

基于CNN-BiLSTM-ARIMA模型的煤炭价格预测研究

刘嘉璇¹, 周昊², 花磊³, 崔骥³

¹南京信息工程大学数学与统计学院, 江苏 南京

²南京信息工程大学电子与信息工程学院, 江苏 南京

³苏州博纳讯动软件有限公司, 江苏 苏州

收稿日期: 2023年11月7日; 录用日期: 2023年12月22日; 发布日期: 2023年12月29日

摘要

“碳达峰、碳中和”目标对于煤炭行业“碳减排”提出了巨大挑战, 煤炭行业将面临全方位的深度调整。煤炭价格的预测对于有序降低碳排放至关重要, 但其波动性和不稳定性受多种影响因素共同作用, 因此对煤炭价格的变化做出准确预测较为困难。本文基于深度学习方法, 构建多特征下的网络融合模型(CNN-BiLSTM-ARIMA), 并应用于秦皇岛动力煤(大同优混5800)平仓价预测。选取判定系数 R^2 、平均绝对百分比误差MAPE、均方根误差RMSE作为评价模型的指标, 并与单一长短期记忆网络(LSTM)、双向长短期记忆网络(BiLSTM)及中间网络进行比较分析, 实验结果表明本文提出的融合模型具有更好的预测性能和实用性。

关键词

煤炭价格, 深度学习, CNN, BiLSTM, ARIMA

Coal Price Prediction Based on CNN-BiLSTM-ARIMA Model

Jiaxuan Liu¹, Hao Zhou², Lei Hua³, Ji Cui³

¹School of Mathematics and Statistics, Nanjing University of Information Science and Technology, Nanjing Jiangsu

²School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing Jiangsu

³Suzhou Beyondcent Software Co., Ltd., Suzhou Jiangsu

Received: Nov. 7th, 2023; accepted: Dec. 22nd, 2023; published: Dec. 29th, 2023

文章引用: 刘嘉璇, 周昊, 花磊, 崔骥. 基于 CNN-BiLSTM-ARIMA 模型的煤炭价格预测研究[J]. 运筹与模糊学, 2023, 13(6): 7768-7780. DOI: 10.12677/orf.2023.136759

Abstract

The goal of “carbon peak and carbon neutrality” poses a great challenge to the “carbon emission reduction” of the coal industry, and the coal industry will face an all-round deep adjustment. The prediction of coal price is very important for the orderly reduction of carbon emissions, but its volatility and instability are affected by many factors, so it is difficult to make an accurate prediction of the change of coal price. In this paper, based on deep learning method, a multi-feature network fusion model (CNN-BiLSTM-ARIMA) is constructed and applied to the closing price prediction of Qinhuangdao thermal coal (Datong Youming 5800). Coefficient R^2 , mean absolute percentage error MAPE and root mean square error RMSE were selected as the indexes to evaluate the model, and compared with single long short-term memory network (LSTM), bidirectional long short-term memory network (BiLSTM) and intermediate network. The experimental results show that the fusion model proposed in this paper has better prediction performance and practicality.

Keywords

Coal Prices, Deep Learning, CNN, BiLSTM, ARIMA

Copyright © 2023 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

工厂复工复产导致用电需求急剧增加，推高了作为原材料煤炭的价格。此外，欧洲国家限制煤炭购买和出口、煤炭燃烧造成环境污染以及国家对于清洁能源的倾向均对煤炭价格产生了影响。在此背景下，分析煤炭价格影响因素并预测具有重要研究意义。

秦皇岛动力煤价格受到多种因素的综合影响，包括供需关系、能源政策、宏观经济、季节性需求、进口和出口影响、煤炭品质和产地、运输和物流成本以及天气条件等。在进行煤炭价格预测时，需要综合考虑这些因素的变化和相互关系，以更准确地预测价格趋势。当然，很多学者对此已经有所研究。例如，马艳文(2021)除了选取煤炭价格、煤炭供给量、煤炭需求量等指标，还综合了非金融和金融两个视角，引入了实际GDP增速、美元汇率、和货币供应量指标进行分析预测[1]；袁训锋(2022)利用主成分分析对煤炭价格影响因素的重要程度排序[2]，研究表明重要程度从高到低依次为：成本要素、其他能源价格、进口煤价格、供需要素、国家政策、季节；张建英(2016)使用月度数据用单位根检验、协整检验、Granger因果检验和VAR模型对我国煤炭价格的影响因素进行了分析[3]，研究表明除煤炭价格自身波动外，还受大宗商品价格、宏观经济景气指数和煤炭产量的影响。对于多指标的煤炭价格预测，常用的时间序列数据建模和预测算法包括统计模型、指数平滑模型、机器学习模型、混合模型。例如，孙继湖(2000)以计量经济学和统计学为基础，采用ARIMA模型对山西优混在秦皇岛车站的交易价格进行预测[4]；邹绍辉(2017)利用最小二乘方法和GARCH模型拟合煤炭价格[5]，结果表明GARCH模型对于随机波动趋势较强的煤炭价格时间序列拟合效果更优；袁训锋(2022)建立指数平滑模型在未来31天、35周和36个月对秦皇岛煤炭价格进行预测[2]；刘滋奇(2020)建立基于SVR算法动力煤价格预测模型，实验证明预测效果良好[6]；兰丰(2022)通过构造循环神经网络及时序卷积网络进行实验，为煤炭价格中短期预测提供了实

