

基于LSTM模型的甘肃电力市场现货价格预测与最佳交易决策研究

杨春祥, 马寅, 张晓斌, 韩杰, 张妙静, 郝如海

国网甘肃省电力公司, 甘肃 兰州

收稿日期: 2024年12月8日; 录用日期: 2025年1月5日; 发布日期: 2025年1月10日

摘要

甘肃电力市场由于新能源接入比例的提升增加了市场的不确定性和波动性。本文首先从数据预处理与特征工程入手, 对2024年上半年的现货价格数据进行平滑处理, 捕捉短期和长期的价格趋势。随后建立了高精度的长短期记忆网络模型(Long Short-term Memory, LSTM)对甘肃电力市场未来7天和15天的平均实时和日前现货价格进行了预测, 结果表明LSTM模型在训练集和测试集上的预测准确度较高。其次, 基于预测结果和风险溢价的对数收益分析, 为市场交易建立了最佳交易决策模型; 以案例分析的方式展示了如何利用预测价格与实际价格的差异来评估市场风险和制定相应的交易策略。研究表明, 在高比例新能源电网背景下, 利用先进的机器学习技术可以对电力现货市场价格进行准确预测, 本文的最佳交易决策模型能够提升市场交易决策的科学性及与监测预警支持能力。

关键词

LSTM模型, 电力市场, 现货价格预测, 最佳交易决策, 风险溢价

Research on Spot Price Forecasting and Best Trading Decision in Gansu Province Electricity Market Based on LSTM Modeling

Chunxiang Yang, Yin Ma, Xiaobin Zhang, Jie Han, Miaoqing Zhang, Ruhai Hao

State Grid Gansu Electric Power Company, Lanzhou Gansu

Received: Dec. 8th, 2024; accepted: Jan. 5th, 2025; published: Jan. 10th, 2025

Abstract

The increase in the proportion of new energy access in the Gansu electricity market has increased

文章引用: 杨春祥, 马寅, 张晓斌, 韩杰, 张妙静, 郝如海. 基于 LSTM 模型的甘肃电力市场现货价格预测与最佳交易决策研究[J]. 数据挖掘, 2025, 15(1): 26-39. DOI: 10.12677/hjdm.2025.151003

market uncertainty and volatility. Starting with data preprocessing and feature engineering, this paper smoothed the spot price data for the first half of 2024 to capture short-term and long-term price trends. Subsequently, a high-precision Long Short-Term Memory (LSTM) network model was established to predict the average real-time and intraday spot prices of the Gansu electricity market for the next 7 and 15 days. The results showed that the LSTM model had high prediction accuracy on both the training and testing sets. Secondly, based on the prediction results and logarithmic return analysis of risk premium, an optimal trading decision model was established for market trading; This case study demonstrates how to use the difference between predicted prices and actual prices to assess market risks and develop corresponding trading strategies. Research has shown that in the context of a high proportion of new energy grids, advanced machine learning techniques can be used to accurately predict electricity spot market prices. The optimal trading decision model proposed in this paper can enhance the scientific nature of market trading decisions and support monitoring and early warning capabilities.

Keywords

LSTM Model, Electricity Market, Spot Price Prediction, Optimal Trading Decision, Risk Premium

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

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



Open Access

1. 引言

面对日益严峻的全球环境问题，中国于 2020 年制定了在 2030 年前实现碳达峰、2060 年前实现碳中和的目标。在这一目标的指引下，电力行业正加速清洁能源转型，推动电能替代，承接工业、交通等领域的能源消耗和碳排放，并逐步构建以新能源为主体的新型电力系统[1]。电力市场化改革是实现新能源高效利用的关键途径。自 2015 年发布《关于进一步深化电力体制改革的若干意见(中发〔2015〕9 号)》以来，电力现货市场的建设稳步推进[2]。作为首批试点之一，甘肃省积极开展双边现货市场建设，通过市场竞争形成分时电价，进一步引导用户用电行为，有效促进新能源消纳，提高资源配置效率。

首先，现货市场的运行机制直接影响市场的稳定性和经济性。但现货市场运行体系复杂，各种影响因素多，运行状态多变，潜在运行风险大。为了持续稳步推进现货市场建设，亟需对电力市场运营开展监测和预测。而电力现货价格预测作为市场风险管理的重要手段，不仅能够帮助市场主体制定最佳交易决策，降低交易过程中的经济风险[3]，还能帮助市场运营者掌握运行情况，为现货市场可持续发展提供决策支持。随着新能源比例增加，其出力不确定性加剧了电价波动。为准确预测现货市场价格，LSTM (Long Short-term Memory, LSTM)模型凭借处理时间序列数据的优势成为重要工具。

其次，甘肃所处的独特的地理位置使其已成为全国风光资源最为富集的地区之一。截至目前，甘肃电网全口径装机达到 6803.3 万千瓦，其中火电 2311.3 万千瓦，水电 971.7 万千瓦，风电 2075.6 万千瓦，光伏 1444.7 万千瓦，新能源装机比例达到 51.7%，新能源装机占比居全国第 2 位。但甘肃新能源发电随机性、波动性明显，新能源日内波动最大日(2021 年 4 月 28 日)最大出力达到 1343 万千瓦，最小出力 196 万千瓦；2022 年新能源日波动平均为 913 万千瓦，最大达到 1690 万千瓦。由此导致甘肃电力现货交易具有明显的实时性、波动性、边际性、金融性的特点。这为甘肃电力现货价格预测和交易决策提出了更高的要求。

考虑到甘肃电力现货市场采用单边集中竞争模式，电价波动较大，难以预测的特点[4]，本文采用

LSTM 模型处理这一多重非线性动态特性。LSTM 模型在处理时间序列数据方面具有出色性能, 尤其适合捕捉电力现货价格中复杂的时序依赖关系和长期趋势。因此, 建立 LSTM 模型研究甘肃电力市场现货价格的预测与最佳交易决策模式无疑有利于提高现货价格预测精度。建模中我们对甘肃电力市场双边现货交易数据进行了深入分析, 选取针对性强、可用性高的分析指标, 构建价格预测模型, 并结合市场交易行为, 提出最佳交易决策策略。研究结果不仅有助于提高电力市场价格预测的质量, 减少市场风险, 还为市场主体制定科学的交易决策提供了重要参考, 也为甘肃电力现货市场运营监测提供了风险预警。

