

基于Informer-MATD3的风力发电商现货 价格预测-日前竞价两阶段决策模型

张硕¹, 王雨欣¹, 李英姿², 贺运政³

(1. 华北电力大学经济与管理学院, 北京市 102206; 2. 北京科技大学经济管理学院, 北京市 100083;
3. 华北电力大学环境科学与工程系, 河北省保定市 071003)

摘要:【目的】为解决新型电力系统中风电高比例渗透引发的电价高波动性与预测难题, 提出一种适用于风力发电商的动态竞价策略。【方法】首先, 构建了多市场因素融合的Informer(Market-Informer)预测模型, 通过引入碳价、绿证价格及煤炭价格等关键变量, 实现日前电价预测; 进一步, 将预测信息嵌入基于多智能体双延迟深度确定性策略梯度(multi-agent twin delayed deep deterministic policy gradient, MATD3)算法的竞价决策框架中。该框架通过在包含水电、火电、光伏发电商的市场环境中进行集中训练, 最终实现风力发电商的最优竞价策略。【结果】以欧洲某电力市场2022年数据为案例进行竞价, 结果显示其预测方向准确性(directional accuracy coefficient, DAC)在10%的误差水平下可达94.3%, 较传统自回归积分移动平均模型(autoregressive integrated moving average model, ARIMA)提升了18.6个百分点。该策略使系统总成本降低11.4%, 风力发电商收益提升9.8%, 中标率提高18.7%, 收益波动降低22.3%。【结论】算例分析验证了“预测-决策”动态耦合机制在提升可再生能源竞价能力与低碳转型中的有效性, 为高比例可再生能源电力市场提供了智能化决策范式。

关键词: 电价预测; Informer模型; 多智能体双延迟深度确定性策略梯度(MATD3)算法; 市场竞价

中图分类号: TM73

文献标志码: A

文章编号: 1000-7229(2026)04-0063-19

DOI: 10.12204/j.issn.1000-7229.2026.04.006

Two-Stage Day-Ahead Bidding Decision Model for Wind Power Generator's Spot Price Forecasting Based on Informer and MATD3

ZHANG Shuo¹, WANG Yuxin¹, LI Yingzi², HE Yunzheng³

(1. School of Economics and Management, North China Electric Power University, Beijing 102206, China;

2. School of Economics & Management, University of Science and Technology Beijing,
Beijing 100083, China; 3. School of Environmental Science and Engineering, North

China Electric Power University, Baoding 071003, Hebei Province, China)

ABSTRACT: [Objective] To address the challenges of high electricity price volatility and forecasting difficulties caused by the high penetration of wind power in the new power system, this paper proposes a dynamic bidding strategy suitable for wind power producers. [Methods] The study first constructs a Market-Informer forecasting model that integrates multiple market factors. By introducing key variables such as carbon prices, green electricity certificate prices, and coal prices, it achieves day-ahead electricity price forecasting. Furthermore, the forecast information is embedded into a bidding decision framework designed based on the multi-agent twin delayed deep deterministic policy gradient (MATD3) algorithm. This framework is centrally trained in a market environment that includes hydropower, thermal power, and photovoltaic power producers, which finally contributes to the generation of optimal bidding strategies for wind power producers. [Results] Using data from a European electricity market in 2022 as a case study for bidding, the results show that the directional accuracy coefficient (DAC) of forecasting can reach 94.3% under a 10% error margin, representing an 18.6 percentage-point improvement over the traditional autoregressive integrated moving average (ARIMA) model. This strategy reduces the total system cost by 11.4%, increases the revenue of wind power producers by 9.8%, raises the bid-winning rate by 18.7%, and decreases

基金项目: 国家重点研发计划项目(2021YFB2400704); 教育部人文社会科学研究规划基金(23YJA630133); 北京市自然科学基金项目(9232019); 北京市社会科学基金项目(22GLB020)

© Editorial Department of Electric Power Construction. OA under CC BY-NC-ND 4.0.

revenue volatility by 22.3%. **[Conclusions]** The case study verifies the effectiveness of the "forecasting-decision" dynamic coupling mechanism in enhancing the bidding capacity of renewable energy and promoting low-carbon transition, providing an intelligent decision-making paradigm for power markets with a high penetration of renewable energy.

This work is supported by National Key Research and Development Program of China (No. 2021YFB2400704), Humanities and Social Science Fund of Ministry of Education of China (No. 23YJA630133), Beijing Natural Science Foundation (No. 9232019) and Beijing Social Science Foundation (No. 22GLB020).

KEYWORDS: electricity price forecasting; Informer model; multi-agent twin delayed deep deterministic policy gradient (MATD3); market bidding

0 引言

在新型电力系统建设背景下,风电、光伏等可再生能源的高比例渗透正深刻改变电力市场运行逻辑^[1-3]。随着全国统一电力市场的加速构建以及《关于完善能源绿色低碳转型体制机制和政策措施的意见》等政策文件的出台,电力市场的市场化程度与灵活性进一步提升,为可再生能源的消纳与交易提供了更广阔的空间。然而,风电的间歇性与波动性特征,叠加市场价格信号的快速变化,使得电价预测难度显著增加,传统竞价策略难以适应高比例可再生能源接入下的市场环境。在此背景下,如何通过智能化手段提升风力发电商的竞价能力,成为保障其收益稳定与促进低碳转型的关键问题。截至 2024 年,我国风电装机容量突破 4 亿 kW,其固有的间歇性、反调峰特性与电力市场实时平衡要求形成矛盾,导致市场出清电价呈现高波动、强非线性特征,传统基于历史数据统计规律的报价策略面临失效风险^[4-6]。与此同时,电力市场改革持续深化,现货市场全电量竞价、中长期分时段交易等机制创新,要求发电商从“被动执行计划”转向“主动策略博弈”。然而,现有研究多聚焦于独立解决电价预测或报价优化问题,缺乏对“预测-决策”动态耦合机制的系统性建模,难以满足新型电力市场对发电商智能化决策能力的迫切需求。在“双碳”目标的引领下,低碳减排也已成为电力行业发展的核心要义。

早期电价预测研究多基于统计学方法,主要通过历史电价数据的时间序列分析进行预测。自回归 (autoregressive, AR) 模型、滑动平均 (moving average, MA) 模型以及整合滑动平均自回归 (autoregressive integrated moving average, ARIMA) 模型等被广泛应用于电价预测中。这些方法通常只能处理线性关系,难以准确模拟电价波动的非线性特征。为提升预测精度,研究者们提出了多种改进方法,如结合广义自回归条件异方差 (generalized autoregressive conditional heteroskedasticity, GARCH) 模型与 ARIMA 模型,以捕捉电价波动导致的方差变

化^[7]。此外,季节性自回归积分滑动平均 (seasonal autoregressive integrated moving average, SARIMA) 模型也被用于考虑电价中的周期性因素^[8-10]。

随着人工智能技术的发展,基于数据驱动的电价预测方法逐渐成为主流^[11]。这些方法通过对数据本身的特征进行分析提取,挖掘电价波动中的非线性关系,具有较高的预测精度。文献[12]提出了一种基于小波变换和 Adam 优化的长短期记忆 (long short-term memory, LSTM) 网络混合模型,通过小波变换处理电价序列以稳定方差,结合 LSTM 捕捉电价序列的隐含关系。文献[13]将最大信息系数相关性分析与改进多层级门控 LSTM 结合,提高了输入序列中与预测电价相关的信息密度。

为进一步提升预测精度,目前很多研究也提出了多种混合模型。文献[14]提出了一种集成了注意力机制的基于 Informer 模型的短期光伏发电量精准预测方法;文献[15]则结合卷积神经网络 (convolutional neural network, CNN) 和门控循环单元 (gated recurrent unit, GRU) 模型,利用 CNN 提取电价数据的空间特征,GRU 捕捉时间依赖性。在模型优化方面,目前引入了多种智能优化算法,如遗传算法 (genetic algorithm, GA)、粒子群优化 (particle swarm optimization, PSO) 算法,用于参数优化和特征选择^[16]。文献[17]通过提取净现货竞价空间作为新特征,有效提高了日前出清电价的预测精度。文献[18]针对工业建筑负荷的强随机性,提出基于分解重构和时间卷积网络-Informer模型-双向门控循环单元 (temporal convolutional network-Informer-bidirectional gated recurrent unit, TCN-Informer-BiGRU) 的短期电力负荷预测方法,构建并行双分支预测模型,极大地提高了预测精度。文献[19]利用双延迟深度确定性策略梯度 (twin delayed deep deterministic policy gradient, TD3) 算法构建智能体,设计了一种时间窗口长度自适应可变的变权组合预测策略,使智能体能够快速收敛并做出最优决策。

在基于深度强化学习的报价策略设计方面,文献[20]提出了一种基于 Stackelberg 博弈的负荷聚合

商(load aggregator, LA)竞价策略,通过两阶段定价模型优化需求侧资源配置,有效降低了购电成本。文献[21]针对电力市场中的发电商报价问题,设计了一种基于近端策略优化(proximal policy optimization, PPO)算法的深度强化学习模型,显著提升了发电商的收益。文献[22]提出了一种基于约束感知强化学习的动态聚合与多时间尺度竞价策略,通过分层分区调控架构有效提升了虚拟电厂的市场竞争力。针对新能源参与电力市场的问题,文献[23]通过结合扩散模型(denoising diffusion probabilistic model, DDPM)生成风电场景,并采用改进的Wolf-PHC算法优化报价,有效应对了风电出力的不确定性。文献[24]提出了一种基于多智能体软演员-批评家(multi-agent soft actor-critic, MASAC)算法的风储系统竞价模型,通过引入实时调频性能得分机制,提升了风储系统在调频市场中的竞争力。深度强化学习广泛应用于电价预测、负荷预测及市场参与者行为建模^[25-27]。文献[28]通过结合LSTM和粒子群优化算法,提出了一种混合神经网络模型,实现了对澳大利亚国家电力市场电价的精准预测。文献[29]利用堆叠去噪自编码器-集合经验模态分解(stacked denoising autoencoder-ensemble empirical mode decomposition, SDAE-EEMD)与改进Informer-双向长短期记忆网络(Informer-bidirectional long short-term memory, Informer-BiLSTM)模型,提高了短期负荷预测的精度。文献[30]提出了一种基于深度强化学习的考虑竞争对手行为的电价-电量对策略投标框架,通过TD3算法,实现了智能电力市场中生产商利润最大化及策略鲁棒性。文献[31]基于TD3算法,提出了价格制定者虚拟电厂在日前市场中的最优投标策略,通过考虑市场参与者间的博弈关系,实现了虚拟电厂收益的最大化。

