

基于 NeuralProphet-LSTM 模型的碳价预测研究

蔡远航^{1,2}, 冯建新^{1*}, 王艳青², 李婉君², 丁元明¹, 胡越²

(1. 大连大学通信与网络重点实验室, 辽宁省 大连市 116622;

2. 中国科学院大连化学物理研究所, 辽宁省 大连市 116023)

Research on Carbon Price Prediction Based on NeuralProphet-LSTM Model

CAI Yuanhang^{1,2}, FENG Jianxin^{1*}, WANG Yanqing², LI Wanjun², DING Yuanming¹, HU Yue²

(1. Key Laboratory of Communication and Network, Dalian University, Dalian 116622, Liaoning Province, China;

2. Dalian Institute of Chemical Physics, Chinese Academy of Sciences, Dalian 116023, Liaoning Province, China)

Abstract: With the expanding of humanity's activities, the continuous escalation in greenhouse gas emissions has exacerbated the scarcity of carbon environmental capacity, thereby intensifying the demand for precise carbon emission rights pricing. The transaction price in the carbon market, as a pivotal element driving the functionality of the carbon market, is crucial for the stable operation of the carbon market and the efficiency of carbon emission reductions. Accurate forecasting of carbon market transaction prices is of paramount importance for the effective investment in carbon assets and the pursuit of the lowest carbon emission reduction costs. Consequently, this paper proposes a novel carbon price forecasting method based on the NeuralProphet-LSTM (long short-term memory) model. Initially, the NeuralProphet model is utilized to decompose the carbon price series into trends, seasonal effects, event and holiday effects, and autoregressive effects for preliminary forecasting. The forecast results are then used to calculate the residuals, which are inputted into the LSTM for deeper information mining. Finally, the LSTM's prediction of the residuals is combined with the NeuralProphet forecast results through component addition, completing the integration of carbon price series information. Forecasts for the EU carbon market and China's Hubei carbon market demonstrate that this model's forecasting performance surpasses other models, showing high application value.

Keywords: carbon price prediction; artificial intelligence; hybrid model; NeuralProphet; LSTM

摘要: 随着人类活动的不断扩展, 温室气体的排放量也在持续增长, 加剧了碳环境容量的稀缺程度, 提高了对碳

排放权进行定价的强烈需求。碳市场交易价格作为发挥碳市场功能的核心要素, 关乎碳市场的稳定运行和碳减排效率。碳市场交易价格的准确预测对有效开展碳资产投资和寻求最低碳减排成本具有重要的意义。为此, 提出一种基于 NeuralProphet-LSTM (long short-term memory, 长短期记忆) 模型的新型碳价格预测方法: 首先使用 NeuralProphet 对碳价序列进行趋势、季节性效应、事件和节假日效应以及自回归效应的模块分解并初步预测; 之后使用其预测结果计算残差放入 LSTM 中进行更深层次的信息挖掘; 最后将 LSTM 对残差的预测通过组件加法与 NeuralProphet 预测结果组合, 完成碳价序列信息的融合。针对欧盟碳市场和中国湖北碳市场进行预测, 结果显示该模型的预测性能超过了其他模型, 展现出较高的应用价值。

关键词: 碳价预测; 人工智能; 混合模型; NeuralProphet; LSTM

0 引言

当前, 全球变暖的挑战日益紧迫, 极端气候事件在全球范围内频繁发生, 迫切需要采取措施控制温室气体排放以应对气候变化。研究指出, 碳定价是一种能够有效减少温室气体排放的市场机制^[1-2], 政府可通过设定碳排放目标控制温室气体排放, 市场则可通过碳价格信号对减排行动产生影响。运行完善的碳市场会对技术创新和能源消费产生积极的影响, 有利于促进低碳技术发展和清洁能源投资, 为温室气体减排提供动力。研究碳排放交易中的价格形成机制, 进行碳价格精准预测有助于有效开展碳资产管理, 以较低成本实现减排目标, 进一步为决策者提供科学、合理的决策支持, 从而推动碳市场的健康发展。

基金项目: 大连大学学科交叉项目 (DLUXK-2023-ZD-001)。

Interdisciplinary project of Dalian University (DLUXK-2023-ZD-001).

目前学者们对碳市场价格预测已经开展了相关的研究,碳市场价格预测的方法大致可以分为两类:传统的统计方法和人工智能方法。

在人工智能技术出现之前,碳价格通常使用传统的统计方法进行预测。例如GARCH模型,该模型在预测碳期货市场的波动性方面收获了不错的效果。文献[3]探讨了包括使用碳期货价格的GARCH模型、使用碳期权价格的隐含波动率模型和k最近邻模型3种方法预测碳期货波动率,发现GARCH模型的表现优于隐含波动率模型和k最近邻模型。除了GARCH模型,ARIMA模型是一种常用的金融时间序列分析方法,具有简单、可行和灵活等优点,可以对碳价格进行合理的预测。文献[4]基于ARIMA对碳市场的价格变化进行了预测,并研究了核证减排量(certified emission reduction, CER)期货价格和现货价格之间的关系,为中国碳市场的可持续发展提供了重要的参考和支持。然而,计量经济这类统计模型在基于线性平稳的数据假设下进行构建,这种假设意味着数据遵循一定的规律,即随着时间的推移,数据的变化趋势是线性且稳定的。这种假设在很多情况下是合理的,但在现实世界中,碳价格往往呈现出非线性、非平稳、不规则且高噪声的曲线特征。传统的统计模型很难捕捉更深层次的内在数据关系进行准确建模。

随着人工智能技术的迅速崛起,越来越多的优秀人工智能算法的出现,为突破统计模型的局限性提供了更多思路。相较于传统的统计模型,人工智能模型在建模能力方面具有显著的优势。尤其是在非线性建模方面展现出了强大的能力,能够更好地处理复杂、多变的数据模式和关系。文献[5]使用改进的小波最小二乘支持向量机来预测中国碳市场的碳价格,通过对广东、湖北和上海三个地区的预测结果进行比较,验证了该模型的有效性和优越性。除此以外,高斯过程^[6]、k近邻^[7]、随机森林^[8]也被广泛使用。文献[9]使用长短期记忆网络(long short-term memory, LSTM)对碳价格预测建模,该模型是传统深度学习模型循环神经网络的改进版本,在很多具有挑战性的预测问题上取得了显著的性能提升。文献[10]使用双向门控循环单元(gated recurrent unit, GRU)建立碳价预测模型,该模型在GRU中加入双向递归,这种设计使得双向GRU能够有效地捕捉到长期依赖关系,并且在处理长序列数据时具有更好的性能。文献[11]提出一种TCN-Seq2Seq的碳价预测架构,该模型结合了序列到序列学习框架和通用的时间卷积网络(temporal