2. 相关工作

目前在电力市场时间序列预测领域, 已有大量研究文献提出了多种不同的预测模型。越来越多的学者尝试建立不同的预测模型来优化电力负荷或电力现货价格的波动, 以进行风险预警。这些模型的预测结果的可靠性对市场参与者的交易决策有重大影响[5]。其主要目的是准确表现出被预测变量的真实值与预测值之间的差距。文献[6]介绍了一种基于支持向量机的电力市场参与方法, 其主要目标是基于电力市场价格预测, 为市场参与者提供投标建议。预测价格被用作参与电力市场的代理商运营策略的基础。文献[7]采用几种不同结构的机器学习算法, 验证了这些算法在不同时间范围内对电价预测的可靠性。

尽管已有许多人工智能方法被应用于预测模型, 如支持向量机[6][8]和 ARIMA 模型[9]等, 这些方法虽然能得到一定的预测结果, 但存在收敛慢、复杂度高、效率低等问题。因此它们并不是预测电力现货价格的首选方法。相比之下, LSTM 预测模型在处理长短期效应方面表现出更优越的性能[10]。LSTM 模型在电力领域已有广泛研究, 如文献[11]-[14]将 LSTM 模型应用于短期电力负荷预测; 文献[11]通过反向传播神经网络进行训练, 进一步提高了预测精度; 文献[12]将卷积神经网络与 LSTM 模型结合, 验证了其在短期预测中具有更高的精度和准确度; 文献[13][14]说明了所建立的预测模型在实际应用中的实用性。

在电力现货价格预测方面, LSTM 模型也有广泛应用[15]-[19]。文献[15]基于经验模式分解与 LSTM 提出电价模型, 通过与 ARIMA 及单一神经网络模型的预测结果对比验证可靠性; 文献[16]结合 LSTM 与 k-means 聚类预测风电市场电价, 显著降低预测误差; 文献[17]采用 Adam 优化 LSTM, 提升预测效果; 文献[18]实验表明该模型在精度与稳定性上优于传统模型。

综上所述, LSTM 在时间序列模型中的优越性得到了广泛验证, 但大多数研究仅基于现货价格进行短期预测, 且只基于日前现货价格或实时现货价格作为主要预测对象。考虑到甘肃电力市场现货价格波动性较大, 本文同时将实时现货价格与日前现货价格数据作为预测变量, 分别预测未来 7 天与 15 天的现货价格, 为甘肃电力现货市场的营运监测和风险规避提供可行的决策支持。

3. 数据预处理与变量设计

电力现货价格是电力交易市场中重要的价格指标之一, 其波动频率和幅度较大, 受到多种因素影响, 包括电源结构、燃料价格和外部市场环境等。一个有效的市场机制能够反映电力供应和需求的实时情况, 通过市场供需动态平衡形成电力现货价格。本文选取 2024 年 1 月 1 日至 2024 年 6 月 30 日的现货价格作为原始数据, 预测甘肃电力交易市场未来 7 天和 15 天的平均实时(日前)现货价格。预测模型所用到的输入变量只与甘肃电力现货价格相关变量有关, 包括实时现货价格与日前现货价格。其中实时现货价格反映当前市场的供需状况和价格波动趋势, 而日前现货价格则可以提供对未来市场供需和价格变化的预期。

首先对数据集进行平滑数据处理捕捉现货价格的短期趋势。通过 7 天内的平均现货价格可以有效平滑数据, 即滑动窗口为 $n=7$ 。再利用同样的平滑处理方式, 计算 30 天内的平均现货价格, 即滑动窗口为 $n=30$, 可以捕捉更长时间范围内现货价格的发展趋势与周期性变化。具体实施办法如下, 记交易日

N 前 7 天内的平均实时现货价格为 $RT_{spot,7}$ ，则

$$RT_{spot,7} = \frac{1}{96 \times NT_{d7}} \sum_{d=n-6}^{d=n} \sum_{m=1}^{m=96} RT_{spot,d7} \quad (1)$$

其中 NT_{d7} 表示在电力现货市场内交易日 N 前 7 天内的交易天数，议价日 d 每 15 分钟的平均实时现货价格记为 $RT_{spot,d7}$ 。

记交易日 N 前 7 天内的平均日前现货价格为 $DA_{spot,7}$ ，则

$$DA_{spot,7} = \frac{1}{96 \times NT_{d7}} \sum_{d=n-6}^{d=n} \sum_{m=1}^{m=96} DA_{spot,d7} \quad (2)$$

其中 $DA_{spot,d7}$ 表示在议价日 d 每 15 分钟的平均现货市场价格。

记交易日 N 前 30 天内的平均实时现货价格为 $RT_{spot,30}$ ，则

$$RT_{spot,30} = \frac{1}{96 \times NT_{d30}} \sum_{d=n-29}^{d=n} \sum_{m=1}^{m=96} RT_{spot,d30} \quad (3)$$

其中 NT_{d30} 表示在电力现货市场内交易日 N 前 30 天内的交易天数，议价日 d 每 15 分钟的平均实时现货价格记为 $RT_{spot,d30}$ 。

记交易日 N 前 30 天内的平均日前现货价格为 $DA_{spot,30}$ ，则

$$DA_{spot,30} = \frac{1}{96 \times NT_{d30}} \sum_{d=n-29}^{d=n} \sum_{m=1}^{m=96} DA_{spot,d30} \quad (4)$$

其中 $DA_{spot,d30}$ 表示在议价日 d 每 15 分钟的平均现货市场价格。

利用短期与长期的特征工程有助于减少极端值对于模型训练的影响以及平滑数据的周期性波动。为了进一步提高模型训练速度，通过计算平均值，减少模型需要处理的特征数量来降低复杂度。具体实施办法为：以 2024 年 1 月 1 日 0:00 的数据为例，取 0:00, 0:15, 0:30, 0:45 这四个节点的平均值，作为 0:00~1:00 内的现货价格。按照这种处理方式给出相关变量的定义。