际应用有效的解决思路[7]; 崔曦文(2022)建立基于布谷鸟搜索算法优化的长短期记忆网络(CS-LSTM)模型预测山西电煤价格指数[8], 实例验证了该模型预测的精准度; 刘维曼(2022)构建了 LSTM-ARIMA 预测模型对湖北、广东、北京三个试点地区碳排放权交易价格进行预测[9], 研究表明该模型的预测效果较好, 具有适用性和有效性; Xiang Wang (2022)提出了一种创新的混合预测方法(CEEMDAN-GWO-CatBoost), 通过结合机器学习模型、特征选择、数据分解和模型解释来预测煤炭价格指数[10], 此文提出的组合预测模型的预测性能明显优于其他比较模型; 张克非(2021)构建一种基于经验模态分解(EMD)、注意力(Attention)机制的 LSTM/GRU 融合深度学习模型(EMD-Att-LSTM/GRU) [11], 研究表明该组合模型很好的实现了 EMD 分解和 Attention 机制的双重优势, 能够实现动力煤价格的精准预测; 郭嘉宁(2021)使用双向 LSTM 引入卷积神经网络模块和横向注意力机制, 最终验证了所提模型优于主流的时间序列预测模型[12]; Bo Cao (2023)将改进的麻雀搜索算法(ISSA)和最小二乘支持向量回归机(LSSVR)算法相结合, 提出了 ISSA-LSSVR 煤炭价格时间序列预测模型[13], 与传统的 ARIMA 预测模型相比, 该模型能够更好地匹配煤炭价格的变化趋势, 具有较高的预测精度。

以上国内外煤炭价格波动情况、影响因素及煤炭价格预测方法的研究进展, 为本研究提供了重要的理论依据和参考。本文将综合考虑各类影响因素, 将传统计量学模型与神经网络模型的优点结合, 希望得到更好的预测效果。

2. 模型简介

2.1. ARIMA 模型

自回归移动平均模型(Autoregressive Integrated Moving Average Model, ARIMA)主要由三部分构成, 分别为自回归模型(AR)、差分过程(I)和移动平均模型(MA)。ARIMA 模型具体流程图如图 1 所示。

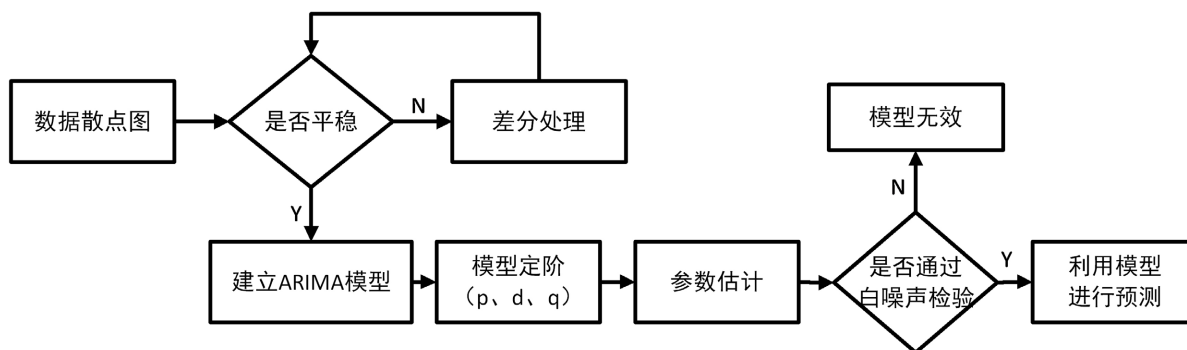


Figure 1. ARIMA model flow chart
图 1. ARIMA 模型流程图

ARIMA 模型预测时间序列的基本步骤如下:

1) 差分处理: ARIMA 模型要求时间序列是平稳的。为了消除时间序列数据的非平稳性, ARIMA 模型通常需要进行差分处理, 即将原始数据转化为差分数据, 以消除趋势和季节性等影响。模型中差分阶数 d 表示需要对时间序列数据进行差分的次数。

2) 模型定阶: 确定 ARIMA 模型的阶数 p 、 q 通常需要通过观察自相关函数(ACF)和偏自相关函数(PACF)图来进行选择, ARMA 通用判断标准如表 1 所示。

3) 参数估计: 确定模型的阶数后, 可以使用最小二乘估计等方法估计模型参数。

4) 模型预测: 利用构建好的 ARIMA 模型进行时间序列数据的预测, 通过已知历史数据得到未来时

间点的预测值。

5) 模型评估：可以使用均方根误差(RMSE)等指标来评估模型的预测精度。

Table 1. ARMA general criteria description table
表 1. ARMA 通用判断标准说明表

模型	自相关图	偏自相关图
AR(p)	拖尾	p 阶截尾
MA(q)	q 阶截尾	拖尾
ARMA(p,q)	拖尾	拖尾

2.2. LSTM 模型

长短期记忆网络(Long-Short Term Memory, LSTM)应用于非线性模型, 可以作为复杂的非线性单元用于构造更大型深度神经网络[14]。LSTM 模型网络结构如图 2 所示。

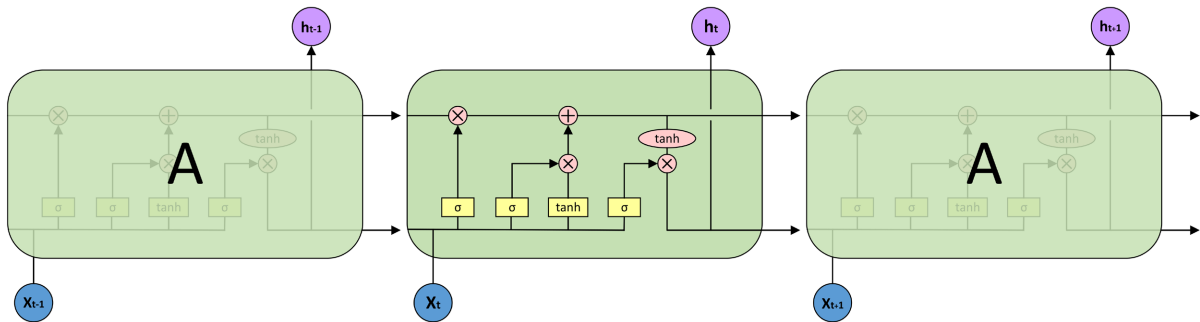


Figure 2. LSTM network structure
图 2. LSTM 网络结构

1) 遗忘门 f_t 的计算过程如公式(1)所示。其中 σ 是激活函数, W_f 是遗忘门的权重矩阵, h_{t-1} 是前一时刻的隐藏状态, x_t 是当前时刻的输入, b_f 是遗忘门的偏置。

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

2) 输入门 i_t 、候选记忆单元值 \tilde{C}_t 、记忆单元值 C_t 如公式(2)、(3)、(4)所示。其中 W_i 是输入门的权重矩阵, C_{t-1} 是前一时刻的记忆单元值。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{2}$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \tag{3}$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \tag{4}$$

3) 输出门的值 o_t 和模型的最终输出值 h_t 的计算如公式(5)、(6)所示, 其中 W_o 是输出门的权重矩阵, \tanh 是双曲正切激活函数。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{5}$$

$$h_t = o_t * \tanh(C_t) \tag{6}$$

2.3. BiLSTM 模型

双向长短期记忆网络(Bi-directional Long Short-Term Memory, BiLSTM)由前向与后向 LSTM 模型组合而成。使用 LSTM 模型进行预测时可以较好的捕捉到较长距离的依赖关系,但无法编码从后到前的信息,此时可以利用 BiLSTM 模型捕捉双向依赖达到更精准的预测效果。BiLSTM 模型网络结构如图 3 所示。