为解决风力发电商在新型电力系统下的竞价难题,本文实现预测与决策策略的动态协同优化以应对市场的不确定与复杂。主要创新点如下:

1)方法创新。本文创新性地提出“预测-决策”两阶段动态耦合框架,突破了现有研究孤立处理电价预测与报价决策的局限,通过融合多市场因素的Informer预测模型与基于多智能体双延迟深度确定性策略梯度(multi-agent twin delayed deep deterministic policy gradient, MATD3)的竞价决策框架,实现了预测与决策策略的实时协同优化。针对风电电价强非线性特征,首次将碳市场价格、绿证价格及煤炭价格纳入预测体系,利用ProbSparse自注意力机制捕捉市场动态关联,显著提升预测精度。同

时,设计了基于MATD3的多主体竞价策略,有效协调了风电、水电、火电及光伏发电商的竞价行为,提升了市场效率。

2)应用创新。本文所提竞价策略特别适用于高比例可再生能源电力市场,有效应对风电等可再生能源的间歇性与波动性,为发电商提供科学报价依据。通过引入碳市场价格与绿证价格等低碳政策变量,不仅提高了预测精度,还体现了对低碳减排政策的高度关注,支持电力市场低碳转型。

3)性能提升。实验表明,Informer预测模型方向准确性(directional accuracy coefficient, DAC)达94.3%,较传统模型提升18.6个百分点,均方根误差(root mean squared error, RMSE)降低12.3%。竞价策略使系统总成本降低了11.4%,风力发电商收益提高了9.8%,中标率增大了18.7%,收益波动降低了22.3%。MATD3算法增强了收敛速度与策略稳定性,提升了整体市场收益。

1 考虑多市场因素的现货价格Informer预测模型

1.1 基于现货市场供应的多时间尺度分析

电力现货价格的形成是多时间尺度市场力量耦合的结果。在超短期尺度(15 min),出力供需比 R_t 是核心驱动因素^[32],直接决定系统边际价格。当 $R_t < 1$ 时,备用机组启动使电价急剧飙升。电力负荷 L_t 则通过需求弹性塑造日内周期。在短期尺度(1~3天),电煤价格 C_t 通过燃料成本传导影响边际机组报价,煤炭作为火力发电主要燃料,价格波动对电力现货价格影响直接且显著。火力发电在我国电力供应中占重要地位,煤炭成本占其发电成本的60%~70%,煤炭价格上涨,火力发电企业燃料成本大增,为维持经营和利润,会提高上网电价,推动整个电力市场成本上升,促使电力现货价格上涨。中长期电价 p_t^{forward} 则形成价格锚定效应,当期货贴水提升时,套利行为会压制现货波动幅度^[33]。中长期尺度(>7天)体现政策市场影响,碳市场价格 p_t^{carbon} 通过碳排放成本内部化推高化石能源发电成本。绿证价格 p_t^{green} 则改变新能源企业报价策略,绿证价格上涨通常意味着市场对可再生能源电力的需求增加^[34],这有助于提升风电等可再生能源发电的市场价值,从而对电价产生积极影响。上述变量说明见表1。

结合历史现货价格 p_t^{spot} 最终可以得到多尺度特征融合公式:

$$X_t^{\text{multi}} = [p_t^{\text{spot}}, p_t^{\text{forward}}, p_t^{\text{green}}, p_t^{\text{carbon}}, C_t, L_t, R_t] \quad (1)$$

表 1 多市场因素变量说明

Table 1 Explanation for multiple market factors variables

变量	时间尺度
历史现货价格 p_t^{spot} /(欧元/MWh)	15 min
电力负荷 L_t /MW	15 min
电煤价格 C_t /(欧元/t)	日
中长期电价 p_t^{forward} /(欧元/MWh)	月
碳市场价格 p_t^{carbon} /(欧元/t)	日
绿证价格 p_t^{green} /(欧元/MWh)	日
出力供需比 R_t	15 min

1.2 基于 Informer 的预测模型总体结构

针对电力现货价格预测中多市场耦合复杂、长期依赖性强及极端事件敏感三方面问题,本文提出改进的多市场因素融合的 Informer(Market-Informer)模型,采用特征分流的方式进行抽象,最后进行融合。输入层将 168 h 历史序列处理为 10 维特征向量,包含 7 维市场因子(现货价、中长期价、绿证价、碳价、电煤价、负荷、供需比)和 3 维时间编码(日/周相位与节假日标识)。为适应不同变量的物理特性,创新性地实施分组预处理:能源因子组(p_t^{spot} 、 L_t 、 R_t)经批归一化保留瞬时波动特征;政策因子组(C_t 、 p_t^{carbon} 、 p_t^{green})采用 Tukey 变换压缩长尾分布;中长期组(p_t^{forward})通过一阶差分凸显期现套利趋势。在编码阶段,模型构建 3

条独立路径实现特征分流:能源路径采用空洞率递增的卷积堆(膨胀率为 1,3,5)捕获出力供需比突变与负荷爬坡事件;政策路径引入时间衰减掩码建模碳价 56 h 半衰期的持续影响;中长期路径使用时变权重记忆单元跟踪期货价格均值回归特性,3 条路径的输出通过特征桥接层实现跨域融合。解码器采用简洁的序列到序列架构,将编码器提取的多尺度特征转化为最终的现货电价预测。Market-Informer 架构如图 1 所示。

1.3 编码嵌入操作

电力现货价格预测的核心挑战在于有效融合多源异构市场数据,这些数据在时间尺度、统计特性和市场属性上存在显著差异。本模块通过 3 层嵌入架构实现特征工程的物理与数学意义的统一:市场类型嵌入基于电力市场运行机制的本质解耦,将变量划分为能源市场类(现货价、负荷、供需比、电煤价)、政策市场类(绿证价、碳价)和中长期电价,采用独热编码标识各类别:

$$\boldsymbol{E}_{\text{type}} = \begin{cases} [1, 0, 0], & \text{能源市场类} \\ [0, 1, 0], & \text{政策市场类} \\ [0, 0, 1], & \text{中长期电价} \end{cases} \quad (2)$$

式中: $\boldsymbol{E}_{\text{type}}$ 为市场类型嵌入向量。

周期相位嵌入显式建模市场活动的时序规律,




图 1 Market-Informer 架构

Fig. 1 Market-Informer framework

通过日相位角和周相位角的傅里叶基函数捕捉日前市场的双峰特性和中长期交易的周循环模式:

$$\theta_{\text{day}} = 2\pi(t \bmod 1440)/1440 \quad (3)$$

$$\theta_{\text{week}} = 2\pi(t \bmod 10\,080)/10\,080 \quad (4)$$

$$\mathbf{E}_{\text{cyc}} = [\sin \theta_{\text{day}}, \cos \theta_{\text{day}}, \sin \theta_{\text{week}}, \cos \theta_{\text{week}}] \quad (5)$$

式中: θ_{day} 为日相位角(弧度制); θ_{week} 为周相位角(弧度制); t 为时间戳, min; $\mathbf{E}_{\text{cyc}}$ 为周期特征向量。

差异归一化策略则针对不同变量的统计分布特性,对政策类变量实施 Tukey 变换压缩长尾分布,对能源类变量采用动态标准化保留供需突变信息。

$$\tilde{x} = \begin{cases} x^{0.25}, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (6)$$

式中: $\tilde{x}$ 为归一化后的政策变量; x 为原始政策变量值(绿证价或碳价);指数 0.25 为基于长尾分布特征的经验参数。

$$\tilde{x}_t = \frac{x_t - \mu_t - 168:t}{\sigma_t - 168:t} \quad (7)$$

式中: $\tilde{x}_t$ 为标准化后的能源变量; x_t 为原始能源变量值(负荷 L_t 、供需比 R_t 或电煤价 C_t); μ_t 为历史 168 h(7 天)的均值; σ_t 为历史 168 h(7 天)的标准差。

最终通过可学习投影矩阵将处理后的特征映射至高维隐空间,实现特征解耦与升维,同时在物理意义上构建多市场耦合的联合表征。

$$\mathbf{Z}^{(0)} = \mathbf{W}_p \mathbf{U}_t \quad (8)$$

$$\mathbf{W}_p \in \mathbb{R}^{10 \times 512} \quad (9)$$

$$\dim(\mathbf{Z}^{(0)}) = 512 \quad (10)$$

式中: $\mathbf{Z}^{(0)}$ 为嵌入层输出; $\mathbf{W}_p$ 为可学习投影矩阵; $\mathbf{U}_t$ 为拼接后的特征向量; $\dim(\mathbf{Z}^{(0)})$ 为嵌入维度。

1.4 编码器

1.4.1 多电力现货价格的多因素特征提取

编码器作为模型的核心组件,承担着从复杂市场数据中提取深层特征的重要任务。针对电力市场数据的特性,本文设计了多路径特征提取机制,通过能源路径、政策路径和中长期路径分别处理不同类型的市场变量。

能源路径专门处理电力负荷、出力供需比等具有明显时空相关性的变量,采用空洞卷积网络来捕获不同时间尺度上的供需关系变化^[35]。其中,膨胀率递增的设计(膨胀率为 1, 3, 5)能够有效感知从分钟级到小时级的负荷波动,特别是对新能源出力骤降等突发事件具有快速响应能力。

$$\mathbf{Z}_{\text{phys}}^{(l)} = \text{DConv}(\mathbf{Z}^{(l-1)})(\mathbf{Z}^{(l-1)}, k=3, d=2^{l-1}) \quad (11)$$

