

中国碳排放区域分布特征、预测及差异化政策建议

于昊延, 冯建斌

辽宁科技大学电子与信息工程学院, 辽宁 鞍山

收稿日期: 2025年11月12日; 录用日期: 2025年12月10日; 发布日期: 2025年12月19日

摘要

全球气候变暖背景下, 中国“双碳”目标(2030年前碳达峰、2060年前碳中和)的实现需精准把握碳排放区域特征与未来趋势。针对中国碳排放“高维、非线性、时空异质”的核心特征, 以及现有研究方法单一、区域分类粗放、未充分解构时序特征的缺口, 本文构建HP-LSTM模型, 基于CEADS数据库2000~2020年30个省份47个行业的碳排放数据, 通过HP滤波分解排放序列的趋势与周期成分, 结合LSTM模型实现精准预测, 并与ARIMA模型进行对比验证。研究发现, 30个省份可划分为排放顶峰型、趋势增长缓慢型和持续增长型三类, 部分省份难以在2030年前达峰; 电力、蒸汽和热水生产供应业是碳排放主要贡献来源。基于预测结果, 本文提出差异化治理策略与动态监测机制的政策启示, 为中国“双碳”目标落地提供科学支撑。

关键词

碳排放, HP-LSTM模型, 区域分布特征, 排放预测, 差异化政策, “双碳”目标

Regional Distribution Characteristics, Prediction and Differentiated Policy Recommendations Policies for China's Carbon Emissions

Haoyan Yu, Jianbin Feng

School of Electronics and Information Engineering, University of Science and Technology Liaoning, Anshan Liaoning

Received: November 12, 2025; accepted: December 10, 2025; published: December 19, 2025

Abstract

Against the backdrop of global warming, the achievement of China's “dual carbon” goals (peaking

carbon emissions before 2030 and achieving carbon neutrality before 2060) requires an accurate grasp of the regional characteristics and future trends of carbon emissions. Addressing the core characteristics of China's carbon emissions—high-dimensionality, non-linearity, and spatial-temporal heterogeneity—as well as the gaps in existing research (e.g., single research methods, crude regional classification, and insufficient deconstruction of time-series characteristics), this study constructs an HP-LSTM model. Based on carbon emission data from 47 industries across 30 provinces in China (2000~2020) from the CEADs database, the model decomposes the trend and cyclical components of emission sequences through HP filtering, and combines the LSTM model to achieve accurate prediction, with comparative verification against the ARIMA model. The results show that the 30 provinces can be classified into three types: emission peak-reached type, slow trend growth type, and continuous growth type, with some provinces struggling to peak before 2030. The production and supply of electricity, steam, and hot water is the main contributor to carbon emissions. Based on the prediction results, this study proposes policy implications including differentiated governance strategies and dynamic monitoring mechanisms, providing scientific support for the implementation of China's "dual carbon" goals.

Keywords

Carbon Emissions, HP-LSTM Model, Regional Distribution Characteristics, Emission Prediction, Differentiated Policies, "Dual Carbon" Goals

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

全球气候变暖背景下, 国际能源署(IEA)数据显示 2023 年全球碳排放量达 36.8 亿吨历史峰值, IPCC 第六次评估报告(AR6)指出地球表面温度较工业革命前升高 1.1℃, 若维持当前排放趋势, 2040 年前将突破《巴黎协定》1.5℃控温阈值。中国作为全球最大碳排放国, “双碳”目标(2030 年前碳达峰、2060 年前碳中和)的实现需依托对区域排放特征的精准认知与未来趋势的科学预测。

中国碳排放数据具有“高维、非线性、时空异质”特征: CEADs 数据库显示, 全国 30 个省份的碳排放关联经济、能源、社会等 47 个行业维度, 存在显著多重共线性。传统研究多采用线性回归或 ARIMA 模型, 难以处理高维数据冗余与非线性时序特征; 同时, 区域间产业结构(如东部高技术产业 vs 中西部重工业)、能源结构(如北方煤炭依赖 vs 南方水电占比)差异显著, 亟需差异化治理方案。

现有碳排放研究: 国内研究侧重实证分析, 但多依赖单一模型, 缺乏高维数据系统解构[1][2]; 国外研究多采用复杂系统模型, 但较少结合深度学习捕捉时序非线性特征。

