种门控机制（输入门、遗忘门和输出门），有效解决了传统 RNN 在长时间序列预测中遇到的梯度消失和梯度爆炸问题^[8]，使其在捕捉负载数据的长期依赖性和复杂非线性关系方面表现出色，特别适用于电力负载这种具有高度波动性和不确定性的时间序列数据。相比传统方法，LSTM 能够更好地捕捉历史数据中的模式和特征，从而提高预测准确性。

一、能源需求预测与负载管理概述

能源需求预测是能源管理中的核心环节，通过对未来能源需求的精准预测，可以实现资源的高效分配和调度，避免能源浪费和供应不足。然而，随着需求的高度波动、能源供应的复杂化以

及对清洁能源依赖的不断加深，传统预测方法逐渐显现出难以应对非线性和长期依赖问题的局限性，无法满足复杂系统对预测精度的要求。例如，2024 年重庆连续 70 多天的高温天气对供电体系造成了巨大压力，进一步凸显了通过更精准的能源需求预测缓解供电压力的重要性。在此背景下，基于人工智能的预测方法，

尤其是长短期记忆网络（LSTM），凭借其强大的时间序列建模能力，成为研究热点^[9]。精准的能源需求预测不仅为能源调度提供了坚实基础，还能优化电力系统的运行效率，通过合理调整用电设备的运行时间，减轻高峰时段电网压力，提高电力资源利用效率，同时增强可再生能源的接入能力，为实现绿色能源转型提供有力支持。

目前，国内外关于负载预测和能源调度的研究主要集中在优化调度方法的改进上。国外学者在基于机器学习和深度学习的负载预测方面取得了显著进展，特别是智能算法在电力负载预测和智能调度中的应用取得了良好的成果。例如，K Xie等人（2020）提出了一种基于粒子群优化的Elman神经网络负荷预测方法，大大提高了预测的准确性和稳定性^[10]。此外，Tarmanini等人（2021）提出了一种基于ARIMA和ANN方法的短期负荷预测模型，验证了其在负荷预测方面的作用。在国内，研究者们更多地结合了电网的实际情况，将能源调度与智能电网和可再生能源的接入相结合，推动了能源管理的智能化和绿色化。例如，赵洋等人（2022）研究了基于卷积网络的短期电力负荷预测模型，实验验证了其可行性和有效性。相较于传统电网，基于LSTM的能源需求预测在处理非线性特征和长期依赖性方面具有显著优势，使其成为现代电力系统中不可或缺的技术^[13]。

二、LSTM神经网络原理

LSTM（长短期记忆网络，Long Short-Term Memory）是一种特殊的递归神经网络（RNN，Recurrent Neural Network），专门用于解决时间序列数据中的长期依赖问题。传统的RNN在处理长时间序列时容易遇到梯度消失或梯度爆炸的问题，而LSTM通过引入记忆单元（Memory Cell）和三种门控机制（输入门、遗忘门和输出门）有效地解决了这些问题，使其在捕捉长期依赖性和复杂非线性关系方面表现出色。此外，LSTM可以选择性地记忆和遗忘信息，这使得它在处理具有噪声和高波动性的负载数据时表现尤为优越。与传统RNN和其他机器学习方法相比，LSTM不仅能够捕捉历史数据中的模式，还能够对不同时间尺度的特征进行建模，从而显著提高预测的准确性和鲁棒性。图1展示了一个典型的LSTM单元的结构。




图1 长短期记忆神经网络结构

LSTM的核心是记忆单元，这些单元用于保留和管理信息。输入门控制新信息的加入，遗忘门决定丢弃多少以前的信息，而输出门控制输出哪些信息。网络工作时通过细胞状态 c 和隐藏状态

h_t 来处理时间序列中的长期和短期信息，同时通过三个门控机制来控制信息的流动，即：遗忘门 f_t 决定前一时间步的细胞状态 c_{t-1} 中哪些信息需要保留或遗忘，输入门 i_t 决定当前输入 x_t 中哪些信息更新到细胞状态，输出门 o_t 控制细胞状态中哪些信息输出到隐藏状态 h_t 。同时，LSTM生成一个候选细胞状态 $\tilde{c}_t$ 用于更新现有信息，通过遗忘门和输入门加权结合，计算出新的细胞状态 c_t 。最终，隐藏状态 h_t 输出门和激活函数 $\tanh(c)$ 决定，从而捕捉时间序列中的复杂依赖关系。遗忘门 f_t 、输入门 i_t 和输出门 o_t 由以下关系式决定：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