式中: $\mathbf{Z}_{\text{phys}}^{(l)}$ 为第 l 层能源路径输出; $\mathbf{Z}^{(l-1)}$ 为 $l-1$ 层输出特征; k 为卷积核大小; d 为空洞率(按层数指数增

长)。膨胀率递增示意如图 2 所示。




图2 $k=3$ 时膨胀率递增示意

Fig. 2 Schematic diagram of increasing expansion rate when $k=3$

政策路径则专注于处理碳价和绿证价格,通过引入时间衰减掩码来模拟政策影响的持续性特征,这种设计能够准确反映碳价变动对发电成本的传导时滞。

$$M_{ij} = e^{-\lambda|t_i - t_j|} I_{\{p_{\text{carbon}} > 0\}} \quad (12)$$

式中: M_{ij} 为时间 i 到 j 的衰减系数; λ 为衰减速率,取 0.05 h^{-1} ; I 为指示函数(碳价有效时为 1); t_i 为当前时刻; t_j 为历史时刻。

中长期路径采用时变权重的记忆单元来处理中长期电价数据,能够更好地捕捉期货市场与现货市场之间的套利关系和均值回归特性。

$$h_t = \mathbf{G}[p_t^{\text{forward}}, h_{t-1}(1 + \alpha\Delta t)] \quad (13)$$

式中: h_t 为 t 时刻的隐藏状态; $\mathbf{G}$ 为门控循环单元,用于捕捉时间序列的长期依赖关系; α 为时间衰减系数,取 0.1; Δt 为时间间隔。

3 条路径提取的特征通过特征桥接层进行融合:

$$\Phi = \mathbf{W}_b [\mathbf{Z}_{\text{phys}}^{(L)} \oplus \mathbf{Z}_{\text{policy}}^{(L)} \oplus \text{AvgPool}(\mathbf{Z}_{\text{final}}^{(L)})] + \mathbf{b}_b \quad (14)$$

式中: Φ 为桥接后的特征; $\text{AvgPool}(\cdot)$ 为平均池化操作; $\mathbf{W}_b$ 为符合特征维度要求的可学习权重矩阵; $\mathbf{b}_b$ 为可学习的偏置项; $\mathbf{Z}_{\text{phys}}^{(L)}$ 为第 L 层能源特征输出; $\mathbf{Z}_{\text{policy}}^{(L)}$ 为第 L 层政策特征输出; $\mathbf{Z}_{\text{final}}^{(L)}$ 为第 L 层最终输出。

该层有效实现了跨域特征的交互,编码器的输出包含了电力市场价格形成的多尺度、多因素耦合特征,为后续的解码预测提供了丰富的信息。

1.4.2 蒸馏操作

蒸馏操作通过层级式的特征压缩和精炼机制,逐步剔除冗余信息,保留对电价预测最具判别性的特征。蒸馏操作采用了两阶段处理流程:首先通过最大池化实现特征图的降维,随后利用门控线性单元进行特征选择。蒸馏操作对不同类型的市场变量采取了差异化的处理策略。

1) 能源变量特征蒸馏。

对于能源类变量,重点保留其突变特征:

$$\mathbf{Z}_{\text{phys}}^{(l)} = \text{MaxPool}\{\text{ReLU}[\text{Conv1D}(\mathbf{Z}^{(l-1)})]\} \quad (15)$$

式中: $\text{MaxPool}(\cdot)$ 为最大池化; $\text{ReLU}(\cdot)$ 为修正线性单元激活函数; $\text{Conv1D}(\cdot)$ 为一维卷积操作。

2) 政策变量特征蒸馏。

对于政策类变量, 更关注其持续影响的时间模式。通过3层的级联蒸馏, 序列长度从初始的168个时间点逐步压缩至21个, 但关键的价格形成特征得到了完整保留。

$$\mathbf{G} = \sigma(\mathbf{W}_g[\mathbf{Z}^{(l-1)}, \mathbf{E}_{\text{type}}]) \quad (16)$$

$$\mathbf{Z}_{\text{policy}}^{(l)} = \mathbf{G} \otimes \mathbf{Z}^{(l-1)} \quad (17)$$

式中: $\sigma(\cdot)$ 为激活函数, 可以将输出映射到(0, 1)区间; $\mathbf{W}_g$ 为可学习权重矩阵。

在特征处理时, 中长期路径使用的时变权重记忆单元相当于隐式蒸馏, 在此过程中不再进行蒸馏操作。

特征重组和残差连接式为:

$$\mathbf{Z}^{(l)} = \text{LayerNorm}(\mathbf{Z}_{\text{phys}}^{(l)} + \mathbf{Z}_{\text{policy}}^{(l)}) \quad (18)$$

$$\mathbf{Z}_{\text{final}}^{(l)} = \mathbf{Z}^{(l)} + \mathbf{W}_r \mathbf{Z}^{(l-1)} \quad (19)$$

式中: $\text{LayerNorm}(\cdot)$ 为层归一化处理; $\mathbf{W}_r$ 为可学习的残差权重矩阵。

残差连接机制确保了极端事件信息不会在蒸馏过程中丢失。层归一化的引入稳定了不同市场变量的特征尺度, 防止某一类变量(如剧烈波动的碳价)主导整个特征空间。通过3层的级联蒸馏, 模型最终提取的特征既包含分钟级的供需动态, 又保留了政策影响的长期趋势, 形成了多时间尺度融合的优质特征表示。

最后将序列映射为传统 Transformer 的查询矩阵 $\mathbf{Q}_{\text{enc}}^T$ 、主键矩阵 $\mathbf{K}_{\text{enc}}^T$ 和值矩阵 $\mathbf{V}_{\text{enc}}^T$, 便于后续的解码器进行解码操作。

$$\mathbf{Q}_{\text{enc}}^T = \mathbf{W}_q \mathbf{Z}_{\text{final}}^{(l)} \quad (20)$$

$$\mathbf{K}_{\text{enc}}^T = \mathbf{W}_k \mathbf{Z}_{\text{final}}^{(l)} \quad (21)$$

$$\mathbf{V}_{\text{enc}}^T = \mathbf{W}_v \mathbf{Z}_{\text{final}}^{(l)} \quad (22)$$

式中: $\mathbf{W}_q$ 、 $\mathbf{W}_k$ 、 $\mathbf{W}_v$ 为符合特征维度要求的可学习权重矩阵。

编码器结构如图3所示。

1.5 解码器

解码器采用简洁的序列到序列架构, 将编码器提取的多尺度特征转化为最终的现货电价预测。解码器接收2个关键输入: 编码器输出的包含历史市场的信息高阶特征矩阵和未来时间步的初始化序列。在解码过程中, 通过多层注意力机制实现历史特征与未来信息的融合, 最终输出预测电价序列。解码器结构如图4所示。

解码器的核心计算流程为:

$$\mathbf{X}_{\text{future}} = [0; \mathbf{E}_{\text{time}}(t+1:t+\tau); p_{t:t+\tau-1}^{\text{forward}}] \quad (23)$$




图3 编码器结构

Fig. 3 Encoder structure




图4 解码器结构

Fig. 4 Decoder structure

$$\mathbf{A}_{\text{cross}} = \text{Softmax}\left(\frac{\mathbf{Q}_{\text{dec}} \mathbf{K}_{\text{enc}}^T}{\sqrt{d_k}}\right) \quad (24)$$

$$\mathbf{Z}_{\text{dec}} = \mathbf{A}_{\text{cross}} \mathbf{V}_{\text{enc}}^T \quad (25)$$

$$\hat{p}_{t+1:t+\tau}^{\text{spot}} = \text{Linear}[\text{LayerNorm}(\mathbf{Z}_{\text{dec}}^{(N)})] \quad (26)$$

式中: $\mathbf{X}_{\text{future}}$ 为未来序列; $\mathbf{E}_{\text{time}}$ 为未来时间步的位置编码; $p_{t:t+\tau-1}^{\text{forward}}$ 为对应时段的中长期电价(趋势约束); $\mathbf{A}_{\text{cross}}$ 为跨注意力计算; Softmax 为激活函数, 可以将注意力分数归一化为概率分布, 使所有权重之和为1;

Q_{dec} 为解码器查询矩阵; d_k 为注意力维度; $\hat{p}_{t+1:t+\tau}^{\text{spot}}$ 为最终预测输出; $Z_{\text{dec}}^{(N)}$ 为第 N 层解码器输出; $\text{Linear}(\cdot)$ 为全连接投影层。

2 风力发电商竞价决策模型

2.1 双层竞价策略模型概述

精准的电价预测为风力发电商参与竞价提供了关键依据,但市场环境复杂多变,仅依靠预测难以确保竞价策略的最优性。因此,还需结合科学有效的竞价策略,才能进一步提升风力发电商在新型电力系统中的竞争力。本文所提“预测-决策”两阶段竞价流程如图5所示。

在电力市场中,为了更有效地应对市场的不确定性和复杂性,本文提出一种双层竞价策略模型。该模型上层由风力发电商根据预测信息制定报价策

略,而火力发电商、水力发电商和光伏发电商则基于成本进行报价;下层则通过市场出清机制确定最终的中标电量和电价。发电商竞价策略如图6所示。

本文所提“预测-决策”动态耦合机制是一种前馈式耦合,即高精度的日前电价预测信息作为前馈输入,显著提升了后续竞价策略的决策质量。在当前阶段,决策模块的输出表现(如中标收益)并不会反向反馈给预测模块用于其在线参数调整,两者保持相对独立。

2.2 风力发电商报价策略

风力发电商的报价策略基于第1章所述的Informer预测模型,该模型综合考虑了历史电价、供需比、碳市场价格、绿证价格以及煤炭价格等多重因素,以生成高精度的电价预测序列。风力发电商利用这些预测信息,结合自身的风电出力预测,制定动