convolutional network, TCN)结构,自动执行特征组合,并挖掘输入数据之间的关系,从而提高预测准确性。并且相对于传统的循环神经网络(recurrent neural network, RNN)模型,TCN-Seq2Seq模型可以通过并行计算来实现更高的计算效率。由于上述单一模型预测方法有着各自的缺点,近年来,大量的研究采用多个模型融合预测方法,结合多个模型优点,以达到提高预测精度的目的。为了捕捉到碳价序列中线性关系的同时又能获得其深层次的信息以及非线性关系,文献[12]提出了一种结合传统模型与深度学习模型的方法,ARIMA-CNN-LSTM模型是一个结合了传统时间序列分析方法(ARIMA)和深度学习方法(LSTM和卷积神经网络(convolutional neural networks, CNN))的模型,用于预测碳价格期货市场。这种模型组合的方法可以充分利用不同模型的优势,提高预测准确性。文献[13]提出了一种基于改进的完整集合经验模式分解和自适应噪声(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)的混合模型,用于碳价格预测。该模型利用Lempel-Ziv复杂性算法进行重构,通过相空间重构算法(phase space reconstruction, PSR)结合偏自相关函数(partial autocorrelation function, PACF)确定输入变量,并使用麻雀搜索算法(sparrow search algorithm, SSA)优化极限学习机(extreme learning machine, ELM)模型。还有研究者们采用LSTM混合深度多层感知器等神经网络模型进行组合预测,证明了组合预测相较于单一方法具备更好的准确性、优越性和鲁棒性^[14-16]。

现有的碳价预测方法存在一些明显的不足。传统的统计方法^[17-18]难以捕捉碳市场非线性、非平稳的价格走势。随着人工智能技术的不断发展,人们已经开展人工智能技术进行碳价预测研究以期提高预测准确性。但是目前方法^[19-20]没有考虑碳市场受季节性和周期性因素的影响,同时在处理数据时可能出现过拟合或欠拟合的问题,造成预测结果欠准确;并且由于其黑箱性质,缺乏可解释性。

基于上述背景,本文提出了一种结合NeuralProphet和LSTM的混合碳价格预测模型—NeuralProphet-LSTM模型,这种混合模型的设计使得各个组件之间相互协同,NeuralProphet专注于捕捉碳价中的趋势和季节性等方面,LSTM则专注于深层次的非线性信息,实现了模型的互补性,以此提高碳价预测精度并具有可解释性。

本文的主要贡献如下: ①提出了新型碳价预测模型NeuralProphet-LSTM模型; ②通过计算NeuralProphet头残差输入至LSTM获得尾残差, 通过组件加法将尾残差与NeuralProphet预测值进行模型融合, 使用头残差经过滑动窗口处理输入至4层LSTM进行处理; ③在欧洲碳市场和中国湖北碳市场进行实验验证, 对比分析了单一模型与组件分解模型预测结果, 证明提出的NeuralProphet-LSTM模型具备较高性能, 在欧洲碳市场和湖北碳市场, 均方误差 (mean-square error, MSE) 指标较最优的NeuralProphet和NeuralProphet-SVM分别提高12.6%和3.8%。

1 基础模型介绍

1.1 NeuralProphet模型

NeuralProphet是一个结合了FBProphet^[21]和神经网络的时间序列预测模型, 是一种结合了传统时间序列预测方法与深度学习技术的新型模型, NeuralProphet保留了FBProphet的设计理念, 并提供了相同的基本模型组件。NeuralProphet的核心设计是其模块化的结构, 由6个模块构成, 分别是趋势、季节性、事件和节假日效应、未来已知的外部变量回归、基于过去的自回归以及外部变量滞后回归。模型可以自由选择这些模块进行组合配置。每个模块都有其单独的构建过程, 都为NeuralProphet模型的最终预测做出贡献。

$$\hat{y}_t = T(t) + S(t) + E(t) + F(t) + A(t) + L(t) \quad (1)$$

式中: $T(t)$ 是 t 时刻的趋势函数; $S(t)$ 是 t 时刻的季节性效应函数; $E(t)$ 是 t 时刻的事件和节假日效应函数; $F(t)$ 是 t 时刻的未来已知的外部变量回归效应函数; $A(t)$ 是 t 时刻的基于过去的自回归效应函数; $L(t)$ 是 t 时刻的外部变量滞后回归效应函数。

具体来说, NeuralProphet模型首先将时间序列数据分解为趋势、季节性和节假日效应等部分。然后, 利用神经网络对这些部分进行建模和预测。在模型构建的过程中, 利用反向传播算法, 神经网络能够自我调节参数, 目的是降低预测的误差至最小。综合相加所有部分的预测输出后, 模型可以获得时间序列的最终预测结果。

尽管NeuralProphet集成了神经网络技术, 但它依然重视预测结果的可解释性。NeuralProphet提供了一些工具和方法, 使用户能够理解模型对数据进行预测的依据, 这在一些业务场景中尤为重要。NeuralProphet提供了简单易用的接口和预设参数, 使

得用户可以快速上手并进行预测。得益于PyTorch后端和标准深度学习方法, NeuralProphet可以方便地扩展和定制模型组件, 以适应不同的预测任务和数据类型。与FBProphet相比, NeuralProphet在生成的时间序列和真实世界数据集上的表现更加出色, 可以提高预测准确性55%~92%^[22]。

NeuralProphet模型的优势主要体现在以下几个方面: ①它结合了传统时间序列预测方法和深度学习技术的优势, 既能够捕获数据中的复杂非线性关系, 又具有较高的可解释性; ②NeuralProphet模型通过自动学习参数, 减少了人工调参的复杂性, 提高了预测效率; ③该模型还具有较好的扩展性, 可以方便地添加新的组件或调整现有组件的结构, 以适应不同场景下的时间序列预测需求。然而, NeuralProphet模型也存在一定的局限性: ①由于引入了深度学习技术, 模型的训练过程可能较为复杂和耗时; ②虽然模型的可解释性相对较好, 但相比传统的时间序列预测方法, 其解释性仍有一定差距; ③NeuralProphet模型在处理异常值或噪声较多的数据时, 可能会受到一定影响, 导致预测结果不准确。因此, 研究需要在NeuralProphet模型的基础上进行改进, 以提高其预测能力。

1.2 LSTM模型

LSTM^[23]是一种用于处理序列数据的RNN的变体。它在解决传统RNN面临的长期依赖问题上具有出色的表现, 并被广泛应用于自然语言处理、语音识别、时间序列预测等领域。