候选细胞状态 $\tilde{c}_t$ 是对当前输入 x_t 的一个新的信息表示，它通过 $\tanh$ 激活函数生成：

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

细胞状态 c_t 是通过遗忘门 f_t 和输入门 i_t 的加权控制，将前一时间步的状态 c_{t-1} 和候选细胞状态 $\tilde{c}_t$ 结合：

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (\text{符号}\odot\text{表示元素乘积})$$

当前时间步的隐藏状态 h_t 由输出门 o_t 和细胞状态 c_t 的激活值共同决定：

$$h_t = o_t \odot \tanh(c_t)$$

其中： σ 为sigmoid函数，用于门控机制， $\tanh$ 为双曲正切函数，用于生成候选细胞状态和隐藏状态的激活值。

通过细胞状态和隐藏状态的结合，使得LSTM能够有效地捕捉时间序列中的长期和短期依赖关系。与传统预测方法相比，LSTM在处理复杂的非线性关系和长期依赖性方面表现得更为出色。尤其是在应对能源负载中普遍存在的非线性特征、结构复杂以及长时间非线性波动时，LSTM具有显著优势。

三、实验设计与结果分析

（一）数据集与预处理

本研究采用了美国PJM电力市场1998-2001年期间部分州的每小时能耗公开数据集，共计32869条记录，有效记录32872条，部分结果如下表所示。数据集经过数据清洗和归一化处理，以去除噪声并减少不同量纲之间的影响。数据集被分为训练集（23010条样本，占70%）、验证集（4930条样本，占15%）和测试集（4932条样本，占15%），用于训练和评估LSTM模型的有效性。

表1 美国PJM电力市场部分用电数据


Datetime	PJM_Load_MW
1998/12/31 1:00	29309
1998/12/31 2:00	28236
1998/12/31 3:00	27692
1998/12/31 4:00	27596
1998/12/31 5:00	27888

Datetime	PJM_Load_MW
1998/12/31 6:00	29382
1998/12/31 7:00	31373
1998/12/31 8:00	33272
1998/12/31 9:00	34133
1998/12/31 10:00	35232
1998/12/31 11:00	35401
1998/12/31 12:00	35331
1998/12/31 13:00	34582
1998/12/31 14:00	33767
1998/12/31 15:00	33026
1998/12/31 16:00	32620
1998/12/31 17:00	33741
1998/12/31 18:00	36510
1998/12/31 19:00	36783
1998/12/31 20:00	35482


(二) LSTM模型架构

本文构建如下多层 LSTM 网络结构对时间序列用电量数据进行建模，考虑到数据集包含两列：Datetime（时间戳）和 PJM_Load_MW（每小时的用电量）。模型由一个输入层、两层 LSTM 隐藏层和一个输出层组成。输入层为 $(n_steps, 1)$ ，即基于过去 n 个时间步的用电量作为输入，用于预测下一时间步的用电量。第一层 LSTM 包含 50 个单元，采用 $\tanh$ 激活函数，并返回完整时间序列的隐藏状态；随后通过 Dropout 层随机丢弃 20% 的神经元以防止过拟合。第二层 LSTM 也包含 50 个单元，返回最后一个时间步的隐藏状态，再通过 Dropout 层进一步正则化模型。输出层为一个单神经元的全连接层，用于预测目标值。

模型采用均方误差（MSE）作为损失函数，使用 Adam 优化器进行训练，设置学习率为 0.001。超参数包括时间步数 $n_steps = 24$ （基于过去 24 小时的数据预测未来 1 小时的用电量）、批次大小为 64、训练轮 50 次（epochs）。为全面衡量模型的预测性能，选择了均方误差（MSE）、平均绝对误差（MAE）等作为评估指标，训练结果如下：




> 图2训练和验证过程的 MSE 曲线




> 图3训练和验证过程的 MAE 曲线

从图1和图2的误差曲线可以看出，模型性能表现出色。Loss 曲线（MSE）和 MAE 曲线均随训练过程逐渐下降并趋于平稳，说明模型已实现有效收敛。验证集的 Loss 和 MAE 始终略低于训练集，进一步表明模型对验证集具有良好的泛化能力。总体而言，模型在训练和验证阶段均未出现明显的过拟合现象，展现出良好的收敛性和拟合性。



> 图4实际负载和预测负载对比


从图3的整体和局部对比可以看出，模型在用电负载预测中表现优异，展现了较高的拟合精度和稳定性。在整体趋势上，预测值（橙色线）与真实值（蓝色线）高度吻合，准确捕捉了用电负载的波动规律。局部放大图进一步表明，模型能够精准预测短时间内的波动特征，尤其在趋势一致性和拐点捕捉方面表现突出。虽然在负载高峰或谷值区域，因极端值样本较少或波动性较大，导致预测值存在一定偏差，但在负载较为平稳的区域，模型的预测值与实际值几乎完全重合，充分展现了其卓越的稳定性和高精度。