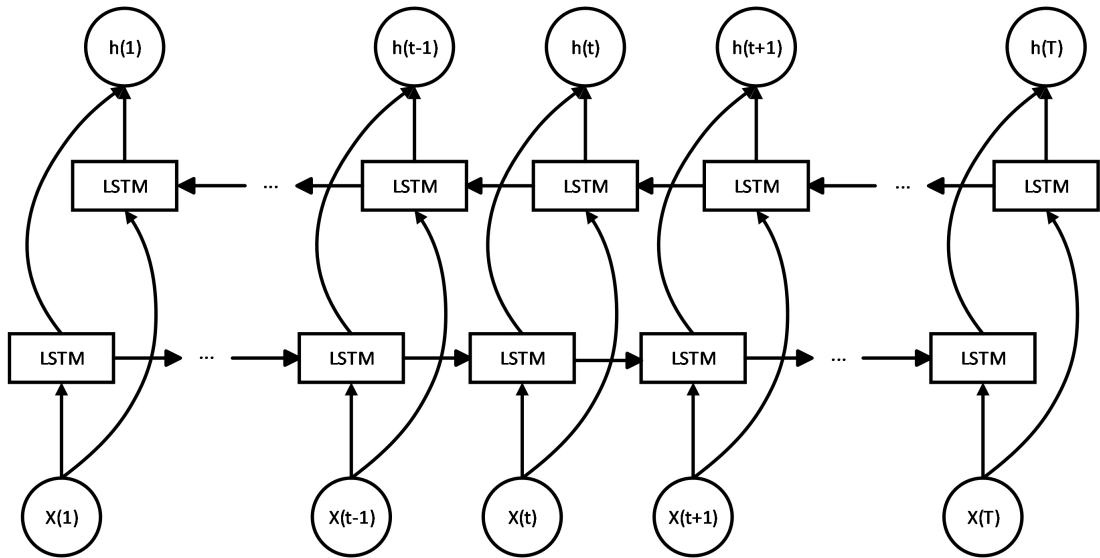


Figure 3. BiLSTM network structure
图 3. BiLSTM 网络结构

2.4. CNN-(Bi)LSTM-ARIMA 模型

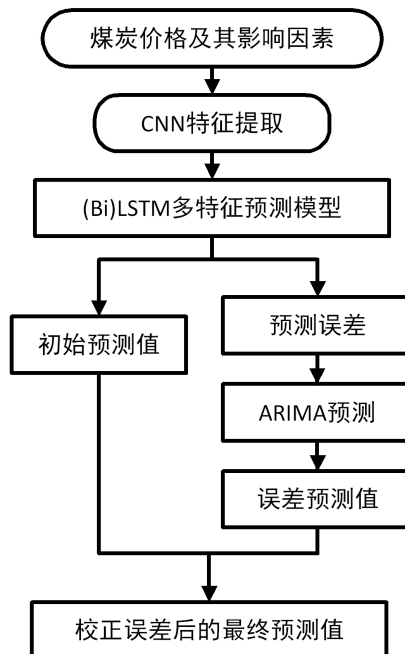


Figure 4. CNN-(Bi)LSTM-ARIMA network structure
图 4. CNN-(Bi)LSTM-ARIMA 网络结构

煤炭价格数据趋势复杂，具有非平稳、长期依赖并受多种影响因素影响的特点。由于 ARIMA 模型在处理平稳或线性相关的时间序列数据方面表现良好，而 LSTM、BiLSTM 网络模型在处理非线性、复杂关系的数据时效果较好；并且 LSTM 这类神经网络能够对具有多个输入变量的问题进行建模，而 ARIMA 这种经典的线性方法无法进行多变量输入的预测问题。本文将两种类型的时间序列预测模型相结合，充分利用两者的优势，同时加入 CNN 模块提取特征信息，构建 CNN-(Bi)LSTM-ARIMA 融合模型对煤炭价格进行预测，期望提高预测的准确性。

CNN-(Bi)LSTM-ARIMA 模型的流程图如图 4。

1) 将煤炭价格历史数据用 BiLSTM 进行单特征预测分析；加入影响因素的煤炭价格历史数据用 BiLSTM 进行多特征预测分析，分别得到初始预测结果和预测误差；

2) 利用 ARIMA 模型对误差序列进一步拟合预测，并对初始 BiLSTM 预测值进行修正，从而得到最终预测结果；

3) 根据 R^2 、RMSE、MAE 和 MAPE 等评价指标来评估模型的预测准确度。

2.5. 评价指标

本文选择 R^2 、MAPE 和 RMSE 三种评价指标检验模型预测性能。

1) 判定系数 R^2 ：通过计算回归平方和(SSR)与总平方和(SST)的比值，反应因变量 Y 的全部变动能通过回归模型被自变量 x 解释的比例。判定系数越接近于 1，模型的拟合效果越好。

$$R^2 = \frac{SSR}{SST} \quad (7)$$

2) 平均绝对百分误差 MAPE：通过计算真实值 y_i 与预测值 \hat{y}_i 的误差百分比避免了数据范围大小的影响。

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (8)$$

3) 均方根误差 RMSE：通过模型预测值 \hat{y}_i 与真实值 y_i 之间的偏差来评估预测结果好坏。均方根误差越小，模型的预测效果越好。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (9)$$