记最终交易日 N 前 7 天内的平均实时现货价格为 $RT_{spot,n7}$ ，则

$$RT_{spot,n7} = \frac{1}{4} \sum_{m=1}^{m=4} RT_{spot,7m} \quad (5)$$

其中 $RT_{spot,7m}$ ($m=1,2,3,4$) 分别表示 $RT_{spot,7}$ 在整点、整点一刻、半点以及半点一刻的平均现货价格。

记最终交易日 N 前 7 天内的平均日前现货价格为 $DA_{spot,n7}$ ，则

$$DA_{spot,n7} = \frac{1}{4} \sum_{m=1}^{m=4} DA_{spot,7m} \quad (6)$$

其中 $DA_{spot,7m}$ ($m=1,2,3,4$) 分别表示 $DA_{spot,7}$ 在整点、整点一刻、半点以及半点一刻的平均现货价格。

记最终交易日 N 前 30 天内的平均实时现货价格为 $RT_{spot,n30}$ ，则

$$RT_{spot,n30} = \frac{1}{4} \sum_{m=1}^{m=4} RT_{spot,30m} \quad (7)$$

其中 $RT_{spot,30m}$ ($m=1,2,3,4$) 分别表示 $RT_{spot,30}$ 在整点、整点一刻、半点以及半点一刻的平均现货价格。

记最终交易日 N 前 30 天内的平均日前现货价格为 $DA_{spot,n30}$ ，则

$$DA_{spot,n30} = \frac{1}{4} \sum_{m=1}^{m=4} DA_{spot,30m} \quad (8)$$

其中 $DA_{spot,30m}$ ($m=1,2,3,4$) 分别表示 $DA_{spot,30}$ 在整点、整点一刻、半点以及半点一刻的平均现货价格。

将上述的定义变量作为输入变量加入到训练模型当中，并分别给出预测结果。

4. 基于 LSTM 模型的甘肃电力现货价格预测

基于上述对甘肃电力现货市场的变量设计和预处理，本节将详细给出长短期记忆网络 LSTM 模型的建立过程，包括模型架构的设计、训练参数的选择以及模型的评估方法。

4.1. LSTM 模型单元结构

LSTM 模型是一种特殊的递归神经网络(Recurrent Neural Network, RNN)，该模型可以有效地解决传统 RNN 在处理长时间序列时存在的梯度消失和梯度爆炸问题，专门设计用于处理和预测时间序列数据中的长期依赖关系。图 1 展示 LSTM 模型独特的单元结构和门控机制，并详细说明 LSTM 单元如何在每个时间步更新和维护细胞状态和隐藏状态。

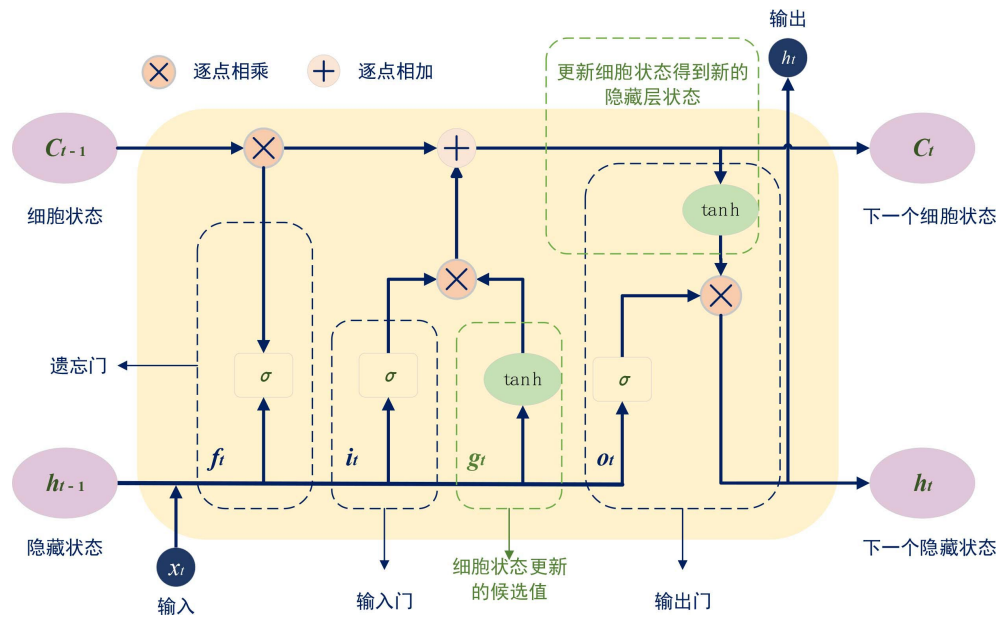


Figure 1. Schematic diagram of a long short-term memory (LSTM) unit
图 1. 长短期记忆网络(LSTM)单元结构示意图

在 LSTM 模型的信息流动过程中，第一步需要控制遗忘门 f_t 中的 σ 层，通过点乘运算决定从前一时间步的细胞状态 C_{t-1} 内丢弃掉哪些信息，给出如下表达式：

$$f_t = \sigma(w_f \cdot [x_t, h_{t-1}] + b_f) \quad (9)$$

其中 σ 层输出 $[0, 1]$ 之间的值，表示 f_t 通过部分信息， $\sigma = 1$ 时代表所有的信息都会通过。 b_f 为偏置变量， t 为时间步长。

第二步首先要控制输入门 i_t 中的 σ 层，决定更新细胞内的部分信息；其次再利用 \tanh 层创建一个候选值向量 g_t ，将会被添加到细胞状态中。最终结合两部分新的信息用于更新细胞状态，具体表达式为，

$$i_t = \sigma(w_i \cdot [x_t, h_{t-1}] + b_i) \quad (10)$$

$$g_t = \tanh(w_g \cdot [x_t, h_{t-1}] + b_g) \quad (11)$$

其中 b_i 、 b_g 为偏置向量。

第三步更新细胞状态，确定本细胞内部分旧信息被遗忘，再添加部分新信息，从而有如下表达式

$$C_t = f_t \odot C_{t-1} + i_t \odot g_t \quad (12)$$

第四步要输出 LSTM 模型的预测信息。首先利用输出门 o_t 的 σ 层决定细胞状态 C_t 输出部分信息；其次利用输出门 o_t 的 \tanh 层使得细胞状态 $C_t \in [0,1]$ ，再与输出门的结果相乘，形成新的隐藏 h_t 。给出表达式如下，

$$o_t = \sigma(w_o \cdot [x_t, h_{t-1}] + b_o) \quad (13)$$

$$h_t = o_t \odot \tanh(C_t) \quad (14)$$

其中 b_o 为偏置向量。

4.2. LSTM 预测实验设计和结果分析

4.2.1. 实验环境与相关配置

本实验使用 Anaconda 开发平台，并将 Python 作为主要编程语言建立深度学习框架。实验最终目的是研究使用 LSTM 模型预测未来 7 天和 15 天的平均实时现货价格与平均日前现货价格，再比对实际的现货价格，建立最佳的交易决策，具体的步骤如下。