LSTM网络的核心功能依托于其细胞状态, LSTM细胞如图1所示。

LSTM采用门控制机制来细致调控细胞状态的更新与遗弃, 从而实现信息的有选择性传递。这种门的控制由一个sigmoid函数层和点乘操作构成, sigmoid函数层产生的输出介于0和1之间, 输出为0表示无信息传递, 输出为1则允许信息全量通过。LSTM内部设有3种门控机制: 遗忘门、输入门和输出门。其中, 输入门负责调节当前输入信息的接收量; 遗忘门决定了上一状态记忆保留的量; 输出门则管理着从当前状态输出的记忆量。这些门控机制依据通过学习获得的权重来自动调整信息流, 使得LSTM能够在处理长序列数据时, 有效地记忆与忘记信息。

初始化过程中, 遗忘门负责筛选细胞状态中将被遗弃的信息。此操作通过将输入数据传递至sigmoid函数完成, 该函数将输出限制在0到1的范围内, 此输出




图1 LSTM细胞

Fig. 1 LSTM cell

值进而与细胞状态进行元素级乘法操作。当遗忘门的输出值达到1时,相应信息得以保留;反之,若输出值为0,则表明相应信息将被舍去。遗忘门的具体运算过程可参见式(2)。

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + W_{fc}c_{t-1} + b_f) \quad (2)$$

式中: x_t 是当前时刻 t 的输入数据; h_{t-1} 是 $t-1$ 时刻的隐藏层数据; c_{t-1} 是 $t-1$ 时刻的细胞状态; W_{fx} 、 W_{fh} 、 W_{fc} 、 b_f 为遗忘门 f_t 的权重参数和偏置项; σ 为激活函数 sigmoid。

随后,输入门的职责是判定哪些信息应当被保存在细胞状态之中。这一过程涉及两部分:首先, sigmoid 函数负责选择需要更新的信息;其次, tanh 层确定了哪些信息可以被纳入细胞状态。通过整合这两个步骤来执行对细胞状态的更新。输入门的运算可以通过式(3)进行描述。

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + W_{ic}c_{t-1} + b_i) \quad (3)$$

式中: W_{ix} 、 W_{ih} 、 W_{ic} 、 b_i 为输入门 i_t 的权重参数和偏置项。

接下来,细胞状态将被更新:通过点乘操作和遗忘门决策来移除既定舍弃的信息,并将输入门筛选的新信息累加进来,完成状态的更新。更新细胞状态的过程可由式(4)展示。

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_{cx}x_t + W_{ch}h_{t-1} + b_c) \quad (4)$$

式中: W_{cx} 、 W_{ch} 、 b_c 为细胞单元 c_t 的权重参数和偏置项, tanh 为双曲正切函数。

最终, LSTM 单元通过输出门来决定哪些信息需要被输出。这一过程涉及先将细胞状态传递给 tanh 层,以此调整信息范围,随后乘以 sigmoid 层的结果,以筛选出具体需要输出的信息部分。输出门的具体操作可

参照式(5)与(6)进行理解。

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + W_{oc}c_{t-1} + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

式中: W_{ox} 、 W_{oh} 、 W_{oc} 、 b_o 为输出门 o_t 的权重参数和偏置项; h_t 为 LSTM 的输出值。

2 NeuralProphet-LSTM模型

NeuralProphet 虽然通过组件分解具备了一定的可解释性且具有相对出色的预测能力,但 NeuralProphet 基于传统统计方法的组件使得其对非线性信息的挖掘不够充分且无法捕捉序列数据中的长期依赖关系。为了进一步挖掘 NeuralProphet 未识别的非线性部分,本文利用 LSTM 强大的非线性建模能力以及捕捉序列数据中长期依赖关系的能力,将 NeuralProphet 未识别的非线性部分交由 LSTM 处理,以进行更深层次的信息挖掘,完成对残差部分的精确预测。

为了使模型具备传统方法的解释性和对数据中线性部分的分解能力,另一方面能够挖掘碳价序列中的非线性深层次信息及数据中的长期依赖关系,以达到更加准确的碳价预测精度,本文提出了 NeuralProphet-LSTM 模型,如图2所示。

NeuralProphet-LSTM 首先将碳价序列 y 通过 NeuralProphet 模块进行分解下的自回归得到 NeuralProphet 预测值 \hat{y}_{NP} , 将其与输入序列 y 相减得到头残差 $R_{head}(t)$, 再经过数据预处理以及滑动窗口处理放入4层 LSTM 中进行更深层次的信息挖掘得到尾残差 $R_{tail}(t)$, 最终将包括趋势 $T(t)$ 、季节性效应 $S(t)$ 、事件和

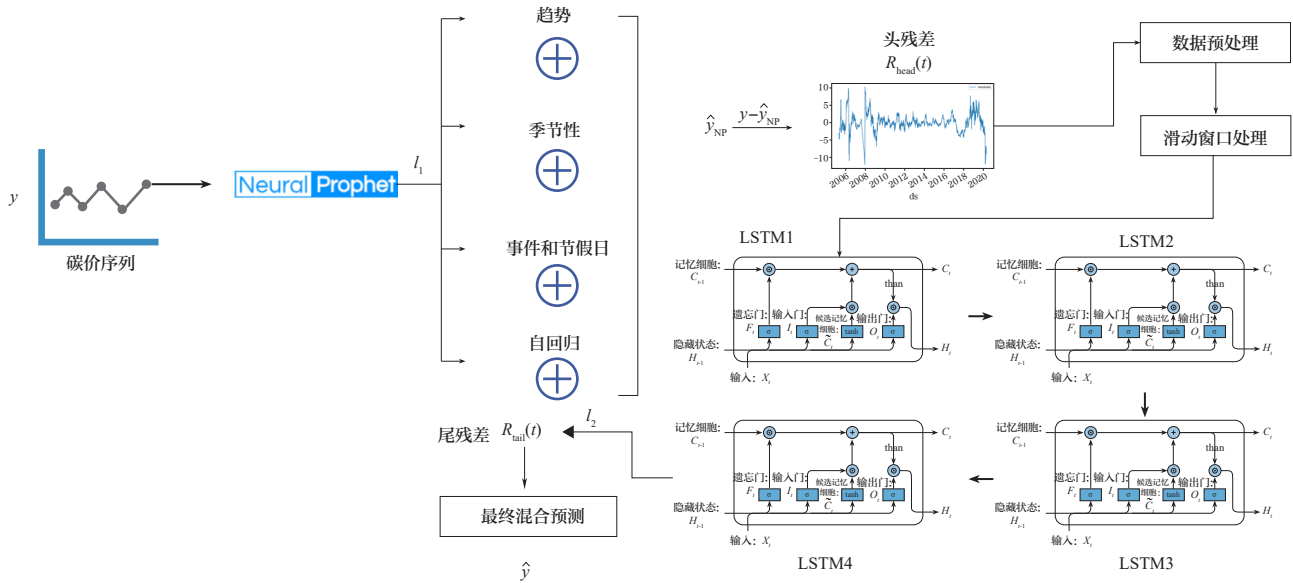


图 2 NeuralProphet-LSTM模型

Fig. 2 NeuralProphet-LSTM model

节假日效应 $E(t)$ 、自回归效应 $A(t)$ 的NeuralProphet预测值与尾残差 $R_{tail}(t)$ 累加获得最终碳价预测值 \hat{y} 。