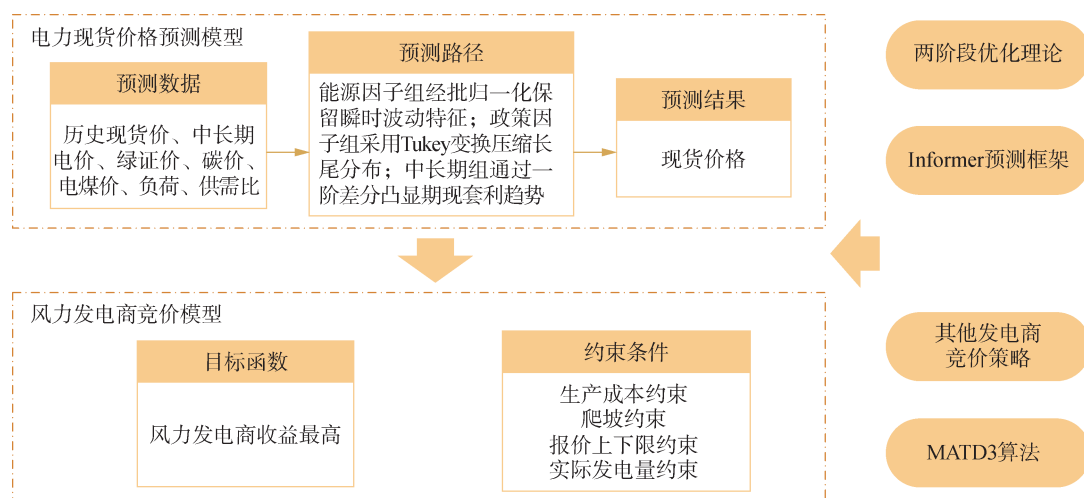


图5 “预测-决策”两阶段竞价流程

Fig. 5 “Prediction-decision” two-stage bidding process




图6 发电商竞价策略

Fig. 6 Power generators' bidding strategies

态报价策略。

1) 目标函数。

风力发电商的目标函数即为利润最大:

$$\max W^w = \sum_t (q_t^w \lambda_t^w - C_t^w) \quad (27)$$

式中: W^w 为风力发电商的收益; q_t^w 、 λ_t^w 、 C_t^w 分别为 t 时段风力发电商的中标电量、预测电价和发电成本。中标电量 q_t^w 作为决策变量, 取值范围通过蒙特卡罗方法(设定模拟次数为 10 000 次, 在每次模拟中从拟合的概率分布中随机抽取风电出力值, 生成多个可能的风电出力场景, 并记录各场景的出力值及其对应概率, 以此确定报量的合理取值范围, 作为报量的约束条件)确定。

2) 约束条件。

风力发电商报价要受到发电成本、报价上下限、爬坡约束和实际发电量的约束。

$$C_t^w = \alpha(q_t^w)^2 + \beta q_t^w + \chi \quad (28)$$

$$\lambda_{\min} \leq \lambda_t^w \leq \lambda_{\max} \quad (29)$$

$$\begin{cases} q_t^w - q_{t-1}^w \leq R_U^w \\ q_{t-1}^w - q_t^w \leq R_D^w \end{cases} \quad (30)$$

$$0 \leq q_t^w \leq \min(q_t^{wf}, P_w) \quad (31)$$

式中: 二次项系数 α 、一次项系数 β 、常数项 χ 为风电成本系数, 构成风电场的运营成本曲线; $\lambda_{\max}$ 、 $\lambda_{\min}$ 分别为最高和最低允许报价; R_U^w 、 R_D^w 分别为最大向上爬坡速率和最大向下爬坡速率; q_t^{wf} 为 t 时段基于风速预测的可发电量上限; P_w 为风电场装机容量。

2.3 其他生产主体竞价

1) 目标函数。

其他发电商的目标函数也为发电利润最大:

$$\max \pi_i = P_i Q_i - C_i(Q_i) \quad (32)$$

式中: π_i 为其他发电商的收益; P_i 、 Q_i 、 $C_i(Q_i)$ 分别为 t 时段其他发电商的中标电量、中标电价和发电成本。

2) 约束条件。

发电机要受到机组发电成本、启停成本、实际发电量约束和机组爬坡的约束。

$$C_i(Q_i) = aQ_i^2 + bQ_i + c + C_{\text{startup}} S_i \quad (33)$$

$$C_{\text{startup}} S_i \leq C_{\text{startup}}^{\max} \quad (34)$$

$$Q_{\min} \leq Q_i \leq Q_{\max} \quad (35)$$

$$|Q_i - Q_{i-1}| \leq \Delta Q \quad (36)$$

式中: a 、 b 、 c 为发电机的成本系数; C_{startup} 为启停成本系数; S_i 为启停状态, 取值为 0 或 1; $C_{\text{startup}}^{\max}$ 为最大启停成本; $Q_{\min}$ 、 $Q_{\max}$ 分别为发电商的最小、最大发电能力; ΔQ 为最大爬坡速率。

3) 各类发电商行为说明。

(1) 火力发电商成本函数中, 成本系数 a 、 b 、 c 为

燃料成本系数, 需额外考虑启停成本约束。

(2) 水力发电商成本函数中, 成本系数 a 、 b 、 c 为水轮机效率系数, 需满足水量极限约束:

$$\sum_{t=1}^T Q_t \leq W_{\max} \quad (37)$$

式中: $W_{\max}$ 为总可用水量上限。

(3) 光伏发电商。成本系数 a 、 b 、 c 为维护成本系数, 光伏发电量受光照效率 η_i 影响, 需满足:

$$Q_t \leq \eta_i A I_t \quad (38)$$

式中: A 为光伏板面积; I_t 为 t 时段光照强度。

2.4 市场出清模型

电力市场日前出清模型以购电成本最小为目标进行日前市场出清, 时间均采用 15 min, 独立系统运营商(independent system operator, ISO)基于发电商报价和申报负荷, 采用安全约束机组组合(security-constrained unit commitment, SCUC)和安全约束经济调度(security-constrained economic dispatch, SCED)模型进行市场出清, 得到机组启停计划、机组出力情况和节点电价。

目标函数为最小化总购电成本:

$$\min \sum_{t \in T} \left[\underbrace{\sum_{i \in I^h} (C_i^h p_{i,t}^h + C_{\text{SU}}^i u_{i,t}^h + C_{\text{SD}}^i d_{i,t}^h)}_{\text{火电成本}} + \underbrace{\sum_{i \in I^w} C_i^w p_{i,t}^w}_{\text{水电成本}} + \underbrace{\sum_{i \in I^p} C_i^p p_{i,t}^p}_{\text{风电成本}} + \underbrace{\sum_{i \in I^v} C_i^v p_{i,t}^v}_{\text{光伏成本}} \right] \quad (39)$$

式中: I^h 、 I^w 、 I^p 、 I^v 分别为火电机组、水电机组、风电机组、光伏组件的集合; C_i^h 为火电机组的发电成本; C_i^w 为水电机组的发电成本; C_i^p 、 C_i^v 分别为风、光伏发电成本, 通常为 0; $p_{i,t}^h$ 、 $p_{i,t}^w$ 、 $p_{i,t}^p$ 、 $p_{i,t}^v$ 分别为火电、水电、风电、光伏在 t 时段的预测出力; C_{SU}^i 、 C_{SD}^i 为火电机组的启停成本; $u_{i,t}^h$ 、 $d_{i,t}^h$ 为火电机组在 t 时段的启动/停机标志(二元变量)。

市场出清模型的约束条件为:

1) 网络潮流约束。

网络潮流约束意义在于保障电力系统的物理安全性和运行稳定性, 同时协调市场机制与电网实际运行需求。要求通过限制线路和设备的潮流不超过其容量。

$$f_{l,t} = \sum_{b \in B} F_{l,b} \left(\sum_{i \in I_b} p_{i,t}^x - D_{b,t} \right), \quad \forall l \in L, t \in T \quad (40)$$

$$-F_l^{\max} \leq f_{l,t} \leq F_l^{\max}, \quad \forall l \in L, t \in T \quad (41)$$

式中: $f_{l,t}$ 为线路 l 在 t 时段的潮流; $F_{l,b}$ 为线路 l 对节点 b 注入功率的灵敏度系数; $D_{b,t}$ 为节点 b 在 t 时段的负荷需求; $F_l^{\max}$ 为最大潮流; B 为节点集合; I_b 为连接在节点 b 上的所有发电机组的集合; T 为时段集合; L 为线路集合。

2) 系统功率平衡约束。

系统功率平衡约束可以确保电力系统中发电功率与负荷功率(包括网损)的实时动态平衡,从而保障系统的安全、稳定和经济运行。

$$\sum_{i \in I_b} p_{i,t}^x = D_{b,t}, \quad \forall b \in B, t \in T \quad (42)$$

3) 机组技术约束。

火电机组技术约束包括机组出力约束、爬坡约束、最小启停时间约束。

$$u_{i,t}^{\text{th}} P_i^{\min} \leq p_{i,t}^{\text{th}} \leq u_{i,t}^{\text{th}} P_i^{\max}, \quad \forall t \in T \quad (43)$$

$$p_{i,t}^{\text{th}} - p_{i,t-1}^{\text{th}} \leq R_{\text{U}}^i, \quad \forall t \geq 2 \quad (44)$$

$$p_{i,t-1}^{\text{th}} - p_{i,t}^{\text{th}} \leq R_{\text{D}}^i, \quad \forall t \geq 2 \quad (45)$$

$$u_{i,t}^{\text{th}} + d_{i,t}^{\text{th}} \leq 1, \quad \forall t \in T \quad (46)$$

$$\sum_{\tau=t}^{t+D_T^i-1} (1 - u_{i,\tau}^{\text{th}}) \geq D_T^i d_{i,t}^{\text{th}} \quad (47)$$

式中: R_{U}^i 、 R_{D}^i 分别为火电机组的向上、向下爬坡速率; D_T^i 为火电机组的最小启停时间。

水电机组出力需在技术允许范围内,通常无启停成本,但受水头压力和流量限制。

$$P_i^{\text{hy}, \min} \leq p_{i,t}^{\text{hy}} \leq P_i^{\text{hy}, \max} \quad (48)$$