- 数据预处理：按照第 4 节的内容进行数据预处理，输出的未来 7 天与 15 天的预测值；
- LSTM 模型的设计：在 5.1.节中已经给出详细的内容；
- 模型训练：利用数据集中 60%的数据作为训练集对模型进行训练，30%的数据作为验证集来验证所训练模型的可行性。利用损失函数计算预测结果的可靠性，计算 n 个 *epoch* 迭代得到的损失值，当经过 n 个 *epoch* 训练之后损失值趋于稳定时，说明得到较好的训练模型；
- 模型测试：将剩余 10%的数据作为测试集与预测值进行比对分析。

4.2.2. 模型预测效果评价指标

在对本文所建立的 LSTM 模型进行训练与测试后，结合本文研究内容，建立以下评价指标来衡量模型的预测效果。

均方误差(Mean Squared Error, *MSE*)是指预测值与真实值之间的差值的平方的平均值，较大的误差值会有更大的权重，即当模型预测出现较大偏差时，结果更加直观。计算公式为，

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_{spot, fut} - y_{spot, act})^2 \quad (15)$$

其中 n 为数据样本数， $\hat{y}_{spot, fut}$ 是平均实时(日前)现货价格的预测值， $y_{spot, act}$ 是实时(日前)现货价格的真实值。

均方根误差(Root Mean Squared Error, *RMSE*)是用于衡量模型预测误差的一种标准，通常用于回归模型的评估。*RMSE* 的计算如下：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_{spot, fut} - y_{spot, act})^2} \quad (16)$$

平均绝对误差(Mean Absolute Error, *MAE*)是指预测值与真实值之间的平均误差，其绝对值可以使得误差方向对最终结果没有影响，计算公式为，

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_{spot, fut} - y_{spot, act}| \quad (17)$$

上述评价指标取值越小说明预测效果越好。

4.3. 实证分析

以下根据 2024 年 1 月 1 日~2024 年 6 月 30 日甘肃电力现货价格作为监测数据进行实证分析。市场参与者根据实时现货价格和日前现货价格的预测结果,包括未来 7 天和 15 天的电力现货价格,制定甘肃电力现货交易市场的最佳交易决策及市场监测预警机制。

电力现货市场按时段进行交易,图 2 显示甘肃省 2024 年 1 月 1 日~2024 年 6 月 30 日电力现货交易市场中实时和日前现货价格的波动情况。每隔 15 min 进行报价,共有 96 个时段。依据平均实时现货价格与平均日前现货价格的波动曲线可具体划分为用电高峰、用电平稳和用电低谷三个时段。

从图 2 中可以发现,实时现货价格的高峰时段主要集中在 5:00~9:00 和 16:00~21:00,在这两个时段内,电力需求较高,导致现货价格显著上升。平稳时段则出现在 0:00~5:00 和 21:00~24:00,此时段内电力需求相对稳定,现货价格波动较小,保持在较为平稳的水平。低谷时段则位于 9:00~16:00,期间电力需求较低,现货价格相应下降。对于日前现货价格,波动趋势与实时现货价格基本一致。高峰时段集中在 17:00~21:00,这表明电力需求预测在这些时段内较为准确,现货价格也反映了高需求的情况。平稳时段出现在 0:00~7:00 和 21:00~24:00,现货价格在这些时段内也较为平稳。低谷时段出现在 7:00~17:00,日前价格在此期间也较低,与实时价格的低谷相吻合。




Figure 2. Fluctuation curve of average real-time spot price and average day-ahead spot price in Gansu province
图 2. 平均实时现货价格与平均日前现货价格的波动曲线

整体来看,实时现货价格和日前现货价格的波动趋势相似。实时价格的波动幅度在某些时段内略大于日前价格,反映了市场的即时反应情况。这种价格波动的对比分析有助于理解电力市场的动态变化,可为电力交易决策和监测预警提供参考。

4.4. LSTM 模型预测结果

本实验基于式(3)与式(4)中的单变量进行预测,分别得到实时现货与日前现货未来 7 天和 15 天的平均价格。

4.4.1. 实时现货价格预测

为了评估模型在未见数据上的预测能力,将预处理过的数据集按 6:3:1 的比例分割为训练集、验证集和测试集。图 3(a)为利用 $n=7$ 时的数据集得到的结果,可以看到训练集的预测值与真实值几乎完全重合,

说明模型在训练集上有很高的拟合度。预测值与真实值在峰值和谷值的区域也有很好的一致性。从图 3(b)中可以看出,从 6 月 12 日到 6 月 27 日,测试集的预测值与真实值在大多数时间段一致。未来 7 天与 15 天的预测值与真实值有偏差,但总体趋势一致,且未来 7 天的预测值更接近真实值。从 $n=30$ 时平均实时现货价格的走势来看,相较于 $n=7$,前者的价格波动更加平稳。再观察图 3(c)中利用月平均实时现货价格的预测结果,训练模型得到的预测值与真实值出入较小,说明训练结果较好。在实验过程中,图 3(d)展示了本文对测试集的预测值与真实值进行分别标记出未来 7 天与 15 天的实时现货价格。不难看出,未来 7 天的预测值与真实值非常接近;而在后 8 天的预测中,预测值与真实值出现较大的偏差,但最终这种偏差变得非常小。