本文提出的NeuralProphet-LSTM模型的NeuralProphet模块缓解了单一机器学习模型存在的过拟合现象,在此基础上对头残差的建模,使用LSTM有效地挖掘了其残差中的非线性部分,也就是NeuralProphet未能捕获的时序信息。最终,有效地将NeuralProphet预测与LSTM残差预测结合起来,使得每个模型完成各自负责部分,NeuralProphet专注于碳价中的趋势、季节性等部分,而LSTM完成对其残差中非线性部分信息的捕捉,融合优势,提升模型的预测性能。具体步骤包括:

1) 数据预处理。对数据归一化和标准化处理操作,从而满足模型对数据分布和范围的要求,采用最小-最大缩放如式(7)所示:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (7)$$

式中: x 表示输入数据; x' 表示归一化后的输出数据。归一化后的输出数据范围在0到1之间,用于度量2个变量之间的相对大小。

2) NeuralProphet模块。采用NeuralProphet模型中趋势、季节效应、事件和节假日效应、基于过去的自回归效应构建本模型中的NeuralProphet模块,得到NeuralProphet预测值 \hat{y}_{NP} ,如式(8)所示:

$$\hat{y}_{NP} = T(t) + S(t) + E(t) + A(t) \quad (8)$$

式中 $T(t)$ 、 $S(t)$ 、 $E(t)$ 、 $A(t)$ 定义与式(1)中相同。

3) 头残差获得模块。计算NeuralProphet预测值 \hat{y}_{NP} 与原始数据 y 的残差。计算得到头残差 $R_{head}(t)$,如式(9)所示:

$$R_{head}(t) = y - \hat{y}_{NP} \quad (9)$$

4) 滑动窗口处理。为了从多个已有数据得到预测数据,本模型定义了滑动窗口处理部分,该部分的窗口大小由分析数据自相关特性决定。本文采用的窗口大小为20,即从20天前头残差数据 $R_{head}(t)$ 中得到第21天的尾残差预测值 $R_{tail}(t)$ 。

5) LSTM处理。将经过滑动窗口处理的头残差数据 $R_{head}(t)$ 输入到LSTM处理部分产生LSTM输出尾残差 $R_{tail}(t)$,即残差预测值。LSTM处理部分由4个串行LSTM模块构成,1个LSTM模块含有32个LSTM细胞。

NeuralProphet预测值 \hat{y}_{NP} 与LSTM输出尾残差 $R_{tail}(t)$ 相加得到碳价预测值 \hat{y} ,如式(10)所示:

$$\hat{y} = T(t) + S(t) + E(t) + A(t) + R_{tail}(t) \quad (10)$$

此外,图2中的 l_1 和 l_2 分别是NeuralProphet与LSTM在训练过程中的损失函数,二者使用 L_{MSE} 作为损失函数,如式(11)所示:

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

LSTM优化器选择自适应矩估计(adaptive moment estimation, Adam)结合StepLR(步长学习率调度),用以动态调整学习率,防止模型陷入局部最优。

3 实证分析

在欧盟碳市场以及湖北碳市场进行本文提出的NeuralProphet-LSTM模型预测能力验证。通过选取Prophet、NeuralProphet、支持向量机(support vector machine, SVM)、LightGBM、LSTM以及这些模型的混合模型进行对比,证明本文提出的NeuralProphet-LSTM模型性能。

3.1 实验设置及运行环境

模型评估选择均方根误差(root mean square error, RMSE)、均方误差(mean square error, MSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)以及决定系数4个评价指标。如式(12)~(15)所示:

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

$$E_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (13)$$

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

式中: E_{RMSE} 为均方根误差; E_{MSE} 为均方误差; E_{MAPE} 为平均绝对百分比误差; R^2 为决定系数; n 表示数据点的总数; \hat{y}_i 表示预测值; y_i 表示实际值; \bar{y} 表示实际值的均值。

本文模型的构建使用Python3.8,基于深度学习框架PyTorch1.12.1来完成模型的快速搭建。数据处理部分结合Pandas和Numpy完成。硬件平台基于NVIDIA RTX 2080 Ti,用于深度学习加速计算。CUDA版本为11.3。机器学习模型通过scikit-learn1.4.1版本构建。

3.2 碳市场数据集

欧盟碳市场(European Union Emissions Trading System, EU ETS)是全球最大的碳排放交易体系之一^[24]。它涵盖了欧洲经济区内的工业、能源和航空等多个关键领域。在该体系下,政府向企业分配一定数量的排放许可证——欧盟配额(European Union Allowances, EUA),确保企业持有足够的EUA来覆盖其排放量,否则将面临罚款。EU ETS采用市场驱动机制,碳配额的价格由市场供需关系决定,从而激

励企业采取更环保的措施,以降低碳排放成本。截至2023年,EU ETS不仅覆盖了欧盟27个成员国,还包括冰岛、列支敦士登、挪威和英国北爱尔兰(仅电力企业)等国家和地区^[25]。这种跨国界的碳交易市场为碳排放权交易提供了一个统一的平台,促进了碳排放权的有效分配和价格形成。

EU ETS交易数据的选取基于Wind数据库,覆盖了从2005年4月22日至2024年1月16日的时间跨度,共计4819个观测值。考虑到EU ETS历史较长且相对成熟,将其与中国湖北碳市场进行对比建模,可为后者的碳市场发展提供有价值的参考和指导。在研究EUA价格时,多使用期货价格,主要是因为期货市场集聚了众多参与者,能够综合反映市场对未来供求关系变化的预期,有效展现价格发现功能。同时,期货交易所提供的详细、准确、及时的交易数据,为研究者进行市场分析和预测提供了便利,能够全面把握欧盟碳市场的动态,并为政策制定和市场决策提供依据。在进行模型的训练与验证时,数据被按照8:2的比例划分。EU ETS的历史数据如图3所示,被用于训练和验证过程。