3. 基于 CNN-BiLSTM-ARIMA 模型的预测研究

本文综合考虑了供需因素、替代能源、运输调度、宏观经济四大类指标，选取共计 55 种影响因素对动力煤价格利用趋势性、相关性和因果性分析，保留重要影响因素作为预测模型的输入特征；基于双轨制定价模式的调整，选取 2016 年 1 月 4 日至 2023 年 6 月 6 日秦皇岛动力煤大同优混(5800)的日平仓价作为煤炭价格预测的研究对象；针对传统的计量学模型与深度学习模型的优缺点，取长补短，构建 CNN-(Bi)LSTM-ARIMA 融合模型对煤炭价格以 1/3/5/7 为时间跨度分别进行预测，并与单特征和单一网络模型进行对比分析，以期加入影响因素的融合模型预测精准度更高。

3.1. 数据预处理与特征选择

观察数据集发现，各变量均有不同程度的数据缺失现象。针对缺失数据的数量及规律，本文采用不同的处理方法。对于存在大面积缺失的变量，如果将其人为填充可能会对研究结果产生错误的影响，因此决定删除这些变量，不使用其作为影响因素放入模型研究。针对那些有较强规律的缺失值，即主要集

中在非工作日以及节假日期间的缺失数据，本文采用引入节假日标签的方式与工作日缺失值进行区分，并利用平推法填充。最后，由于数据漏更或者其他可能存在的技术原因造成的缺失值采用插值进行填充。

3.1.1. 相关性分析

对经过预处理后的煤炭价格及 55 个影响因素首先进行相关性检验。相关性分析是一种用于探索两个或多个变量之间关系的统计方法。可以帮助我们了解变量之间的相关程度，从而揭示变量之间的潜在关联。常用的相关性系数包括 Pearson 相关系数、Spearman 等级相关系数和 Kendall 等级相关系数。以下是这三种相关性系数的公式：

1) Pearson 相关系数：

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (10)$$

2) Spearman 等级相关系数：

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n^3 - n} \quad (11)$$

3) Kendall 等级相关系数：

$$\tau = \frac{n_c - n_d}{n_0} \quad (12)$$

其中， X_i 、 Y_i 表示第 i 个数据点的值， \bar{X} 、 \bar{Y} 为均值， n 表示数据点的数量， d_i 表示 X 的第 i 个数据点与 Y 的第 i 个数据点的等级差， n_c 表示具有相同等级顺序的数据点对的数量， n_d 表示具有不同等级顺序的数据点对的数量， n_0 表示总的的数据点对的数量。

通常，当 $|r| \geq 0.8$ 时，可视为高度相关，以此为三种相关系数的共同筛选依据，可以初步剔除相关系数绝对值的均值小于 0.8 的 49 个变量，保留剩余 6 个自变量。

相关性分析提供的是线性关系方向上的参考，但一些变量带来的影响不是简单线性的。例如，某些变量对煤炭价格带来的影响不容易被发现，因为他们所造成的影响可能不是同期特征的变化就能够反映在煤炭价格的变化上。因此，下面需要 Granger 因果关系检验做进一步分析，查看各变量与煤炭价格之间的非线性关系，探究各自变量和因变量之间的因果关系，确定各自变量带来影响的滞后或先行时长。

3.1.2. 平稳性分析

进行格兰杰因果关系检验的一个前提条件是时间序列必须具有平稳性，否则可能会出现虚假回归问题。常用增广的迪基 - 富勒检验(ADF 检验)来分别对各指标序列的平稳性进行单位根检验。

经过 ADF 检验与平稳化处理，所有变量经过一次一阶自差分后均能够达到平稳。其中，煤炭价格变量一阶平稳，影响因素中原数据平稳的有 16 个变量，一阶差分后平稳的有 39 个变量。

3.1.3. 协整检验

协整检验用来分析变量之间的长期均衡关系，由于原始序列平稳肯定协整，变量间进行协整检验的必要条件是它们之间是同阶单整。故针对平稳性检验得到的 39 个一阶平稳变量以秦皇岛动力煤(大同优混 5800)平仓价作为基准变量进行协整检验。

Engle-Granger (EG) 两步法是一种用于检验时间序列数据是否存在协整关系的常用方法。它的基本思想是，首先在第一步中估计出长期均衡关系，然后在第二步中检验残差序列的平稳性，以确定是否存在协整关系。检验结果显示，在显著性水平为 0.05 时，有 25 个影响因素变量表现为协整。