> 图5 预测误差的分布

从图5误差分布可以看出，模型的预测误差接近正态分布，中心集中在 0 附近，且分布大致对称，说明预测误差总体随机且无明显偏向。大部分误差集中在 -1000 MW 到 1000 MW 范围内，表明模型预测精度较高且稳定。少数误差出现在长尾区域，但其频率较低，对整体预测性能影响有限。总体来说模型具备较好的拟合能力和预测稳定性。

为对比传统时间序列预测方法，本文在相同的数据集上采用了 SARIMA 模型进行建模预测。从图6的对比结果可以看出，LSTM 模型在用电负载预测中的表现明显优于 SARIMA 模型。LSTM 模型不仅能够准确拟合真实负载趋势，还能精准捕捉高峰和低谷的动态变化，特别是在拐点区域（如时间步 10 和 60）表现出卓越的预测能力。相比之下，SARIMA 模型尽管可以反映整体趋势，但在高峰和低谷区域预测误差较大，且在复杂波动的捕捉方面存在明显不足。



> 图6 LSTM与 SARIMA预测效果对比

实验结果表明，基于 LSTM 的能源需求预测方法在预测准确性上显著优于传统的 SARIMA 方法。LSTM 模型能够精确预测未来的负载峰值，使得提前采取负载转移策略成为可能，从而有效实现削峰填谷的目标。此外，实验验证了该方法在能源管理中的实际可行性和高效性，为实现智能化能源调度提供了重要支持。

四、结论与未来展望

本文提出了一种基于 LSTM 的能源需求预测方法，展示了

其在辅助制定动态能源调度策略中的潜在应用。实验结果显示，与传统预测方法相比，LSTM 方法在能源需求预测中表现出更高的准确性和稳定性，能够为能源调度优化决策提供可靠的技术支持，展现出在能源管理领域的广阔应用前景。

未来的研究将进一步结合实际用电环境，纳入天气条件、新能源接入、分布式能源供给等多种影响因素，对能源需求预测算法进行优化，以提升其在复杂能源系统中的适应能力。通过这一改进，有望进一步提高供电系统的智能化管理水平，助力构建更加高效、灵活的能源管理体系。

参考文献

[1]徐佳, 沈源成, 罗. J. OPTICS, and O. TECHNOLOGY, “基于自动响应控制器的负荷高峰期负载均衡研究,” vol. 20, no. 4, pp. 166–171, 2022.

[2]于贵瑞, 郝天象, and 朱. J. 中国科学院院刊, “中国碳达峰, 碳中和行动方略之探讨,” vol. 37, no. 4, pp. 423–434, 2022.

[3]S. F. Rafique, Z. J. I. G. Jianhua, Transmission, and Distribution, “Energy management system, generation and demand predictors: a review,” vol. 12, no. 3, pp. 519–530, 2018.

[4]P. Vrablecová, A. B. Ezzeddine, V. Rozinajová, S. Šárik, A. K. J. C. Sangaiah, and E. Engineering, “Smart grid load forecasting using online support vector regression,” vol. 65, pp. 102–117, 2018.

[5]A. Gasparin, S. Lukovic, and C. J. C. T. o. I. T. Alippi, “Deep learning for time series forecasting: The electric load case,” vol. 7, no. 1, pp. 1–25, 2022.

[6]I. K. Nti, M. Teimeh, O. Nyarko–Boateng, A. F. J. J. o. E. S. Adekoya, and I. Technology, “Electricity load forecasting: a systematic review,” vol. 7, pp. 1–19, 2020.

[7]Y. Yu, X. Si, C. Hu, and J. J. N. c. Zhang, “A review of recurrent neural networks: LSTM cells and network architectures,” vol. 31, no. 7, pp. 1235–1270, 2019.

[8]T. J. A. J. o. A. S. Fadziso and Engineering, “Overcoming the vanishing gradient problem during learning recurrent neural nets (RNN),” vol. 9, no. 1, pp. 197–208, 2020.

[9]K. Albeladi, B. Zafar, A. J. I. J. o. A. C. S. Mueen, and Applications, “Time Series Forecasting using LSTM and ARIMA,” vol. 14, no. 1, pp. 313–320, 2023.

[10]K. Xie, H. Yi, G. Hu, L. Li, and Z. J. N. Fan, “Short-term power load forecasting based on Elman neural network with particle swarm optimization,” vol. 416, pp.