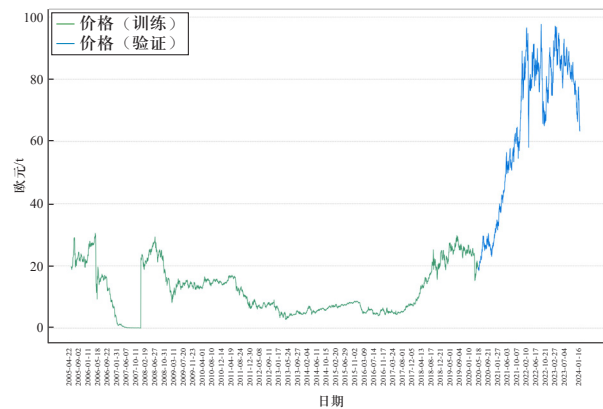


图3 EUA历史数据

Fig. 3 EUA historical data

湖北省作为中国碳市场交易的先行者之一,2014年开始建设碳交易试点市场^[26]。湖北碳市场试点工作不仅有效促进了温室气体排放控制与节能降碳政策的实施,而且为全国碳市场的发展提供了创新实践和宝贵经验,为政策制定和市场研究提供了重要支撑,具有重要的示范效应^[27-31]。

湖北碳配额(Hubei Emission Allowances, HBEA)交易数据也选取于Wind数据库,从2014年4月28日至2024年3月4日,湖北省碳市场共有2138个观测值,是国内观测值数量最多的碳市场之一。在进行数据分析时,这些数据被按照8:2的比例划分为训练集和验证

集, 以用于历史数据的模型训练和验证, 如图4所示。




图 4 HBEA历史数据

Fig. 4 HBEA historical data

3.3 性能分析

本文在欧洲碳市场和中国湖北碳市场上进行了模型实验, 对比验证了所提出的NeuralProphet-LSTM模型性能。首先进行了包括NeuralProphet在内的5种单一模型的对比分析。图5展示了EUA市场的单模型预测结果, 图6展示了HBEA市场的单模型预测结果。可见LSTM模型虽然成功挖掘了碳价的波动信息, 但在掌握总体市场趋势方面表现不足, HBEA数据集性能相对较好。SVM模型预测值远离真实值不能体现数据变化趋势, 且波动性不足。LightGBM模型起始阶段预测值接近真实值, 但大范围预测值远离真实值不能体现数据变化趋势且波动性不足。Prophet模型数据趋势较好, 但波动性和预测值准确性都不理想, HBEA