式中: $P_i^{\text{hy}, \max}$ 、 $P_i^{\text{hy}, \min}$ 分别为水电机组出力上、下限。

风光出力由自然条件决定,实际出力不能超过预测最大可用功率。

$$\begin{cases} 0 \leq p_{i,t}^{\text{pv}} \leq P_{i,t}^{\text{pv}, \max} \\ 0 \leq p_{i,t}^{\text{wd}} \leq P_{i,t}^{\text{wd}, \max} \end{cases} \quad (49)$$

式中: $P_{i,t}^{\text{wd}, \max}$ 、 $P_{i,t}^{\text{pv}, \max}$ 分别为风、光出力上限。

出清结果为:

$$\lambda_{b,t} = \frac{\partial \mathcal{L}}{\partial D_{b,t}} \quad (50)$$

式中: $\lambda_{b,t}$ 为节点 b 在 t 时段电价; $\mathcal{L}$ 为拉格朗日函数, 对应功率平衡约束的对偶变量。

3 MATD3算法求解

3.1 MATD3算法结构

MATD3是多智能体强化学习领域针对连续动作空间的高效算法,是一种基于马尔科夫决策过程的交互式学习方法。MATD3结合了双 Q 学习(double Q -learning)、延迟策略更新(delayed policy updates)和策略平滑(policy smoothing)等关键技术,适用于电力市场中多发电商协同竞价的复杂决策场景。本文中应用的核心理论为:

1) 多智能体集中训练与分散执行(centralized training with decentralized execution, CTDE)。

MATD3采用集中式训练、分散式执行的架构,每个发电商(风力、水力、火力、光伏)作为独立智能体,

其策略网络(Actor)仅依赖局部观测(如预测电价、机组成本),而Critic网络在训练阶段可访问全局状态(如全网负荷、竞价曲线),实现协作学习。这种设计解决了多智能体环境中的非平稳性问题,即单个智能体的策略更新会受其他智能体行为影响。

2) 双Critic网络与延迟更新机制。

为缓解 Q 值高估偏差, MATD3使用2个独立的Critic网络(Q_1 , Q_2)对同一状态-动作对进行评估,取最小值作为目标 Q 值,计算式为:

$$y = r + \gamma \min_{j=1,2} Q_j[s', \pi'(s') + \varepsilon] \quad (51)$$

式中: $\varepsilon \sim \text{clip}(N(0, \sigma), -c, c)$ 为策略平滑噪声,限制动作扰动范围以增强稳定性。Critic网络每更新2次后, Actor网络才更新1次,避免策略过早收敛到次优解。

电力市场适配的奖励函数需平衡经济性、安全性和环保性。发电商以成本覆盖和利润最大化为目标,奖励函数为:

$$r_{\text{hydro/coal}} = w_1(p_{\text{bid}} q_{\text{bid}} - C_m) - w_2 P_v \quad (52)$$

式中: $r_{\text{hydro/coal}}$ 为水力/火力发电商奖励; w_1 和 w_2 为收益权重系数; p_{bid} 为中标电价; q_{bid} 为中标电量; C_m 为边际成本; P_v 为违反机组约束的惩罚项。

3.2 模型求解

采用MATD3算法求解本文模型的过程为:在现货电价预测与多主体竞价模型中,风力、水力、火力、光伏发电商分别作为MATD3算法中的智能体,市场环境(电价预测结果、其他主体报价等)作为环境输入,各主体的报价报量决策作为智能体动作,市场出清结果(中标电量与价格)作为环境反馈,各主体的净利润作为智能体奖励。本文所提模型与MATD3求解流程如图7所示。




图7 模型求解流程

Fig. 7 Model solution process

表 4 预测模型设置

Table 4 Settings of the prediction model

项目	详情	具体设置
模型	Informer 模型	
输入序列长度	考虑电价 时序相关性	96(对应过去 24 h, 每 15 min 一个数据点)
输出序列长度	匹配预测需求	96(预测未来 24 h 电价)
网络结构	构建有效的时序 特征提取结构	Encoder 和 Decoder 均采用 3 层堆叠的 ProbSparse 自注意力模块, 每层嵌入维度为 512, 注意力头数为 8
训练参数	优化模型 训练过程	使用 Adam 优化器, 学习率 0.000 1, 批量大小为 32, 训练轮数为 100

表 5 MATD3 算法参数

Table 5 MATD3 algorithm parameters

类别	参数	具体设置
网络结构	演员网络	输入层 6 维(3 维预测特征+3 维实时特征), 2 个隐藏层神经元个数分别为 256 和 128, 输出层 1 维连续型报价系数
	双评论家网络	输入层 6 维, 每个网络 2 个隐藏层神经元个数分别为 256 和 128, 输出层 1 维 Q 值
	经验回放池容量	100 000
超参数	折扣因子 γ	0.99
	软更新系数 τ	0.005
	策略延迟更新步数	每 2 个训练步更新一次演员网络和目标网络
	目标动作噪声	添加高斯噪声 $N(0, 0.1)$
	最大迭代次数	200 000

表 6 对比场景设置

Table 6 Settings of the comparison scenario

对比场景	方案	预测信息使用情况	算法
1	传统无预测方案	不使用	MATD3 算法
2	MADDPG	使用	MADDPG 算法
3	MATD3 标准方案	使用	MATD3 算法

4.2 结果分析

4.2.1 预测精度分析

本文提出的 Informer 预测模型展现了显著优于传统方法的电价预测能力。实验表明,该框架在日前电价预测任务中,相较于基准模型,DAC(计算式见附录 A)提升了 18.6%,RMSE 降低了 12.3%,充分验证了其在短期波动预测中的有效性。Market-Informer 模型和 ARIMA 模型以及 Transformer-LSTM 的电价预测情况如图 9 所示。各模型预测价格评价

指标对比如表 7 所示。




图 9 2022 年 7 月各模型预测价格对比

Fig. 9 Comparison of price forecasts from various models for July 2022

表 7 各模型预测价格评价指标对比

Table 7 Comparison of evaluation metrics for price forecasts from various models

模型	DAC/%	RMSE/(欧元/MWh)	MAPE/%
ARIMA	74.7	10.12	9.8
Transformer-LSTM	86.1	8.74	7.5
Market-Informer	94.3	7.15	5.2

基于 2022 年全年的日前市场数据(采样间隔 30 min, 样本量 131 379 条),Transformer-LSTM 模型对 96 个时点电价序列的 DAC 指标达到 89.3%,较传统 ARIMA 模型的 74.7% 提升了 14.6 个百分点。这一改进得益于模型对多重市场因素的融合建模能力,通过引入碳市场价格、绿证价格及煤炭价格等低碳变量,模型有效捕捉了电力市场与碳交易市场的动

态耦合关系。实测数据显示,在风电出力超过系统负荷 70% 的时段,传统 ARIMA 模型的电价峰值预测误差率达 12.4%,而 Market-Informer 模型通过 ProbSparse 自注意力机制对历史电价、供需比及绿证价格的协同分析,将误差率控制在 6.2% 以内。2022 年 7 月 15 日风电出力峰值时段,实际电价为 62.3 欧元/MWh,ARIMA 模型预测值为 51.5 欧元/MWh,误差为 13.1%,而 Market-Informer 模型预测值为 60.1 欧元/MWh,误差为 2.7%,显著提升了发电商在市场环境下的报价决策精度。

为进一步验证 Market-Informer 模型的先进性,本文同时将其与 Transformer-LSTM 混合模型进行对比。该基线模型采用与本文相同的输入维度和训练集,其结构包含一个 12 层的 Transformer 编码器以提取序列的全局依赖关系,后接一个两层 LSTM 网络作为解码器以生成预测输出。

如表 7 所示,Transformer-LSTM 混合模型的预测性能(DAC 为 86.1%,RMSE 为 8.74 欧元/MWh)虽显著优于传统 ARIMA 模型,但仍逊于本文所提的 Market-Informer 模型(DAC 为 94.3%,RMSE 为 7.15 欧元/MWh)。这表明,尽管 Transformer 架构在捕捉长期依赖方面具有强大能力,但本文针对电力市场特性所设计的特征分流嵌入、多路径编码以及市场因素融合机制,能够更精准地刻画碳价、绿证价格等政策因素与能源因素之间的非线性耦合关系,从而实现了更高的预测精度。特别是在 2022 年 7 月 15 日的峰值预测中,Transformer-LSTM 模型的预测值为 55.2 欧元/MWh,误差为 11.4%,其误差介于 ARIMA 与 Market-Informer 之间,再次验证了 Market-Informer 模型在极端波动场景下的优越性。

Market-Informer 模型预测误差标准值如图 10 所示。由图 10 可知,指标数值有一定波动,但整体标准

差可控,意味着数据离散程度稳定,误差不大。0~8 时点,数值平稳,标准差小;8 时点后,波动频繁,幅度在 5.5~6.5 欧元/MWh,可见标准差未异常扩大,表明模型能较好应对市场等动态变化,预测结果较为可信。




图 10 日内 96 时点预测误差标准值

Fig. 10 Prediction error standard value of intraday 96-point

图 11 展示了 00:00—24:00 实际电价与预估电价的变化,划分了上下午峰段与谷值时段。整体来看,一天内大部分时间两者趋势相似,虽存在偏差,但误差分布区间处于合理范围,说明预测结果具备可信度。

进一步分析表明,模型对低频数据(日/月级)的长期趋势预测同样具有优势。这种全周期预测能力的提升,为发电商制定中长期交易策略提供了可靠的数据支撑,验证了模型在复杂电力市场环境下的普适性与鲁棒性。

4.2.2 预测指标贡献度分析

为定量解析各输入变量对预测模型的贡献机制及其内在关联,本节采用排列特征重要性方法与相关性分析,对构建的 Market-Informer 预测模型进行可解释性评估,电价预测特征重要性如图 12 所示。