3.1.4. Granger 因果分析

协整检验结果可以得出协整变量之间存在长期的稳定关系，这只是从数量上得到的结论，但不能确定谁是因、谁是果。下面对协整检验后的协整变量进行 Granger 因果检验，判断影响因素与动力煤价格间的领先滞后关系。在 5% 显著性水平下，筛选出 16 个与因变量具有因果关系的自变量。

通过以上对煤炭价格及其影响因素定性和定量的分析，共同筛选出表 2 中的 5 个指标作为煤炭价格预测的输入变量。

Table 2. Input variable

表 2. 输入变量

序号	变量	Pearson	Spearman	Kendall	平稳性结论	协整性结论	因果关系结论
1	秦皇岛动力煤：平仓价：大同优混(5800)(元/吨)	1.000**	1.000**	1.000**	一阶平稳	协整	有因果关系
2	主流价：煤沥青(中温)：河北地区(元/吨)	0.861**	0.857**	0.699**	一阶平稳	协整	有因果关系
3	中信行业指数：煤炭	0.872**	0.885**	0.713**	一阶平稳	协整	有因果关系
4	中信行业指数：煤炭开采洗选	0.876**	0.897**	0.731**	一阶平稳	协整	有因果关系
5	中信行业指数：动力煤	0.880**	0.871**	0.709**	一阶平稳	协整	有因果关系

由于数据之间存在量纲不一致问题，对原始数据使用“MinMaxScaler”函数对数据进行归一化处理，函数表达式为：

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (13)$$

其中， x^* 是归一化后数值， x 是原始数值， x_{\max} 是数据最大值， x_{\min} 是最小值。

3.2. 实验结果与分析

数据集按照 9:1 划分训练集和测试集。参数 $Kim = 10$ ， $Step = 1/3/5/7$ 表示利用煤炭价格及其影响因素过去 10 个历史数据预测未来步长为 1/3/5/7 的煤炭价格。各模型的名称、分类及输入如表 3 所示。

Table 3. Each model feature input

表 3. 各模型特征输入

模型分类	模型名称	特征输入
传统计量学模型	ARIMA	
	SF-LSTM	动力煤自身价格
深度学习	SF-BiLSTM	
	LSTM	
	BiLSTM	
	CNN-LSTM	
计量学 + 深度学习融合模型	CNN-BiLSTM	动力煤自身价格及其影响因素
	CNN-LSTM-ARIMA	
	CNN-BiLSTM-ARIMA	

对于不同时间步长, 图 5 显示在 SF-LSTM、SF-BiLSTM 两个单一价格变量预测网络的基础上加入影响因素后, 测试集预测效果更优; 图 6 显示在加入影响因素的 LSTM、BiLSTM 网络中加入 CNN 特征提取模块后, 测试集的预测效果提升; 图 7 显示加入 ARIMA 修正使得 CNN-LSTM、CNN-BiLSTM 模型预测效果再次得到提升, 从而得到 ARIMA-CNN-(Bi)LSTM 融合模型。