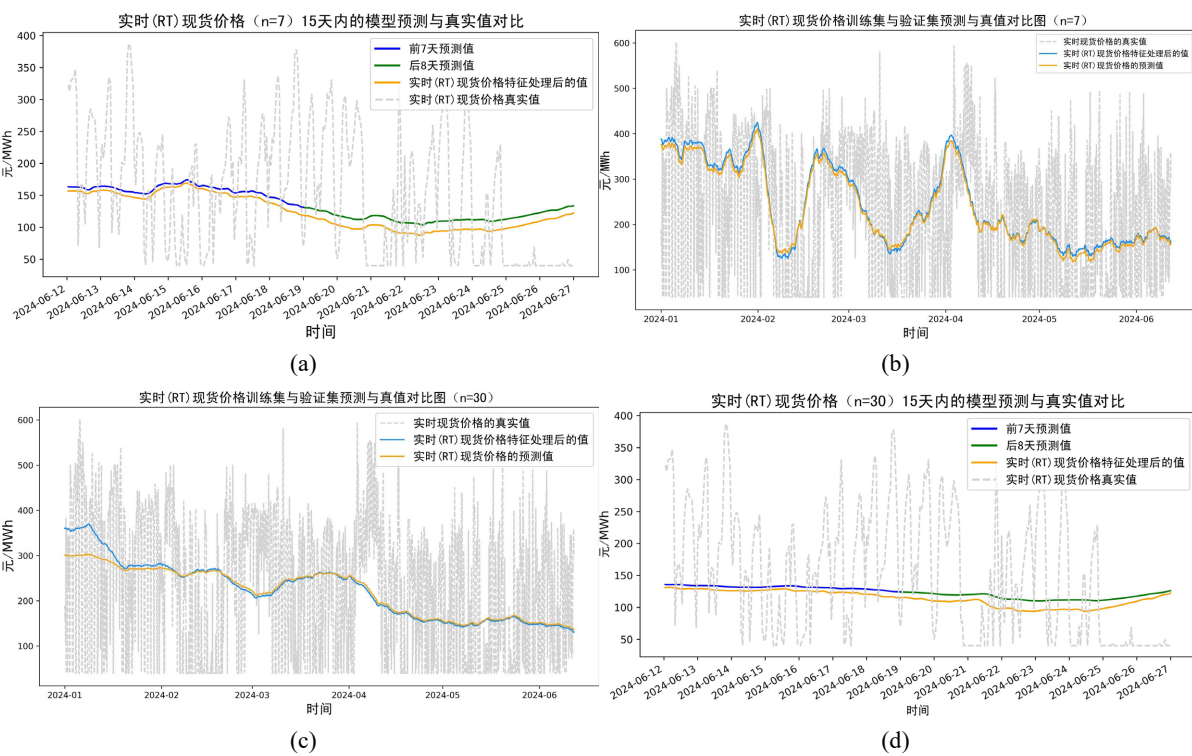


Figure 3. Training results chart and prediction results chart for average real-time spot prices

图 3. 平均实时现货价格的训练结果图与预测结果图

4.4.2. 日前现货价格预测

将日前现货价格的预处理好的数据集按照 6:3:1 的比例分割为训练集、验证集和测试集。图 4(a)的结果展示训练集的预测值与真实值非常接近,仅在峰值与谷值出略有偏差。但是这种预测偏差是可以接受的,说明模型的训练结果得到较好的验证。从图 4(b)中可以看出,从 6 月 12 日到 6 月 27 日,测试集的预测值与实际值在大多数时间段内表现出较高的一致性,后 8 天的预测结果略高于真实值。从 $n=30$ 时平均日前现货价格的走势来看,相较于 $n=7$ 时的平均实时现货价格,前者预测值的波动更加稳定。再观察图 4(c)中月平均日前现货价格的预测结果接近训练模型的真实值,甚至出现重合的迹象,说明训练模型的预测效果非常好。图 4(d)显示出 $n=30$ 时平均日前价格得到未来 7 天和 15 天的平均日前现货价格,不难看出测试集的预测结果较好。未来 7 天的平均日前现货价格预测结果更接近真实值。

4.4.3. 损失值

记录模型损失变化的目的是监控模型的训练过程及其在不同数据集上的表现。图 5 展示不同滑动

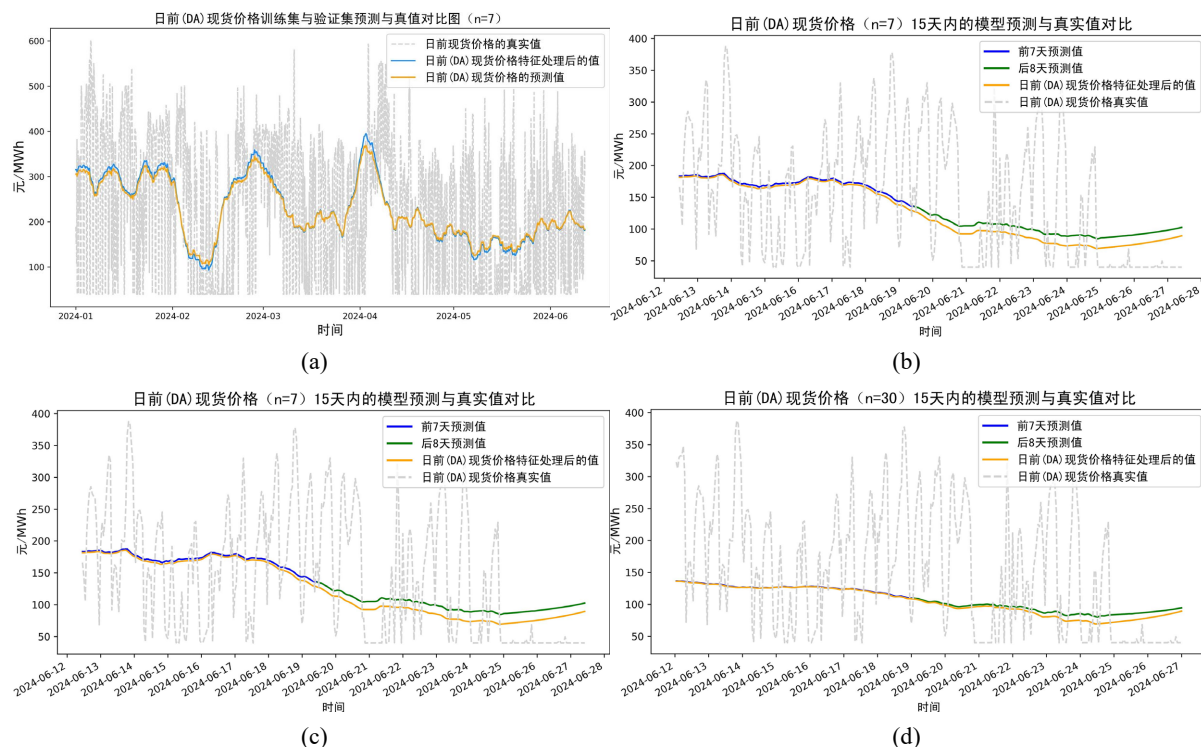


Figure 4. Training results chart and prediction results chart for average day-ahead spot prices