由图 12 可得,历史现货价格贡献度最高




图 11 日内实际电价与预测电价对比

Fig. 11 Comparison of actual electricity price and predicted electricity price




图 12 电价预测的特征重要性

Fig. 12 Feature importance of electricity price forecasting

(32.5%), 凸显其作为时间序列基础变量的核心作用,有效捕捉了电价的自相关特性与波动聚集效应。电力负荷(19.8%)与出力供需比(18.1%)作为反映系统实时平衡状态的关键物理量,对电价形成具有显著解释力。电煤价格(11.5%)作为火电边际成本的主要构成,直接传导至现货报价行为。中长期电价(9.7%)则通过远期价格信号对日前市场产生锚定效应。值得注意的是,尽管碳市场价格(5.2%)与绿证价格(3.2%)的贡献度相对较低,但其作为新型电力系统背景下重要的政策变量,为模型引入了关键的低碳政策信息维度,尤其在碳市场活跃波动阶段显著增强了模型的适应性。

输入特征与现货电价的相关性热力图如图 13 所示,其揭示了变量间的线性关联结构。现货价格与电力负荷呈现强正相关(0.72),符合需求拉动电价的基本规律;与出力供需比呈现强负相关(-0.68),




图 13 输入特征与现货电价的相关性热力图

Fig. 13 Correlation heatmap between input features and electricity prices

体现了供应充裕度对电价的压制作用。电煤价格与现货电价的中等相关性(0.51)验证了成本推动型通胀的传导机制。政策类变量中,碳市场价格(0.19)与绿证价格(0.14)与现货电价仅呈现弱相关,反映其现阶段仍以制度性影响为主,市场传导效应尚未充分显现。更重要的是,所有自变量间的两两相关系数均低于0.4的阈值,表明特征集不存在严重的多重共线性问题,满足机器学习模型对输入变量独立性的要求,从统计上验证了多因素融合预测框架的合理性。

4.2.3 输入变量的因果性检验与分析

为检验碳市场价格、绿证价格及电煤价格等变量与日前电价间的统计因果关系,避免模型过拟合,本研究首先对日度频率的序列进行了格兰杰因果检验(Granger causality test)。

格兰杰因果检验用于判断一个变量的历史信息是否有助于预测另一个变量的未来值。对各变量与现货电价进行检验(选取滞后 2 阶,原假设 X 不是电价的格兰杰原因),所得结果见表 8。

表 8 格兰杰因果检验结果
Table 8 Results of Granger causality test

变量	F 统计量	P 值	结论 (5% 显著性水平)
历史现货价格	285.731	1.32×10^{-75}	拒绝原假设
电力负荷	42.109	9.64×10^{-17}	拒绝原假设
出力供需比	25.237	5.21×10^{-11}	拒绝原假设
电煤价格	8.146	0.000 3	拒绝原假设
中长期电价	15.884	3.45×10^{-7}	拒绝原假设
碳市场价格	5.237	0.005 7	拒绝原假设
绿证价格	2.981	0.040 3	拒绝原假设

如表 8 所示,历史现货价格、电力负荷、出力供需比、电煤价格、中长期电价和碳市场价格的 P 值远小于 0.05 的显著性水平,均在统计上显著地拒绝原假设。这意味着这些变量的历史值包含了预测未来电价独特且显著的信息,完全有理由作为核心输入变量纳入预测模型。该结果与第 1 章中阐述的电力市场多时间尺度价格形成机制完全吻合。

历史现货价格体现了电价波动的聚集性(volatility clustering)和强劲的自相关特性,是时间序列预测的基础;电力负荷与出力供需比直接反映了电力系统的实时平衡状态,是驱动现货电价最直接的物理因素,结论高度显著;电煤价格作为火电边际成本的核心构成,其成本传导效应得到了统计上的确认;中长期电价作为重要的价格信号,对日前市场具有显著的锚定和引导作用;碳市场价格虽显著性

稍弱于其他物理因素,但结果依然证实了碳成本通过影响发电报价而传导至电价的机制;绿证价格的 P 值为0.040 3,仅略低于0.05的阈值。这表明,在严格的统计定义下,其历史值对电价的线性预测能力稍弱。这可能是由于绿证市场与电力市场的耦合机制更为复杂和间接,其影响可能通过更长的滞后周期或非线性渠道体现。然而,鉴于其重要的政策意义和在能源转型中的关键作用,以及其在特征重要性分析中贡献了边际信息,仍将其保留在模型中,以避免遗漏变量偏差,并确保模型能够捕捉完整的市场政策环境。

4.2.4 市场出清结果分析

通过对比3种不同场景下的市场出清效果,揭示了场景3(Informer预测电价+成本报价,MATD3算法)在收益最大化与风险控制方面的最优性能,结果如图14和表9所示。场景3的发电联盟总收益达到598.72万元,较场景1和场景2分别提升23.1%和9.8%,成本则分别下降16.9%和6.3%,且风力发电商收益波动率(定义为日收益的样本标准差)降低至5.3%,显著优于其他场景。




图 14 不同场景下各发电商收益与成本
Fig. 14 Revenues and costs of each power generator in different scenarios

竞价策略对比分析来看,场景1所有发电商采用基于成本报价策略,虽保证了基础收益,但未能利用电价预测信息捕捉市场高价时段机会,导致风电收益潜力未充分释放,且由于缺乏电价预测信息,发电商难以根据市场情况灵活调整报价和成本控制策

略,导致成本效益比不理想;场景2总收益提升至629.04万欧元,风电收益有所增加。整体成本为439.29万欧元,虽然尝试通过优化报价策略来降低成本,但由于MADDPG算法的集中式训练框架存在局限性,未能实现最优成本管理。火电/水电商为对冲风电低价竞争而压低报价,导致收益被压制的同时,也影响了成本控制的效率。火电/水电商为对冲风电低价竞争,被迫压低报价,导致收益被压制(火电收益较场景3下降9.2%)。而MATD3通过分布式批评家设计,允许各智能体独立优化策略,更适应非合作博弈环境。场景3的MATD3算法通过多智能体协同优化,在风电收益提升至18.63万欧元的同时,火电和水电收益分别增长8.7%和6.2%,实现总收益725.34万欧元。

综合以上分析,本文所提的MATD3方案(场景3)在利用预测电价数据优化策略方面展现出显著优势。通过引入预测信息并结合MATD3算法进行策略优化,该方案提升了模型的收敛速度和最终性能,增强了模型在面对电价波动时的适应性和鲁棒性。相比之下,场景1和场景2的方案在性能上均存在一定局限性。因此,本文所提MATD3方案为强化学习在电价预测与策略优化领域的应用提供了新的思路和方法。

4.2.5 算法性能有效性分析

为验证MATD3算法在多智能体电力市场环境中的优越性,本文将其与MADDPG算法进行系统性对比,从收敛特性、策略稳定性及市场收益3个维度展开分析。不同算法下市场成员总收益随迭代次数变化曲线如图15所示。

在算法性能的全面对比分析中,MATD3算法相较于MADDPG算法展现出显著的优越性,尤其在收敛效率、策略稳定性以及市场收益等关键方面表现突出。

在收敛效率上,MATD3算法展现出更快的收敛速度,仅需约7000次迭代即可进入稳定状态,较MADDPG算法有提速。这一优势得益于其分布式双批评家架构,独立策略评估机制有效避免了集中式 Q 值过估计问题,同时风电预测偏差奖励的优先级采样策略加速了关键经验的学习。相比之下,

表 9 不同场景收益及成本
Table 9 Revenue and costs in different scenarios

场景	火电收益/ 万欧元	水电收益/ 万欧元	风电收益/ 万欧元	光伏收益/ 万欧元	总收益/ 万欧元	总成本/ 万欧元	风电波 动率/%
1	340.25	166.32	10.25	85.40	602.22	483.21	13.5
2	308.71	227.46	14.72	78.15	629.04	439.29	18.2
3	343.52	270.39	18.63	92.80	725.34	413.31	11.2




图 15 总收益迭代次数变化曲线

Fig. 15 Curve of total revenue iteration times variation

MADDPG 算法因需协调所有智能体的全局策略,在早期迭代中出现明显的收益震荡,0~5000 次迭代波动幅度达 $\pm 35\%$ 。

在策略稳定性方面,MATD3 算法同样表现更优,后期收益标准差仅为 18.7 万欧元,最大策略熵下降速率为 0.12/1000 次,将火电与风电的策略冲突转化为协同优化,风电收益波动率控制在 4.8%,火电最低收益保障提升至 343.52 万欧元。而 MADDPG 算法的后期收益标准差为 26.3 万欧元,最大策略熵下降速率为 0.21/1000 次,风电收益波动率达 7.9%,火电最低收益保障仅 308.71 万欧元。

在市场收益分析中,MATD3 驱动下 3 类发电主体在 2500 次迭代后形成严格纳什均衡,总收益峰值达 612.54 万欧元,较 MADDPG 的 570.89 万欧元提升了 7.3%,且收益基尼系数从 0.38 降至 0.22,体现了更公平的收益分配。综上所述,MATD3 算法在多个维度均展现出优于 MADDPG 算法的性能。

4.3 敏感性分析

4.3.1 Informer 模型预测电价误差标准值

在电力市场动态竞价策略中,电价预测的准确性对发电商的报价决策及最终收益具有显著影响。

为评估 Informer 模型预测电价误差对风力发电商竞价策略的影响,本节通过添加随机噪声的方式改变预测误差标准差,分析不同误差水平下风力发电商的收益变化和市场总收益变化情况。

在 Informer 模型预测的电价序列中,通过添加不同标准差的高斯随机噪声,模拟预测误差的变化。噪声标准差设置为原始预测误差标准差的 10%、20%、30% 和 40%,分别对应低、中、高、极高 4 个误差水平。模型预测电价误差敏感性分析结果见表 10。

表 10 模型预测电价误差敏感性分析结果

Table 10 Sensitivity analysis results of electricity price forecasting error

电价误差标准差变动比例/%	风力发电商平均收益/(万欧元/MWh)	风力发电商平均收益变化率/%	发电商总平均收益/(万欧元/MWh)	发电商总平均收益变化率/%
0(基准)	18.63	0	612.54	0
10	19.39	+4.1	580.08	-5.3
20	17.43	-4.8	568.43	-7.2
30	15.76	-16.1	549.45	-10.3
40	10.92	-41.3	499.83	-18.4