Figure 5. Add the prediction curve comparison of influencing factors

图 5. 加入影响因素的预测曲线对比






Figure 6. Add the prediction curve comparison of CNN module

图 6. 加入 CNN 模块的预测曲线对比

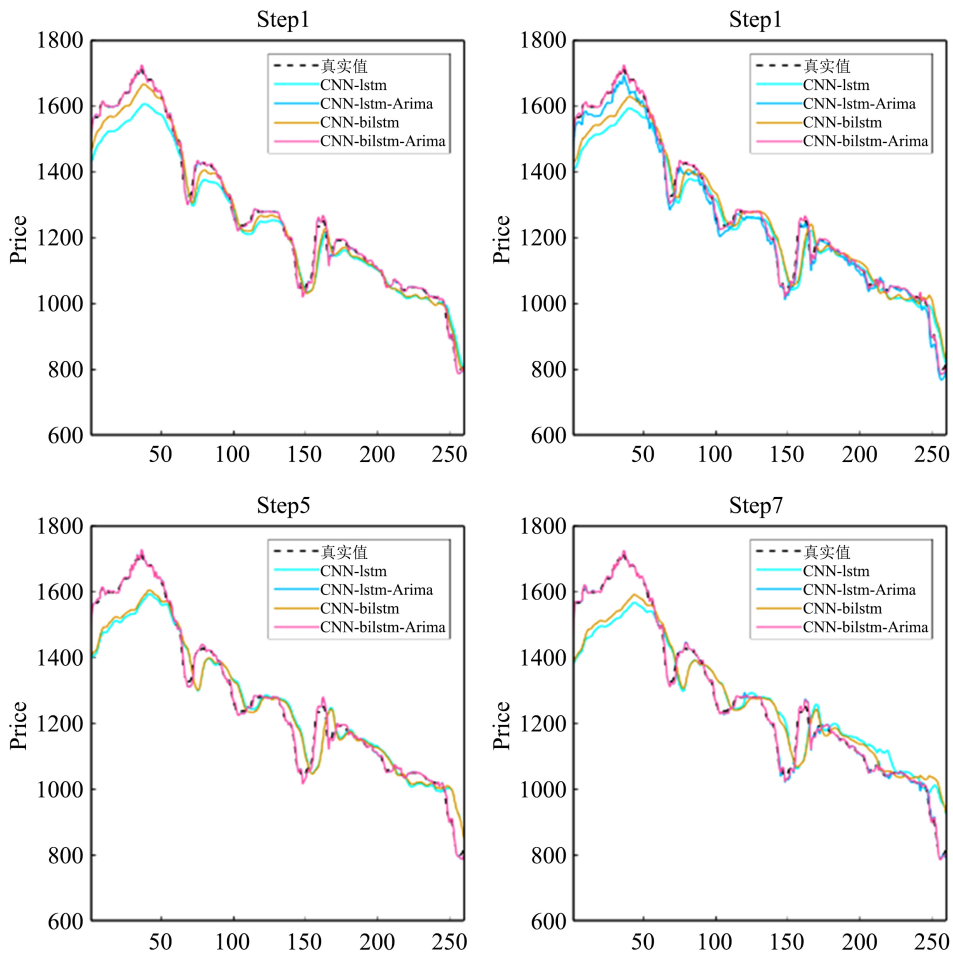


Figure 7. Add ARIMA modified prediction curve comparison

图 7. 加入 ARIMA 修正的预测曲线对比

表 4 具体展示了各类模型通过判定系数、平均绝对百分误差、均方根误差对其预测效果的评价结果。

Table 4. Comparison of model prediction results
表 4. 模型预测结果对比

Step	Model	R ²	MAPE	RMSE
1	SF-LSTM	0.9064	4.5561%	71.0510
	LSTM	0.9265	3.7694%	63.9521
	CNN-LSTM	0.9502	3.1117%	51.8470
	CNN-LSTM-ARIMA	0.9977	0.6360%	11.1814
	SF-BiLSTM	0.9502	3.0623%	51.7984
	BiLSTM	0.9672	2.7084%	42.0879
	CNN-BiLSTM	0.9805	2.0190%	32.4723
	CNN-BiLSTM-ARIMA	0.9977	0.6455%	11.1724
3	SF-LSTM	0.8897	4.2293%	77.1414
	LSTM	0.9130	4.2319%	68.5003
	CNN-LSTM	0.9267	3.6352%	62.8748
	CNN-LSTM-ARIMA	0.9903	1.4751%	22.8542
	SF-BiLSTM	0.8912	4.1702%	76.6049
	BiLSTM	0.9222	3.8848%	64.7892
	CNN-BiLSTM	0.9453	3.2697%	54.3385
	CNN-BiLSTM-ARIMA	0.9974	0.6945%	11.9108
5	SF-LSTM	0.8799	4.5823%	80.4756
	LSTM	0.8953	4.6011%	75.1302
	CNN-LSTM	0.9084	4.1685%	70.2918
	CNN-LSTM-ARIMA	0.9976	0.6426%	11.4602
	SF-BiLSTM	0.8863	4.4469%	78.3038
	BiLSTM	0.9010	4.5295%	73.0771
	CNN-BiLSTM	0.9143	3.9993%	67.9995
	CNN-BiLSTM-ARIMA	0.9976	0.6664%	11.4461
7	SF-LSTM	0.8131	5.5837%	100.3833
	LSTM	0.8162	5.7603%	99.5646
	CNN-LSTM	0.8574	5.4005%	87.693
	CNN-LSTM-ARIMA	0.9970	0.6944%	12.7607
	SF-BiLSTM	0.8356	5.3170%	94.1685
	BiLSTM	0.8524	5.2054%	89.2128
	CNN-BiLSTM	0.8765	4.9580%	81.6192
	CNN-BiLSTM-ARIMA	0.9972	0.6563%	12.2964

由表 4 可知:

1) 步长一定时, 多变量 LSTM、BiLSTM 模型的预测准确率高于单变量的对应模型, 说明加入影响因素对煤炭价格预测有重要作用;