图 4. 平均日前现货价格的训练结果图与预测结果图

窗口大小(分别为 7 和 30)时, 平均实时与日前现货价格在训练集、验证集和测试集上的损失函数随训练迭代次数的变化情况。四张图在训练初期都显示出损失值迅速下降, 这说明模型在初期阶段能够快速学习数据中的规律, 显著降低损失。随着迭代次数的增加, 训练损失逐渐稳定并保持在较低的水平。图 5(a)开始出现短暂的损失值上升, 随后开始下降收敛; 图 5(b)表示 $n = 30$ 时的平均实时现货价格的训练模型在进行 60 次迭代后达到最佳效果。与图 5(b)略有不同的是, 图 5(c)直接开始下降收敛, 图 5(d)表示 $n = 30$ 时的平均日前现货价格的训练模型在进行 70 次迭代后达到最佳效果。

另外, 在图 5 中, 验证损失始终高于训练损失, 这也是常见的现象, 通常是由于模型在训练集上表现更好, 而在验证集上表现稍差。部分图中验证损失在后期逐渐上升, 显示出过拟合的迹象。

4.5. 预测模型结果比对

为了进一步说明 LSTM 模型的优越性, 本节结合公式(15)~(17)对比不同时间序列预测模型(AMIRA,






Figure 5. The chart of model loss variation for average day-ahead spot prices

图 5. 平均日前现货价格的模型损失变化图

Prophet, Random Forest, LSTM)在不同变量(包括 $RT_{spot,n7}$, $RT_{spot,n30}$, $DA_{spot,n7}$, $DA_{spot,n30}$)数据集上的性能指标。为此先将每个数据集按照 7:3 的比例划分为训练集和测试集, 表 1 为各模型在测试集上的性能指标结果值, 包括均方误差(MSE)、均方根误差(RMSE)和平均绝对误差(MAE)。

Table 1. Performance metrics of different models under various feature engineering conditions

表 1. 不同模型在不同特征工程下的性能指标

变量名	评价指标	ARIAM	Prophet	Random forest	LSTM
$RT_{spot,n7}$	MSE	0.0800	333.0500	1.6912	0.0795
	RMSE	0.2800	18.2500	100.2371	0.0089
	MAE	0.2700	13.9300	0.9628	0.0082
$RT_{spot,n30}$	MSE	0.0100	33.6900	0.0794	0.4098
	RMSE	0.1000	5.8000	1114.1065	0.0202
	MAE	0.0900	3.7400	0.1985	0.0109
$DA_{spot,n7}$	MSE	0.0700	339.8500	1.6183	0.0635
	RMSE	0.2600	18.4400	38.2582	0.0080
	MAE	0.2200	14.1300	0.9411	0.0063
$DA_{spot,n30}$	MSE	0.0400	57.3800	0.0777	0.0959
	RMSE	0.2100	7.5800	1296.2869	0.0098
	MAE	0.1800	3.7700	0.1999	0.0078

从表 1 中计算结果可以看出, LSTM 模型在多个评价指标上表现出色, 特别是在 $RT_{spot,n7}$ 与 $DA_{spot,n7}$ 的 MSE、RMSE 和 MAE 指标上均优于其他模型。总体来说, LSTM 预测模型仅在个别性能评价指标上略差, 但得益于其自身能够很好地处理序列数据的时间依赖关系, 其在各种特征工程条件下展示出较低的预测误差, 充分地验证了本文中 LSTM 预测模型的可靠性。

5. 现货市场最佳交易决策设计

在上述建模预测的基础上, 本节基于甘肃电力现货市场未来供需分析制定买卖双方的决策方案。

5.1. 决策背景

决策中的风险溢价(Risk Premium, RP)指特定投资回报与无风险投资回报的差异。对数收益是金融市场常用的收益度量方法,因其符合正态分布假设,更适用于统计分析和风险评估模型,能有效评估投资回报与风险。

决策设计中实时现货价格指当前市场交易中电力的即时价格,直接反映电力供需平衡状态。此价格随电力市场的供需动态变化而频繁波动,是进行实时交易的重要参考指标。日前现货价格指基于对未来电力供需情况的预测而提前确定的电力价格。此价格在实际交割日的前一天确定,为市场参与者提供提前决策的依据,有助于平衡市场预期和稳定市场运行。

5.2. 决策目标

本文利用对数收益在风险溢价中的应用,计算实时或日前现货价格与预测价格之间的差值,建立一种电力现货交易决策模型。电力现货交易双方可以根据差异情况,评估电力现货市场中的风险。通过引入对数收益,得到更为对称和直观的风险溢价价值,准确评估市场风险和回报,使得市场交易者做出最合适的交易决策。

5.3. 决策方案设计

结合(5)式给出平滑窗口 $n = 7$ 时实时现货价格的风险溢价计算公式,即

$$RP_{RTspot,7} = \begin{cases} \ln(RT_{spot,n7}) - \ln(RT_{spot,fut7}) > 0, & RT_{spot,n7} > RT_{spot,fut7} \\ \ln(RT_{spot,n7}) - \ln(RT_{spot,fut7}) < 0, & RT_{spot,n7} < RT_{spot,fut7} \end{cases} \quad (18)$$

其中 $RT_{spot,fut7}$ 为 $n = 7$ 时的实时现货价格的预测值。

买方与卖方短期内在电力现货市场的交易决策:当 $RT_{spot,n7} > RT_{spot,fut7}$ 时,说明预测值小于实际现货价格,买方可以考虑未来在现货市场中参考实时现货价格进行买入;当 $RT_{spot,n7} < RT_{spot,fut7}$ 时,说明预测值大于实际现货价格,卖方可以考虑未来在现货市场中参考实时现货价格卖出电力。

结合(6)式给出平滑窗口 $n = 7$ 的日前现货价格风险溢价的计算公式,即

$$RP_{DAspot,7} = \begin{cases} \ln(DA_{spot,n7}) - \ln(DA_{spot,fut7}) > 0, & DA_{spot,n7} > DA_{spot,fut7} \\ \ln(DA_{spot,n7}) - \ln(DA_{spot,fut7}) < 0, & DA_{spot,n7} < DA_{spot,fut7} \end{cases} \quad (19)$$