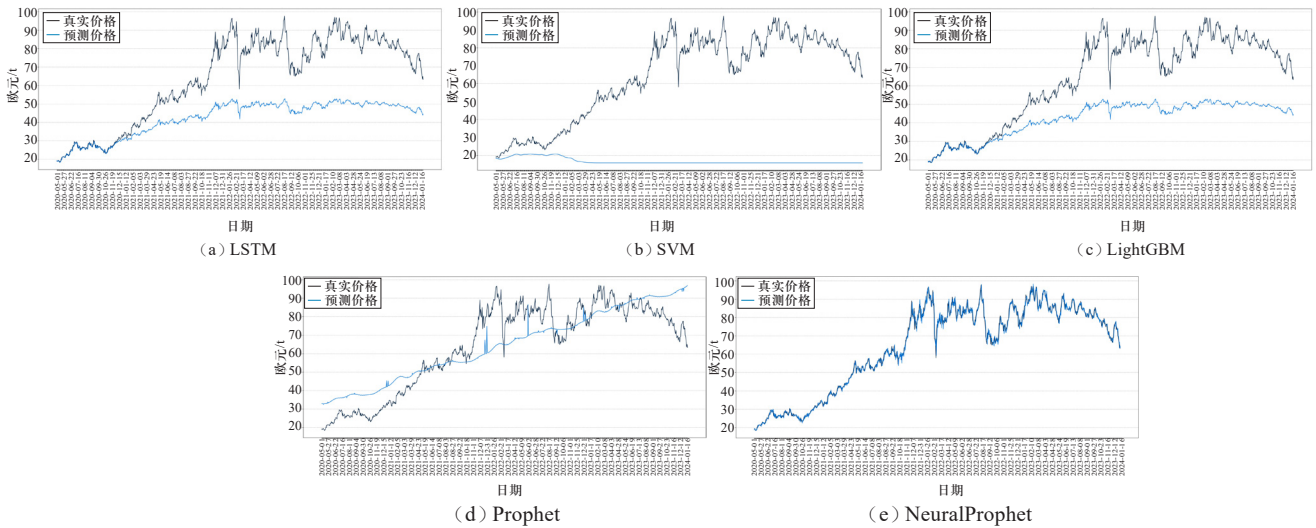


图 5 EUA数据集单一模型预测结果

Fig. 5 Single model prediction results in EUA dataset

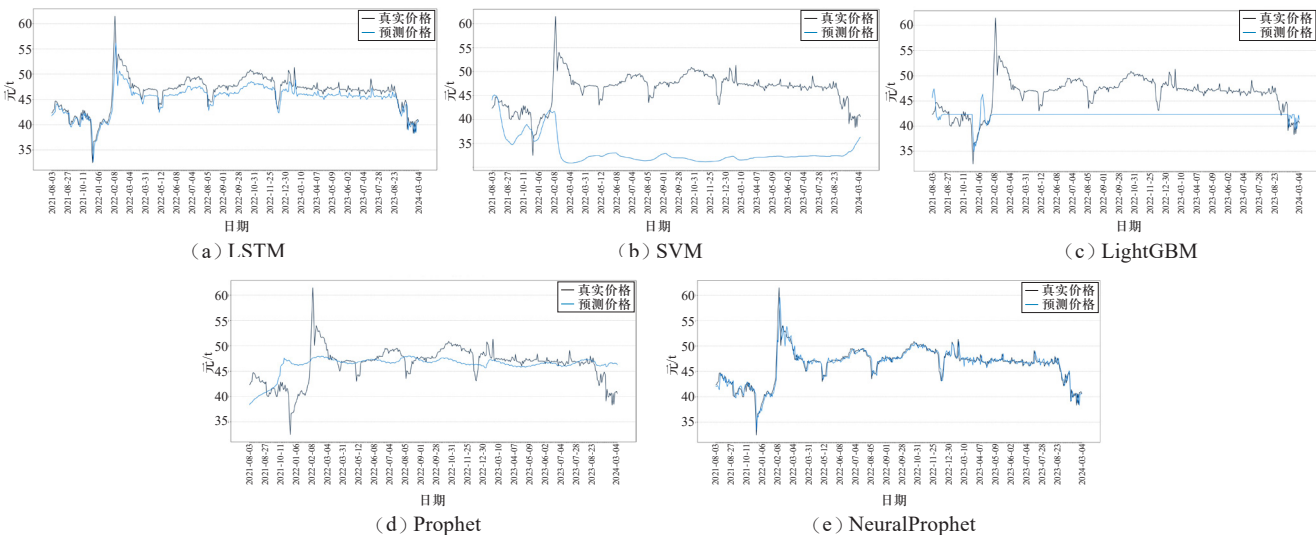


图 6 HBEA数据集单一模型预测结果

Fig. 6 Single model prediction results in HBEA dataset

数据集性能相对较好。无论在EUA数据集，还是在HBEA数据集，NeuralProphet模型全范围内预测值接近真实值，具有较高的预测精确度，数据趋势和波动性在所述单模型中性能最佳，这是该模型在趋势把握、季节性分析以及自回归特性方面的组件分解能力带来的优势。

为了进一步提高NeuralProphet模型的预测精度，本文提出了混合模型方法——NeuralProphet-LSTM模型，通过组件相加方式将Prophet模型和NeuralProphet模型分别与SVM模型、LSTM模型以及LightGBM模型混合，在EUA市场中的应用结果如图7所示，在HBEA市场中的应用结果如图8所示。可见两种数

据集下所提出的NeuralProphet-LSTM模型全范围内预测精确度，数据趋势和波动性最佳，这也说明了NeuralProphet-LSTM模型具有较强的泛化能力。NeuralProphet-LSTM模型将NeuralProphet与LSTM优势融合，NeuralProphet通过其对趋势和季节性变化的精确捕捉，补充了LSTM在这些方面的不足。同时，LSTM的强大非线性建模能力和对序列数据中长期依赖关系的捕捉能力，弥补了NeuralProphet在捕捉复杂时间序列信息方面的局限。

将5种单一模型和6种混合模型在欧洲碳市场和中國湖北碳市场上进行性能指标分析，表1为EUA市场数据预测指标，表2为HBEA市场数据预测指标。可

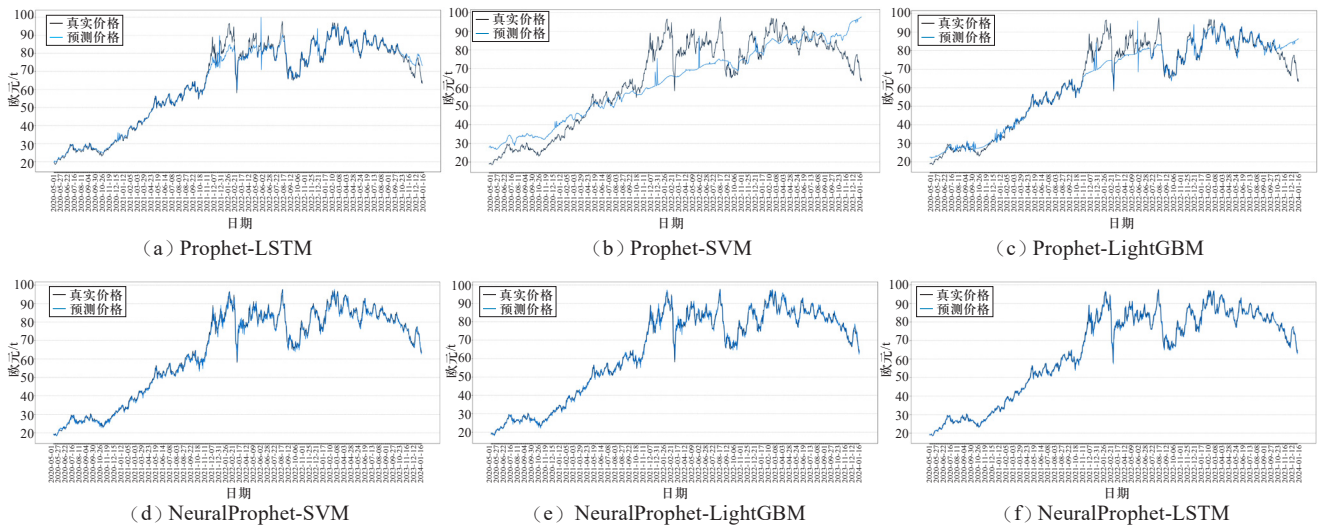


图7 EUA数据集混合模型预测结果

Fig. 7 Prediction results in EUA dataset hybrid model

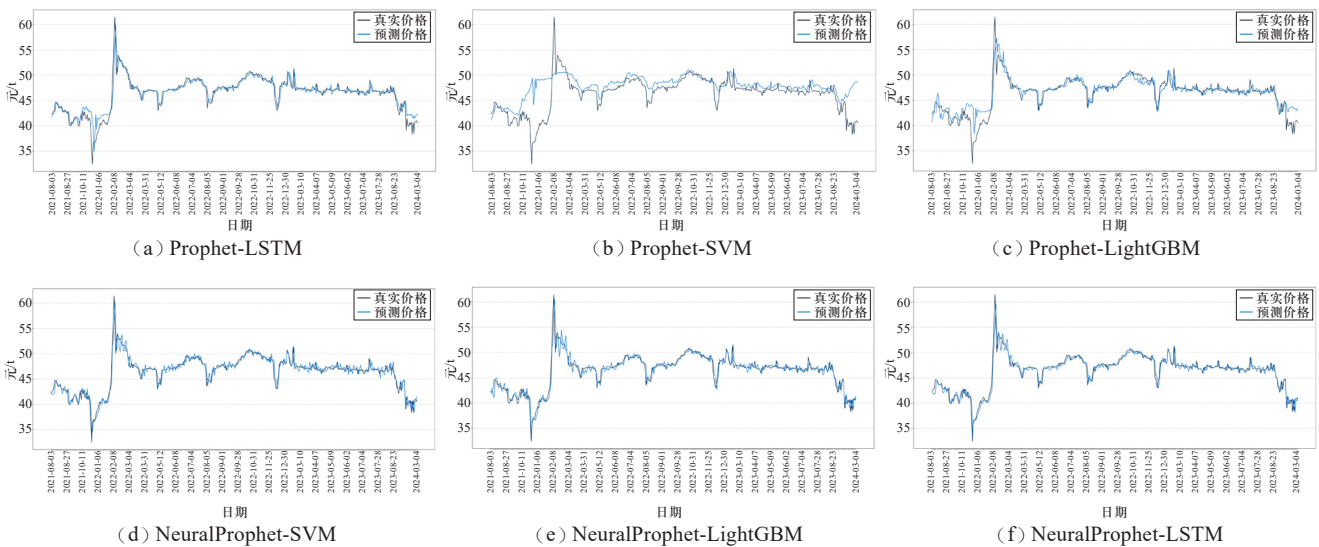


图8 HBEA数据集混合模型预测结果

Fig. 8 Prediction results in HBEA dataset hybrid model

见包括MSE、RMSE、MAPE和决定系数的4种指标, 本文所提出的NeuralProphet-LSTM模型性能最佳, 比如EUA市场数据预测较最优的NeuralProphet在MSE指标上提高了12.6%, HBEA市场数据预测较最优的NeuralProphet-SVM在MSE指标上提高了3.8%; 同时可见NeuralProphet-LSTM模型在HBEA市场数据预测性能好于EUA市场数据, 比如MSE指标从EUA市场的3.626下降到HBEA市场的0.955。