2) 步长一定时, BiLSTM 比 LSTM 模型准确率更高, 说明 BiLSTM 模型的双向反馈机制可以有效提升预测效果;

3) 模型加入 CNN 模块后, LSTM 及 BiLSTM 模型的预测效果都有所提升, 说明 CNN 模块可以加强对模型输入的特征提取作用;

4) 利用 ARIMA 模型对融合模型的误差序列进一步拟合预测, 并对 CNN-(Bi)LSTM 预测值进行修正, 由此得到的预测结果准确度显著提升, 说明 ARIMA 对预测模型具有较强的修正效果;

5) 综合来看, 针对不同的步长, 利用 CNN-BiLSTM-ARIMA 融合模型预测煤炭价格效果最好。

4. 结论与展望

本文调研选取秦皇岛动力煤大同优混(5800)的日平仓价作为煤炭价格预测的研究对象, 综合考虑了四大类指标, 选取共计 55 种影响因素对动力煤价格利用趋势性、相关性和因果性分析, 最终保留 4 种影响因素作为预测模型的输入特征, 通过实验验证加入影响因素显著提升了模型的预测能力。

通过多特征 LSTM、BiLSTM 基准神经网络中加入 CNN 特征提取模块, 提高了预测模型对煤炭价格影响因素的特征提取能力, 同时也与传统计量学 ARIMA 模型进行融合, 改善了神经网络对复杂的煤炭价格非线性趋势的把握, 最终利用 CNN-BiLSTM-ARIMA 融合模型对 1、3、5、7 不同的时间步长进行预测, 准确率均达到 99%以上。

由于个人时间精力有限, 本文工作还有进一步提升的空间。后续可以考虑增加环境、政策、气温等因素对煤炭价格的影响, 或者可以通过增加其他煤炭价格验证融合模型的适用性。

致 谢

感谢给予引用权的文献作者及发布相关数据的数据库对本文的论据支撑。

基金项目

国家自然科学基金面上项目(62076137)。

参考文献

- [1] 马艳文. 基于金融和非金融结合视角的我国大宗商品价格波动风险预警研究[J]. 商展经济, 2021(3): 19-22.
- [2] 袁训锋, 王肖影, 潘新宇, 等. 基于主成分分析和指数平滑法的秦皇岛煤炭价格预测[J]. 微型电脑应用, 2022(1): 16-19.
- [3] 张建英. 我国煤炭价格影响因素的 VAR 模型分析[J]. 经济问题, 2016(1): 108-112.
- [4] 孙继湖, 彭建萍. 时间序列分析技术在煤炭价格预测中的应用[J]. 地质技术经济管理, 2000, 22(3): 33-40.
- [5] 邹绍辉, 张甜. 基于 GARCH 模型的煤炭价格波动规律研究[J]. 价格月刊, 2017(9): 13-18.
- [6] 刘滋奇. 基于 SVR 算法的动力煤价格预测研究[D]: [硕士学位论文]. 徐州: 中国矿业大学, 2020.
- [7] 兰丰. 基于时序卷积网络的煤炭价格预测方法研究[D]: [硕士学位论文]. 上海: 华东师范大学, 2022. <https://doi.org/10.27149/d.cnki.ghdsu.2022.004692>
- [8] 崔曦文, 牛东晓, 张潇丹, 等. 双碳目标下的煤炭价格预测与预警研究[J]. 智慧电力, 2022, 50(9): 16-21, 44.
- [9] 刘维曼. 我国碳排放权交易价格预测研究——以试点地区为例[D]: [硕士学位论文]. 南京: 南京邮电大学, 2022.
- [10] Wang, X., Mao, Y., Duan, Y., *et al.* (2022) *Frontiers in Environmental Science a Study on China Coal Price Forecast-*

- ing Based on CEEMDAN-GWO-CatBoost Hybrid Forecasting Model under Carbon Neutral Target. *Frontiers in Environmental Science*, **10**, 1014021. <https://doi.org/10.3389/fenvs.2022.1014021>
- [11] 张克非. 基于深度学习动力煤价格预测的选煤产品结构优化研究[D]: [硕士学位论文]. 徐州: 中国矿业大学, 2021.
- [12] 郭嘉宁. 动力煤价格中短期预测方法研究[D]: [硕士学位论文]. 北京: 北京邮电大学, 2021.
- [13] Cao, B., Wang, S., Bai, R., *et al.* (2023) Boundary Optimization of Inclined Coal Seam Open-Pit Mine Based on the ISSA-LSSVR Coal Price Prediction Method. *Scientific Reports*, **13**, 1-22.
- [14] 陈亮, 王震, 王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术, 2017(5): 8-11.