其中 $DA_{spot,fut7}$ 为 $n = 7$ 的日前现货价格的预测值。

买方与卖方短期内在电力现货市场的交易决策:当 $DA_{spot,n7} > DA_{spot,fut7}$ 时,说明预测值小于现货价格,买方可以考虑未来在现货市场中参考日前现货价格进行买入;当 $DA_{spot,n7} < DA_{spot,fut7}$ 时,说明预测值大于现货价格,卖方可以考虑未来在现货市场中参考日前现货价格卖出电力。

结合(7)式给出平滑窗口 $n = 30$ 时实时现货价格的风险溢价计算公式,

$$RP_{RTspot,30} = \begin{cases} \ln(RT_{spot,n30}) - \ln(RT_{spot,fut30}) > 0, & RT_{spot,n30} > RT_{spot,fut30} \\ \ln(RT_{spot,n30}) - \ln(RT_{spot,fut30}) < 0, & RT_{spot,n30} < RT_{spot,fut30} \end{cases} \quad (20)$$

其中 $RT_{spot,fut30}$ 为 $n = 30$ 的实时现货价格的预测值。

买方与卖方长期内在电力现货市场的交易决策:当 $RT_{spot,n30} > RT_{spot,fut30}$ 时,说明预测值小于实际现货价格,买方可以考虑未来在现货市场中参考实时现货价格进行买入;当 $RT_{spot,n30} < RT_{spot,fut30}$ 时,说明预测值大于实际现货价格,卖方可以考虑未来在现货市场中参考实时现货价格卖出电力。

结合(8)式给出平滑窗口 $n = 30$ 的日前现货价格风险溢价的计算公式,

$$RP_{DAspot,30} = \begin{cases} \ln(DA_{spot,n30}) - \ln(DA_{spot,fut30}) > 0, & DA_{spot,n30} > DA_{spot,fut30} \\ \ln(DA_{spot,n30}) - \ln(DA_{spot,fut30}) < 0, & DA_{spot,n30} < DA_{spot,fut30} \end{cases} \quad (21)$$

其中 $DA_{spot,fut30}$ 为 $n = 30$ 的日前现货价格的预测值。

买方与卖方长期内在电力现货市场的交易决策: 当 $DA_{spot,n30} > DA_{spot,fut30}$ 时, 说明预测值小于实际现货价格, 买方可以考虑未来在现货市场中参考日前现货价格进行买入; 当 $DA_{spot,n30} < DA_{spot,fut30}$ 时, 说明预测值大于实际现货价格, 卖方可以考虑未来在现货市场中参考日前现货价格卖出电力。

5.4. 决策过程与决策结果

为了展示交易决策的选取方式, 选取实例时段固定于 2024 年 6 月 12 日~6 月 27 日。将此期间甘肃电力市场平均实时现货价格与平均日前现货价格作为基础数据, 基于二者的预测数据与实际数据建立买方与卖方的最佳交易决策。表 2 与表 3 显示的是部分数据内容, 用于简单分析买方与卖方在现货市场的参与情况。图 6 与图 7 分别展示在实例时间范围内买方与卖方参与市场的具体结果。

表 2 首先给出的是当滑动窗口分别为 $n = 7$ 与 $n = 30$ 的实时现货价格, 再给出利用测试集得到的实时现货价格的预测值, 根据实际值与预测值的差值判断, 得到对应的风险溢价值。如图 6 所示, 以 0 为差值分界线, 当 $n = 7$ 与 $n = 30$ 时的差值结果均大于 0 时, 反映出买方可以在此时考虑以实时现货价格进行交易。又发现 $n = 30$ 的差值结果更高, 说明买方要善于把握长期价格的走势, 不要急于买入。对于卖方来说, 差值结果小于 0 时, 应多参照短期实时现货价格的波动特点, 及时卖出。

Table 2. Decision-making process of market participants based on real-time spot prices in Gansu
表 2. 基于甘肃实时现货价格的市场参与者决策过程

变量名	$RT_{spot,n7}$	$RT_{spot,n30}$	$RT_{spot,fut7}$	$RT_{spot,fut30}$	$RP_{RTspot,7}$	买方或卖方 做出决策	$RP_{RTspot,30}$	买方或卖方 做出决策
实时现货价格	332.500	71.074	163.313	135.648	>0	买方	<0	卖方
	337.500	40.000	163.168	135.446	>0	买方	<0	卖方

	99.799	73.223	168.122	131.921	<0	卖方	<0	卖方
	125.000	176.706	146.476	127.937	<0	卖方	>0	买方

	40.000	40.000	132.960	125.557	<0	卖方	<0	卖方
	40.000	40.000	133.705	126.024	<0	卖方	<0	卖方




Figure 6. Difference chart between predicted and actual values of real-time spot prices
图 6. 实时现货价格的预测值与真实值的差值图

表 3 首先给出的是当滑动窗口分别为 $n=7$ 与 $n=30$ 的日前现货价格,再给出利用测试集得到的日前现货价格的预测值,根据实际值与预测值的差值判断,得到对应的风险溢价。如图 7 所示,以 0 为差值分界线,当 $n=7$ 与 $n=30$ 差值结果均大于 0 时,买方应考虑及时入市。大部分的时间内, $n=30$ 的差值结果更大,意味着长期内的日前现货价格波动更有利于买方。但是不乏一些特殊情况出现,在 $n=7$ 的差值结果中,也体现了部分短期价格的可参考性。而对于卖方,大多数时间在 $n=7$ 时得到更大的差值,这里局部展示的价格波动能够更清晰地体现。因此卖方需要多观察短期内的日前现货价格波动,这能为卖方带来更多的效益。观察小于 0 的差值结果,长期的价格波动对卖方影响较小。

Table 3. Decision-making process of market participants based on real-time spot prices in Gansu
表 3. 基于甘肃实时现货价格的市场参与者决策过程

变量名	$DA_{spot,n7}$	$DA_{spot,n30}$	$DA_{spot,fut7}$	$DA_{spot,fut30}$	$RP_{DAspot,7}$	买方或卖方 做出决策	$RP_{DAspot,30}$	买方或卖方 做出决策
日前现货价格	166.121	322.500	183.370	136.504	<0	卖方	>0	买方
	144.070	312.500	183.331	136.404	<0	卖方	>0	买方

	71.662	71.736	171.260	126.864	<0	卖方	<0	卖方
	170.856	232.585	156.866	117.836	>0	买方	>0	买方