表 1 EUA数据集性能
Table 1 Performance in EUA dataset

模型	MSE	RMSE	MAPE	决定系数
LSTM	669.195	25.869	0.285	-0.234
SVM	2 868.058	53.554	0.666	-4.291
LightGBM	1 878.672	43.344	0.491	-2.466
Prophet	134.190	11.584	0.185	0.754
NeuralProphet	4.150	2.037	0.023	0.992
Prophet-LSTM	8.060	2.839	0.029	0.985
Prophet-SVM	101.788	10.089	0.135	0.816
Prophet-LightGBM	28.083	5.299	0.051	0.949
NeuralProphet-SVM	4.410	2.100	0.024	0.992
NeuralProphet-LightGBM	4.339	2.083	0.024	0.992
NeuralProphet-LSTM	3.626	1.904	0.021	0.993

表 2 HBEA数据集性能
Table 2 Performance in HBEA dataset

模型	MSE	RMSE	MAPE	决定系数
LSTM	2.847	1.687	0.030	0.747
SVM	200.521	14.161	0.278	-16.836
LightGBM	27.521	5.246	0.097	-1.448
Prophet	9.385	3.064	0.047	0.165
NeuralProphet	1.008	1.004	0.013	0.910
Prophet-LSTM	1.570	1.253	0.016	0.861
Prophet-SVM	9.457	3.075	0.043	0.165
Prophet-LightGBM	2.566	1.602	0.022	0.773
NeuralProphet-SVM	0.993	0.997	0.014	0.912
NeuralProphet-LightGBM	1.021	1.011	0.014	0.909
NeuralProphet-LSTM	0.955	0.977	0.013	0.915

4 结论

本文提出的NeuralProphet-LSTM模型, 首先通过NeuralProphet模块对碳价序列进行分解, 通过自回归预测了趋势、季节性效应、事件和节假日效应、自回归效应4个组件; 进一步, 引入了4层深度学习模型LSTM构成LSTM模块, NeuralProphet的头残差经过数据处理、滑动窗口处理后输入到LSTM模块, 以挖掘更深层次的非线性信息, 从而捕捉NeuralProphet未能完全捕获的非线性信息尾残差, 进而得到最终碳价格预测值。通过在欧洲碳市场和湖北碳市场上的实验验证, 比较5种单一模型和6种混合模型可知, 本文所提出模型在包括MSE、RMSE、MAPE和决定系数的4种指标上均取得了最优结果, 同时, 所提出的模型能够更准确地预测碳市场的价格, 能够更好地捕捉时间序列数据中的动态变化和趋势, 具有较强的泛化能力, 可以很好地适应不同的碳市场。

综上, 本文提出的NeuralProphet-LSTM模型充分发挥了各个组成模型的优势, 通过组合NeuralProphet模块分解下的各组件功能和LSTM模块的多层深度学习能力, 成功提升了碳价预测的准确性, 并且具有较强的泛化能力, 该模型的设计为时序数据预测领域提供了一种创新的思路, 对于更广泛的金融和经济预测问题具有潜在的应用前景。

参考文献

- [1] 陈旭东, 鹿洪源, 王涵. 国外碳税最新进展及对我国的启示[J]. 国际税收, 2022(2): 59-65.
CHEN Xudong, LU Hongyuan, WANG Han. Latest development of carbon tax systems in selected countries and its enlightenment to China[J]. International Taxation in China, 2022(2): 59-65(in Chinese).
- [2] 蓝虹, 陈雅函. 碳交易市场发展及其制度体系的构建[J]. 改革, 2022(1): 57-67.
LAN Hong, CHEN Yahan. Development and system construction of carbon trading market[J]. Reform, 2022(1): 57-67(in Chinese).
- [3] BYUN S J, CHO H. Forecasting carbon futures volatility using GARCH models with energy volatilities[J]. Energy Economics, 2013, 40: 207-221.
- [4] SHENG C G, WANG G Y, GENG Y D, et al. The correlation analysis of futures pricing mechanism in China's carbon financial market[J]. Sustainability, 2020, 12(18): 7317.
- [5] SUN W, XU C. Carbon price prediction based on modified wavelet least square support vector machine[J]. Science of the