随着预测误差标准差的增加,风力发电商的平均收益呈现下降趋势。在低误差水平下,预测电价与实际电价接近,风力发电商能够制定更接近最优的报价策略,收益较高。然而,在高误差水平下,预测电价与实际电价偏差较大,导致报价策略偏离最优解,报价策略与市场实际电价偏离较大,降低了中标概率,收益显著降低。尽管收益随误差增加而下降,但采用 MATD3 算法求解的双层竞价策略模型表现出一定的鲁棒性。

4.3.2 风力发电商报价区间

在电力市场竞价中,发电商的报价区间(即最低和最高允许报价)直接影响其市场竞争力、中标概率和最终收益。合理的报价区间设定能够平衡收益与风险,避免因报价过高而流标或因报价过低而损失利润。通过调整报价区间的上下限,分析不同报价范围对市场行为的影响。风力发电商报价区间敏感性分析结果见表 11。

报价区间收窄时,风电收益分别下降 5.4% 和 11.2%,主要由于其中标电量减少,但收益波动率同时降低,说明窄区间策略更稳定但牺牲了部分收益。报价区间放宽时,风电收益分别提升 4.8% 和 9.6%,但收益波动率也同时增加,说明过宽的报价区间可能导致极端高价或低价中标,增加收益的不确定性。

表 11 风力发电商报价区间敏感性分析结果
Table 11 Sensitivity analysis results of rbidding range for wind power producers

报价上下限调整比例/%	风力发电商收益变动比例/%	收益波动率变动比例/%
-20	-11.2	-12.5
-10	-5.4	-7.2
0	0	0
10	4.8	6.1
20	9.6	11.4

4.4 相关建议

1)推广多因素融合电价预测技术,并建立误差监控与应对机制。在电价预测过程中,需考虑多因素融合来进行现货价格预测,不仅要考量现货市场本身的历史数据,还要关注与价格传导相关的重要因素,在电力市场里,中长期的因素需纳入考量范围,成本相关因素也不容忽视,比如煤炭价格与市场的关联,碳市场以及其他市场价格对电价的影响也应予以考虑。引入基于 Informer 模型的多市场因素融合电价预测技术,可显著提升预测精度与竞价收益。敏感性分析显示,预测误差会直接影响收益稳定性。当误差标准差增幅超过 20% 这一临界阈值时,收益下降速率会显著加快。建议发电商不仅要采用高精度预测模型,更要建立误差监控体系,一旦预测误差接近或超过阈值,应立即启用风险对冲策略,例如通过电力金融衍生品(如差价合约)锁定部分收益,或者将竞价策略调整至更保守的模式,以此保障收益底线。

2)实施基于风险偏好的动态报价区间管理策略。报价区间宽度的合理设置是平衡收益与风险的关键。从市场整体情况来看,报价区间与市场活力紧密相关,提高报价区间有助于保持市场活力。在市场整体风险偏好较高、预测置信度高且市场供需紧张的时期,可适度提高报价区间(如上限提升 10%~20%),这样既能捕捉高价机会、最大化收益,又能保持市场的活力与竞争力,使报价能够更好地与市场实际情况相匹配,确保市场的高效运行。

3)构建基于风险偏好的风力发电商报价区间优化模型。报价区间宽度直接影响风力发电商收益与风险水平(区间放宽 20% 时收益提升 9.6%,但波动率增加 11.4%)。建议结合发电商风险偏好,构建多目标优化模型,平衡收益最大化与风险可控性。采用条件风险价值(conditional value at risk,CVaR)理论量化风险,或通过强化学习算法动态调整报价上下限,以适应不同市场环境下的竞价需求。

4)完善电力市场机制,促进可再生能源消纳与低碳转型。当前市场机制下,火电与风电的竞价博弈导致可再生能源收益被压制(场景 2 中火电收益较场景 3 下降 9.2%)。建议推动市场机制改革,引入容量市场、绿色电力证书交易激励或碳税政策,提升可再生能源的经济性。同时,优化市场出清模型,考虑低碳属性权重,引导发电商从“成本竞争”转向“低碳价值竞争”,加速能源结构绿色转型。

5 结 论

1)考虑多市场因素的 Informer-MATD3 协同优化模型,有效解决了传统方法中预测与决策环节的信息衰减问题。实验表明,该模型使风力发电商在电价波动率 45% 的场景下,中标率提升 18.7%,收益波动降低 22.3%,显著提升了风力发电商在复杂市场环境下的竞价能力,为使用深度强化学习算法求解电力市场竞价问题提供了新思路。

2)通过将碳市场价格、绿证价格、煤炭价格等关键市场因素纳入预测体系,构建的多市场因素融合 Informer 模型显著提高了电价预测精度。在欧洲电力市场实测中,模型对日前电价的预测方向准确性达 94.3%,较传统模型提升 18.6 个百分点,尤其在风电大发期(出力>70%)电价峰值预测中,误差率控制在 3.2% 以内,为发电商制定科学报价策略提供了可靠依据,对促进可再生能源消纳和电力市场低碳转型具有重要意义。

3)设计的基于 MATD3 的多主体竞价策略有效协调了风力-水力-火力发电商的竞价行为,实现了系统总成本降低 11.4%,风力发电商收益提升 9.8% 的双重目标,验证了多主体协同优化在提升电力市场运行效率和促进能源结构优化方面的有效性。

综上所述,本文针对新型电力系统下风力发电高比例渗透引发的电价预测与竞价难题,创新性地提出“预测-决策”两阶段动态耦合框架,显著提升了电价预测的精准度与竞价策略的适应性,有效协调了不同发电商的竞价行为,促进了电力市场运行效率与能源结构优化。本文基于成本最小化出清模型与 IEEE 14 节点系统,揭示了多能源竞价策略的内在机理,但未引入节点边际电价与阻塞管理细节,其结论更适用于节点电价差异较小的市场环境。未来研究可在 MATD3 框架基础上,进一步融入节点边际机制及备用服务等辅助市场规则,扩展智能体的状态与动作空间至多品种联合报价,从而实现对复杂市场环境下协同竞价策略的深度优化。未来研究还可进一步探索极端市场情景下的模型鲁棒性,完善市

场机制以更好适配可再生能源消纳需求,还可探索闭环反馈式的动态耦合机制,研究如何将决策模块的收益表现作为反馈信号,用于动态调整预测模型的损失函数或参数,形成自我演化的智能决策系统,推动电力市场向更加智能化、低碳化方向发展。

利益冲突声明(Conflict of Interests):

所有作者声明不存在利益冲突。

作者贡献声明(Authors' Contributions):

张硕提出考虑多市场因素的现货价格Informer预测模型的概念和基本框架,提出研究方向,设计论文框架;王雨欣设计研究思路,设计研究方案,研究方案可行性调查分析,实施研究过程,进行实验分析;李英姿确定研究对象范围,收集数据,采集、清洗与分析数据,进行文献调研与整理;贺运政参与技术开发、绘制图谱,参与论文修订、论文最终版本修订。所有作者均阅读并同意了论文终稿内容。

6 参考文献

- [1] 朱博,束洪春,吴水军,等.风电调频补偿水锤效应的频率特性分析[J].电力系统保护与控制,2023,51(2):65-76.
ZHU Bo, SHU Hongchun, WU Shuijun, et al. Analysis of frequency characteristics of water hammer effect compensated by wind power frequency modulation[J]. Power System Protection and Control, 2023, 51(2): 65-76.
- [2] 路朋,陈思捷,张宁,等.计及区间预测信息的含风电电力系统有功多时间尺度协调调度优化方法[J].中国电机工程学报,2024,44(16):6263-6278.
LU Peng, CHEN Sijie, ZHANG Ning, et al. Multi-time scale coordinated dispatch optimization method for power system with large-scale wind power grid-integrated based on interval prediction[J]. Proceedings of the CSEE, 2024, 44(16): 6263-6278.
- [3] 刘家豪,王程,毕天姝.面向新能源电力系统频率时空动态的节点等效惯量指标及其应用[J].中国电机工程学报,2023,43(20):7773-7788.
LIU Jiahao, WANG Cheng, BI Tianshu. Node equivalent inertia index for temporal-spatial frequency dynamics of renewable energy power system and its applications[J]. Proceedings of the CSEE, 2023, 43(20): 7773-7788.
- [4] 于宗超,刘绚,严康,等.考虑DLR和风电预测不确定性的机会约束机组组合模型[J].高电压技术,2021,47(4):1204-1214.
YU Zongchao, LIU Xuan, YAN Kang, et al. Combination model of chance-constrained security constraint unit with considering the forecast uncertainties of DLR and wind power[J]. High Voltage Engineering, 2021, 47(4): 1204-1214.
- [5] MARCJASZ G, NARAJEWSKI M, WERON R, et al. Distributional neural networks for electricity price forecasting[J]. Energy Economics, 2023, 125: 106843.
- [6] RUBASINGHE O, ZHANG X N, CHAU T K, et al. A novel sequence to sequence data modelling based CNN-LSTM algorithm for three years ahead monthly peak load forecasting[J]. IEEE Transactions on Power Systems, 2024, 39(1): 1932-1947.
- [7] 魏勤,陈仕军,黄炜斌,等.利用随机森林回归的现货市场出清价格预测方法[J].中国电机工程学报,2021,41(4):1360-1367.
WEI Qin, CHEN Shijun, HUANG Weibin, et al. Forecasting method of clearing price in spot market by random forest regression[J]. Proceedings of the CSEE, 2021, 41(4): 1360-1367.
- [8] SAI W, PAN Z H, LIU S Y, et al. Event-driven forecasting of wholesale electricity price and frequency regulation price using machine learning algorithms[J]. Applied Energy, 2023, 352: 121989.
- [9] 易小虎,刘青,曹乐,等.含大规模风电电网的关键线路识别及连锁故障预测[J].电网与清洁能源,2022,38(10):79-86.
YI Xiaohu, LIU Qing, CAO Le, et al. Key line identification and cascading fault prediction for the grid containing large-scale wind power[J]. Power System and Clean Energy, 2022, 38(10): 79-86.
- [10] 张玉敏,孙猛,吉兴全,等.基于二次分解和ATT-CNN-LSTM-MLR组合模型的短期电价预测方法[J].智慧电力,2024,52(12):65-72.
ZHANG Yumin, SUN Meng, JI Xingquan, et al. Short-term electricity price forecasting method based on quadratic decomposition and ATT-CNN-LSTM-MLR combined model[J]. Smart Power, 2024, 52(12): 65-72.
- [11] 加鹤萍,郭宇辰,马乾鑫,等.基于机器学习方法的现货电价预测研究综述[J].电力建设,2025,46(2):160-179.
JIA Heping, GUO Yuchen, MA Qianxin, et al. Review of spot electricity price prediction studies based on machine learning methods[J]. Electric Power Construction, 2025, 46(2): 160-179.
- [12] 赵雅雪,王旭,蒋传文,等.基于最大信息系数相关性分析和改进多层级门控LSTM的短期电价预测方法[J].中国电机工程学报,2021,41(1):135-146,404.
ZHAO Yaxue, WANG Xu, JIANG Chuanwen, et al. A novel short-term electricity price forecasting method based on correlation analysis with the maximal information coefficient and modified multi-hierarchy gated LSTM[J]. Proceedings of the CSEE, 2021, 41(1): 135-146, 404.
- [13] YANG H L, SCHELL K R. Real-time electricity price forecasting of wind farms with deep neural network transfer learning and hybrid datasets[J]. Applied Energy, 2021, 299: 117242.
- [14] YU W J, DAI Y M, REN T, et al. Short-time photovoltaic power forecasting based on Informer model integrating attention mechanism[J]. Applied Soft Computing, 2025, 178: 113345.
- [15] LI K, HUANG W, HU G Y, et al. Ultra-short term power load forecasting based on CEEMDAN-SE and LSTM neural network[J]. Energy and Buildings, 2023, 279: 112666.
- [16] NAJAFI A, HOMAEE O, GOLSHAN M, et al. Application of extreme learning machine- autoencoder to medium term electricity price forecasting[J]. IEEE Transactions on Industry Applications, 2023, 59(6): 7214-7223.
- [17] 方逸飞,刘东,陈静,等.考虑中长期市场因素的净现货竞价空间驱动的日前出清电价预测方法[J].中国电机工程学报,2026,46(2):506-519.