	40.000	40.000	101.497	93.693	<0	卖方	<0	卖方
	40.000	40.000	102.449	94.463	<0	卖方	<0	卖方




Figure 7. Difference chart between predicted and actual values of day-ahead spot prices
图 7. 日前现货价格的预测值与真实值的差值图

6. 结论

本文通过对甘肃电力现货价格的精确预测与最佳交易决策研究,旨在提高市场参与者的交易决策与监测预警支持能力。首先从数据预处理与特征工程入手,对 2024 年 1 月 1 日至 6 月 30 日的现货价格数据进行平滑处理,捕捉短期和长期的价格趋势;随后建立了 LSTM 模型对甘肃电力市场未来 7 天和 15 天的平均实时和日前现货价格进行了预测。结果表明, LSTM 模型在训练集和测试集上的预测准确度较高。其次,本文利用对数收益分析实时和日前现货价格的风险溢价,为市场参与者提供了买卖双方的最佳交易决策。结合实际算例,展示出利用预测价格与实际价格的差异来评估市场风险的评估过程,并制定相

应的交易策略与监测预警机制。本文的创新之处在于利用先进的机器学习算法,在高比例新能源电网背景下,对甘肃电力现货市场价格进行了精准预测,研究结果有助于规避市场风险,达到优化资源配置的目的。本文进一步的工作是在机器学习预测的基础上,对甘肃电力现货价格形成的内在机理进行深入探讨,从而为省级双边现货市场监测关键技术的研发提供支持。

基金项目

本文由国网甘肃省电力公司科技项目“适应高比例新能源的省级双边现货市场监测关键技术研究及应用”(522722230062)资助。

参考文献

- [1] 杨春祥, 张天宇, 张晓斌, 等. 适应高比例新能源电网的甘肃双边现货市场机制设计与运行分析[J]. 电网技术, 2022, 46(1): 63-69.
- [2] 中共中央国务院. 关于进一步深化电力体制改革的若干意见(中发〔2015〕9号)[Z]. 2015.
- [3] 徐可琪. 高比例新能源下的市场电价预测及风险评估与分析[D]: [硕士学位论文]. 北京: 华北电力大学, 2023.
- [4] 陈振寰, 杨春祥, 张柏林, 等. 甘肃电力现货市场双边交易机制设计[J]. 全球能源互联网, 2020, 3(5): 441-450.
- [5] Cruz May, E., Bassam, A., Ricalde, L.J., Escalante Soberanis, M.A., Oubram, O., May Tzuc, O., et al. (2022) Global Sensitivity Analysis for a Real-Time Electricity Market Forecast by a Machine Learning Approach: A Case Study of Mexico. *International Journal of Electrical Power & Energy Systems*, **135**, Article ID: 107505. <https://doi.org/10.1016/j.ijepes.2021.107505>
- [6] Wu, J., Wang, J. and Kong, X. (2024) Intelligent Strategic Bidding in Competitive Electricity Markets Using Multi-Agent Simulation and Deep Reinforcement Learning. *Applied Soft Computing*, **152**, Article ID: 111235. <https://doi.org/10.1016/j.asoc.2024.111235>
- [7] Imani, M.H., Bompard, E., Colella, P. and Huang, T. (2021) Forecasting Electricity Price in Different Time Horizons: An Application to the Italian Electricity Market. *IEEE Transactions on Industry Applications*, **57**, 5726-5736. <https://doi.org/10.1109/tia.2021.3114129>
- [8] Magalhães, B.G., Bento, P.M.R., Pombo, J.A.N., Calado, M.R.A. and Mariano, S.J.P.S. (2023) Spot Price Forecasting for Best Trading Strategy Decision Support in the Iberian Electricity Market. *Expert Systems with Applications*, **224**, Article ID: 120059. <https://doi.org/10.1016/j.eswa.2023.120059>
- [9] 袁秀芳. SVR 模型及其用于经济数据预测的研究[D]: [硕士学位论文]. 南充: 西华师范大学, 2016.
- [10] 章维维. 基于 ARIMA 修正模型的电力市场价格预测研究[D]: [硕士学位论文]. 吉林: 东北电力大学, 2018.
- [11] Bashir, T., Haoyong, C., Tahir, M.F. and Liqiang, Z. (2022) Short Term Electricity Load Forecasting Using Hybrid Prophet-LSTM Model Optimized by BPNN. *Energy Reports*, **8**, 1678-1686. <https://doi.org/10.1016/j.egy.2021.12.067>
- [12] Rafi, S.H., Nahid-Al-Masood, Deebe, S.R. and Hossain, E. (2021) A Short-Term Load Forecasting Method Using Integrated CNN and LSTM Network. *IEEE Access*, **9**, 32436-32448. <https://doi.org/10.1109/access.2021.3060654>
- [13] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8): 131-137.
- [14] 查云龙, 茅玉龙, 卜宇, 等. 基于 BasicNet-LSTM 的短期电力负荷预测模型构建[J]. 中国设备工程, 2024(11): 139-141.
- [15] 勾玄, 肖先勇. 基于经验模式分解与 LSTM 神经网络的短期电价预测模型[J]. 西安理工大学学报, 2020, 36(1): 129-134.
- [16] Varanasi, J. and Tripathi, M.M. (2022) Electricity Price Forecasting Using LSTM Network and K-Means Clustering by Considering the Effect of Wind Power Generation. In: Chanda, C.K., Szymanski, J.R., Sikander, A., Mondal, P.K. and Acharjee, D., Eds., *Advanced Energy and Control Systems*, Springer, 29-41. https://doi.org/10.1007/978-981-16-7274-3_3
- [17] Chang, Z., Zhang, Y. and Chen, W. (2019) Electricity Price Prediction Based on Hybrid Model of Adam Optimized LSTM Neural Network and Wavelet Transform. *Energy*, **187**, Article ID: 115804. <https://doi.org/10.1016/j.energy.2019.07.134>
- [18] Zhou, S., Zhou, L., Mao, M., Tai, H. and Wan, Y. (2019) An Optimized Heterogeneous Structure LSTM Network for Electricity Price Forecasting. *IEEE Access*, **7**, 108161-108173. <https://doi.org/10.1109/access.2019.2932999>
- [19] 殷豪, 丁伟锋, 陈顺, 等. 基于长短时记忆网络-纵横交叉算法的含高比例新能源电力市场日前电价预测[J]. 电网技术, 2022, 46(2): 472-480.