- Total Environment, 2021, 754: 142052.
- [6] 何志昆, 刘光斌, 赵曦晶, 等. 高斯过程回归方法综述[J]. 控制与决策, 2013, 28(8): 1121-1129.
HE Zhikun, LIU Guangbin, ZHAO Xijing, et al. Overview of Gaussian process regression[J]. Control and Decision, 2013, 28(8): 1121-1129(in Chinese).
- [7] PETERSON L. K-nearest neighbor[J]. Scholarpedia, 2009, 4(2): 1883.
- [8] 方匡南, 吴见彬, 朱建平, 等. 随机森林方法研究综述[J]. 统计与信息论坛, 2011, 26(3): 32-38.
FANG Kuangnan, WU Jianbin, ZHU Jianping, et al. A review of technologies on random forests[J]. Statistics & Information Forum, 2011, 26(3): 32-38(in Chinese).
- [9] SUN W, LI Z Q. An ensemble-driven long short-term memory model based on mode decomposition for carbon price forecasting of all eight carbon trading pilots in China[J]. Energy Science & Engineering, 2020, 8(11): 4094-4115.
- [10] WANG J J, CUI Q, SUN X. A novel framework for carbon price prediction using comprehensive feature screening, bidirectional gate recurrent unit and Gaussian process regression[J]. Journal of Cleaner Production, 2021, 314: 128024.
- [11] ZHANG F, WEN N. Carbon price forecasting: a novel deep learning approach[J]. Environmental Science and Pollution Research International, 2022, 29(36): 54782-54795.
- [12] JI L, ZOU Y C, HE K J, et al. Carbon futures price forecasting based with ARIMA-CNN-LSTM model[J]. Procedia Computer Science, 2019, 162: 33-38.
- [13] ZHOU J G, CHEN D F. Carbon price forecasting based on improved CEEMDAN and extreme learning machine optimized by sparrow search algorithm[J]. Sustainability, 2021, 13(9): 4896.
- [14] PRADANA Y A, MUKHLASH I, IRAWAN M I, et al. Carbon price prediction in the European market using deep learning[C]//2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI). September 20-21, 2023, Palembang, Indonesia. IEEE, 2023: 307-314.
- [15] DONG H W, HU Y, YANG Y H, et al. A multi-strategy integration prediction model for carbon price[J]. Energies, 2023, 16(12): 4613.
- [16] JIANG N J, YU X B, ALAM M. A hybrid carbon price prediction model based-combinational estimation strategies of quantile regression and long short-term memory[J]. Journal of Cleaner Production, 2023, 429: 139508.
- [17] 王南, 胡展硕, 王丽霞, 等. 指数平滑法模型与ARIMA模型在行业碳排放趋势预测中的综合应用实践分析[J]. 数字技术与应用, 2023, 41(12): 91-93.
WANG Nan, HU Zhanshuo, WANG Lixia, et al. Practical analysis of comprehensive application of exponential smoothing model and ARIMA model in industry carbon emission trend prediction[J]. Digital Technology & Application, 2023, 41(12): 91-93(in Chinese).
- [18] 吕靖烨, 杜靖南, 沙巴·拉苏尔. 基于ARIMA模型的欧盟碳金融市场期货价格预测及启示[J]. 煤炭经济研究, 2019, 39(10): 23-29.
LÜ Jingye, DU Jingnan, Saba Rasool. Forecast and enlightenment of EU carbon financial market futures price based on ARIMA model[J]. Coal Economic Research, 2019, 39(10): 23-29(in Chinese).
- [19] SHI H X, WEI A L, XU X Z, et al. A CNN-LSTM based deep learning model with high accuracy and robustness for carbon price forecasting: a case of Shenzhen's carbon market in China[J]. Journal of Environmental Management, 2024, 352: 120131.
- [20] ZHOU F T, HUANG Z H, ZHANG C H. Carbon price forecasting based on CEEMDAN and LSTM[J]. Applied Energy, 2022, 311: 118601.
- [21] TAYLOR S J, LETHAM B. Forecasting at scale[J]. The American Statistician, 2018, 72(1): 37-45.
- [22] TRIEBE O, HEWAMALAGE H, PILYUGINA P, et al. NeuralProphet: explainable forecasting at scale[EB/OL]. 2021: 2111.15397. <https://arxiv.org/abs/2111.15397v1>.
- [23] YU Y, SI X S, HU C H, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. Neural Computation, 2019, 31(7): 1235-1270.
- [24] 张晶杰, 王志轩, 雷雨蔚. 欧盟碳市场经验对中国碳市场建设的启示[J]. 价格理论与实践, 2020(1): 32-36.
ZHANG Jingjie, WANG Zhixuan, LEI Yuwei. The enlightenment of the EU carbon market experience to the construction of China's carbon market[J]. Price (Theory & Practice), 2020(1): 32-36(in Chinese).
- [25] ICAP. Emissions trading worldwide: status report 2023[R]. Berlin: International Carbon Action Partnership, 2023.
- [26] 姚奕, 吕静, 章成果. 湖北碳市场价格形成机制及价格预测[J]. 统计与决策, 2017, 33(19): 166-169.
YAO Yi, LÜ Jing, ZHANG Chengguo. Price formation mechanism and price forecast of Hubei carbon market[J]. Statistics & Decision, 2017, 33(19): 166-169(in Chinese).
- [27] 田璧源, 刘倩汝, 戚红艳, 等. 阶梯分时碳价下考虑流-碳流耦合的综合能源园区优化调度[J]. 电力需求侧管理, 2024, 26(6): 37-43.
TIAN Biyuan, LIU Qianru, QI Hongyan, et al. Optimal dispatch of PIES considering energy carbon flow coupling under carbon trading mechanism[J]. Power Demand Side Management, 2024, 26(6): 37-43 (in Chinese).
- [28] 叶健强, 孙敦虎. 碳交易条件下基于鲁棒优化的电源规划研究[J]. 发电技术, 2024, 45(3): 566-574.
YE Jianqiang, SUN Dunhu. Research on power planning based on robust optimization under carbon trading condition[J]. Power Generation Technology, 2024, 45(3): 566-574 (in Chinese).
- [29] 吴艳娟, 靳鹏飞, 刘长铨, 等. 基于奖惩阶梯型碳价机制

的能源枢纽低碳优化策略[J]. 电力工程技术, 2024, 43(3): 88-98.

WU Yanjuan, JIN Pengfei, LIU Changcheng, et al. Low-carbon optimization strategy for energy hub based on reward-punishment ladder carbon price mechanism[J]. Electric Power Engineering Technology, 2024, 43(3): 88-98 (in Chinese).

- [30] 王守文, 叶金根, 徐丽洁, 等. 计及温控厌氧发酵和阶梯碳交易的农村综合能源低碳经济调度[J]. 电力系统保护与控制, 2024, 52(8): 88-97.

WANG Shouwen, YE Jingen, XU Lijie, et al. Rural comprehensive energy low-carbon economic dispatch taking into account temperature controlled anaerobic fermentation and ladder carbon trading[J]. Power System Protection and Control, 2024, 52(8): 88-97 (in Chinese).

- [31] 韩浩博, 刘晓峰, 刘怀, 等. 有限理性视角下发电市场竞争动态行为分析[J]. 电力建设, 2024, 45(10): 136-145.
HAN Haobo, LIU Xiaofeng, LIU Huai, et al. Analysis of dynamic behavior of market competition of generation companies from the perspective of limited rationality[J]. Electric Power Construction, 2024, 45(10): 136-145 (in Chinese).

收稿日期: 2024-03-22; 修回日期: 2024-08-20。



蔡远航

作者简介:

蔡远航 (1997), 男, 硕士研究生, 研究方向为图像处理、自然语言处理、时间序列、数据分析, E-mail: caiyuanhang@dicp.ac.cn。

冯建新 (1975), 女, 教授, 研究方向为图像处理。通信作者, E-mail: fengjianxin863@163.com。

王艳青 (1983), 女, 高级工程师, 研究方向为碳排放核算与环境评估, E-mail: wangyanqing@dicp.ac.cn。

(责任编辑 王彦博)