- FANG Yifei, LIU Dong, CHEN Jing, et al. Day-ahead electricity price forecasting driven by net spot market bidding capacity considering medium-and long-term market factors[J]. Proceedings of the CSEE, 2026, 46(2): 506-519.
- [18] 李志军, 徐博, 张家安, 等. 基于TD3可变长度时间窗口最优加权的短期负荷预测策略[J]. 电力建设, 2024, 45(6): 140-148.
- LI Zhijun, XU Bo, ZHANG Jia'an, et al. Short-term load optimal weighted forecasting strategy based on TD3 variable length time window[J]. Electric Power Construction, 2024, 45(6): 140-148.
- [19] ZHANG H J, ZHOU M R, CHEN Y, et al. Short-term power load forecasting for industrial buildings based on decomposition reconstruction and TCN-Informer-BiGRU [J]. Energy and Buildings, 2025, 347: 116317.
- [20] LI Y B, YANG Y N, ZHANG F, et al. A Stackelberg game-based approach to load aggregator bidding strategies in electricity spot markets[J]. Journal of Energy Storage, 2024, 95: 112509.
- [21] LIU C W, RAO X, ZHAO B, et al. Deep reinforcement learning-based optimal bidding strategy for real-time multi-participant electricity market with short-term load[J]. Electric Power Systems Research, 2024, 233: 110404.
- [22] 高元昊, 张继行, 赵胤呈, 等. 基于强化学习的虚拟电厂动态聚合及多时间尺度竞价策略[J]. 电力系统自动化, 2025, 49(23): 108-118.
- GAO Yuanhao, ZHANG Jixing, ZHAO Yincheng, et al. Reinforcement learning-based dynamic aggregation and multi-timescale bidding strategy for virtual power plants[J]. Automation of Electric Power Systems, 2025, 49(23): 108-118.
- [23] HUANG F, CHEN Y, ZHU Y, et al. Multi-agent bidding strategy for wind power producers considering uncertainty: an improved wolf-PHC approach[J]. Applied Energy, 2024, 345: 121304.
- [24] 李钟平, 向月. 深度强化学习驱动的风储系统参与能量-调频市场竞争策略[J]. 电力工程技术, 2025, 44(3): 30-42.
- LI Zhongping, XIANG Yue. Deep reinforcement learning-driven bidding strategy for wind-storage systems in energy and frequency regulation markets [J]. Electric Power Engineering Technology, 2025, 44(3): 30-42.
- [25] 陈哲, 韦美佳, 林达, 等. 基于场景法和深度强化学习的电氢耦合系统两阶段多时间尺度优化调度[J]. 浙江电力, 2025, 44(1): 54-67.
- CHEN Zhe, WEI Meijia, LIN Da, et al. Two-stage multi-timescale optimal scheduling for electricity-hydrogen coupling systems based on scenario approach and deep reinforcement learning[J]. Zhejiang Electric Power, 2025, 44(1): 54-67.
- [26] 陈景文, 单茜, 刘耀先, 等. 面向电力市场的用户侧电力电量预测综述[J]. 电网与清洁能源, 2024, 40(2): 10-20.
- CHEN Jingwen, SHAN Xi, LIU Yaoxian, et al. A review of user-side power and energy forecasting for electricity market[J]. Power System and Clean Energy, 2024, 40(2): 10-20.
- [27] HU F, ZHAO Y, YU Y W, et al. Strategic bidding with price-quantity pairs based on deep reinforcement learning considering competitors' behaviors[J]. Applied Energy, 2025, 391: 125874.
- [28] JIANG Y Z, DONG J, HUANG H X. Optimal bidding strategy for the price-maker virtual power plant in the day-ahead market based on multi-agent twin delayed deep deterministic policy gradient algorithm[J]. Energy, 2024, 306: 132388.
- [29] VIJAYA CHANDRAKALA K R M, KIRAN P. Multi-agent based modeling and learning approach for intelligent day-ahead bidding strategy in wholesale electricity market [J]. Expert Systems with Applications, 2023, 233: 121014.
- [30] JIA H P, GUO Y C, ZHANG X B, et al. Forecasting electricity prices in the spot market utilizing wavelet packet decomposition integrated with a hybrid deep neural network [J]. Global Energy Interconnection, 2025, 8(5): 874-890.
- [31] 蔡子龙, 李嘉棋, 沈赋, 等. 基于SDAE-EEMD降噪分解与改进Informer-BiLSTM模型的电力短期负荷预测方法[J]. 电网技术, 2025, 49(12): 5009-5018.
- CAI Zilong, LI Jiaqi, SHEN Fu, et al. A short-term power load forecasting method based on SDAE-EEMD denoising decomposition and an improved informer-BiLSTM model [J]. Power System Technology, 2025, 49(12): 5009-5018.
- [32] YANG Z K, QIN Z J. Demand response model by locational marginal electricity - carbon price considering wind power uncertainty and energy storage systems[J]. Energy Reports, 2023, 9: 742-752.
- [33] YE B, PU H J, SONG Y Z, et al. Design and pricing of an option product for China's green electricity-carbon medium and long-term markets [J]. Environmental Impact Assessment Review, 2025, 112: 107804.
- [34] 马超, 秦晓辉, 刘晓瑞, 等. 新型电力系统电碳协同研究综述: 量化方法、关键技术与应用展望[J]. 高电压技术, 2026, 52(1): 193-214.
- MA Chao, QIN Xiaohui, LIU Xiaorui, et al. Review of research on electricity carbon collaboration in new type power systems: quantitative methods, customs construction technologies and application prospects [J]. High Voltage Engineering, 2026, 52(1): 193-214.
- [35] LI L P, DONG S M, WANG L. Capacity degradation prediction of electric vehicle battery by integrating convolutional neural network with informer model [J]. Journal of Power Sources, 2025, 651: 237497.

收稿日期: 2025-08-26 修回日期: 2025-11-10



张颀

作者简介:

张颀(1985),男,博士,副教授,主要从事电力市场、电碳市场研究工作;

王雨欣(2002),女,硕士研究生,主要从事电力市场研究工作;

李英姿(1985),女,博士,副教授,主要从事复杂适应系统建模及仿真研究工作;

贺运政(1981),男,硕士,副教授,通信作者,主要从事电力市场研究工作,E-mail:heyun_007@sina.com。

(编辑 景贺峰)

附录 A

均方误差是衡量预测值与真实值之间差异的一种常用指标,MSE的值越小,说明预测值与真实值越接近,模型的预测效果越好,其计算式为:

$$\sigma_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (\text{A1})$$

式中: n 为样本数量; y_i 为第 i 个样本的真实值; $\hat{y}_i$ 为第 i 个样本的预测值。

平均绝对百分比误差是以百分比的形式衡量预测值相对于真实值的误差程度,MAPE越小,表明预测的相对误差越小,模型性能越好,其计算式为:

$$\sigma_{\text{MAPE}} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (\text{A2})$$

均方根误差是在均方误差的基础上进行开方运算得到的,也是衡量预测值和真实值之间的差异,但由于进行了开方操作,RMSE的单位与原始数据的单

位一致,这使得它在解释误差大小时更加直观。和MSE类似,RMSE的值越小,说明模型的预测精度越高,其计算式为:

$$\sigma_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (\text{A3})$$

DAC为二分类指标,通过比较预测值与真实值的变化方向的一致性来计算正确率,其计算式为:

$$\sigma_{\text{DAC}} = \frac{100\%}{N} \sum_{t=1}^N I_{\text{sign}(\Delta p_t^{\text{actual}}) = \text{sign}(\Delta p_t^{\text{predicted}})} \quad (\text{A4})$$

式中: N 为样本总数; $\Delta p_t^{\text{actual}}$ 为 t 时刻实际价格的方向性变化; $\Delta p_t^{\text{predicted}}$ 为 t 时刻预测价格的方向性变化(通常与最近一期真实值比较); I 为示性函数(若括号内条件为真则取1,否则为0); sign 为符号函数,取值为 $\{1, 0, -1\}$,分别代表上涨、持平、下跌。