综上, 现有研究存在“方法单一化、区域分类粗放化、预测未解耦时序特征”的缺口, 本文通过 HP-LSTM 填补这一空白。数据主要来源于 CEADs [3]-[7]。

2. 模型搭建与预测评价

2.1. LSTM 模型理论基础

长短期记忆网络(Long Short-Term Memory, LSTM) [8]作为循环神经网络(Recurrent Neural Network, RNN)的特殊变体, 通过引入门控机制有效解决了传统 RNN 在处依赖时的梯度消失/爆炸问题。其核心结构包含三个关键门控单元:

遗忘门(Forget Gate): 决定细胞状态中需要保留或遗忘的信息, 数学表达式为:

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

输入门(Input Gate): 控制当前时刻新信息的更新量, 数学表达式为:

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

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

输出门(Output Gate): 调节细胞状态对外输出的信息量, 数学表达式为:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (5)$$

其中, σ 表示 sigmoid 激活函数, W 为权重矩阵, b 为偏置项。

2.2. HP-LSTM 模型结构设计与超参数设置

为提升模型对碳排放时序数据的拟合与预测能力, 本文构建了 HP-LSTM 模型, 分别对 HP 滤波分解后的趋势成分与周期成分进行建模预测。同时趋势 LSTM 训练和周期 LSTM 训练 epoch = 2000, 优化器使用 Adam, 学习率 0.001。模型结构及超参数设置如下表 1, 表 2:

Table 1. TrendLSTM network configuration

表 1. TrendLSTM 网络结构

模块名称	输入大小(特征维度)	输出大小(特征维度)
LSTM (堆叠一层) + Dropout (0.3)	1	128
FC + ReLU	128	64
FC + ReLU	64	32
FC	32	16
FC	16	1

Table 2. CycleLSTM network architecture

表 2. CycleLSTM 网络结构

模块名称	输入大小	输出大小
LSTM (堆叠四层) + Dropout (0.1)	1	64
FC + ReLU	64	32
FC + ReLU	32	16
FC	16	1

2.3. 时间序列分解方法

因 CO₂ 排放量时间序列包含长期趋势(工业化进程、能源结构转型)与短期波动(经济周期、政策冲击)。故对模型进行 HP 滤波[9]。HP 滤波通过最优化问题

$$y_t = \tau_t + c_t \quad (t = 1, 2, \dots, T) \quad (6)$$

$$\min_{\tau_t} \left\{ \sum_{t=1}^T (y_t - \tau_t)^2 + \lambda \sum_{t=2}^{T-1} [(\tau_{t+1} - \tau_t) - (\tau_t - \tau_{t-1})]^2 \right\} \quad (7)$$

将原始序列分解为趋势成分 τ_t 和周期成分 $c_t = y_t - \tau_t$ 。本文所使用的数据为 $Y = [3053.31, 3225.16, 3517.78, \dots, 10529.39, 10897.74, 10966.96]$ 共 21 个数据点, 建立 HP 滤波方程:

定义二阶差分矩阵 D 为:

$$D = \begin{bmatrix} 1 & -2 & 1 & 0 & \cdots & 0 \\ 0 & 1 & -2 & 1 & \cdots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & 1 & -2 & 1 \end{bmatrix}$$

$$Y = [3053.31, 3225.16, 3517.78, \dots, 10529.39, 10897.74, 10966.96]^T$$

$$\tau = [\tau_1, \tau_2, \tau_3, \dots, \tau_t]^T$$

其中目标函数可以表示为:

$$\min_{\tau} \left((Y - \tau)^T (Y - \tau) + \lambda \tau^T D^T D \tau \right) \quad (8)$$

对 τ 进行求导并令导数为零可以得到:

$$(I + \lambda D^T D) \tau = Y \quad (9)$$

$$\tau = (I + \lambda D^T D)^{-1} Y \quad (10)$$

将 Y 代入同时取 $\lambda = 6.25$ [10] 最终得到了趋势成分 τ 将 τ 代入 $c_t = y_t - \tau_t$ 得到对应的 c , 经过 HP 滤波后的图像以及对应的波动如图 1 所示:

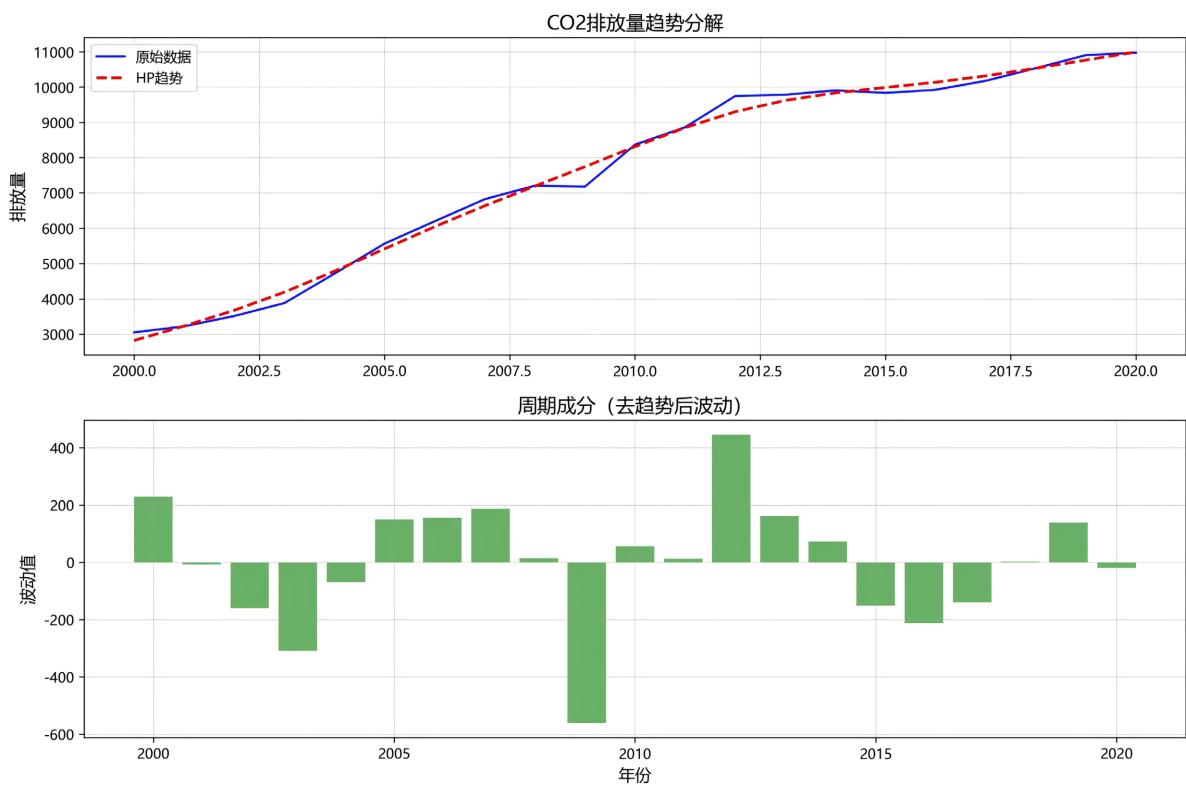


Figure 1. Decomposition of CO₂ emissions

图 1. CO₂ 排放量的分解

其中每个年份对应的 HP 滤波后的数据如表 3 所示:

Table 3. Data after HP Filtering (Unit: 10,000 tons)
表 3. HP 滤波后数据(单位: 万吨)

年份	CO ₂ 排放量(原始)	τ	c
2000	3053.31	2824.03	229.28
2001	3225.16	3233.19	-8.03
2002	3517.78	3677.63	-159.85
2003	3882.92	4191.37	-308.45
2004	4714.92	4783.88	-68.96
2005	5567.01	5417.14	149.87
2006	6197.89	6042.53	155.36
2007	6822.27	6634.49	187.78
2008	7205.22	7191.37	13.85
2009	7178.90	7740.40	-561.50
2010	8366.84	8310.92	55.92
2011	8859.29	8845.93	13.36
2012	9742.70	9297.00	445.70
2013	9778.95	9617.77	161.18
2014	9903.30	9830.43	72.87
2015	9831.56	9981.98	-150.42
2016	9918.46	10130.64	-212.18
2017	10172.43	10311.48	-139.05
2018	10529.39	10526.91	2.48
2019	10897.94	10757.99	139.95
2020	10966.96	10986.12	-19.16

可以看到在 2009 年时出现了最大的波动且为负值, 受全球金融危机影响, 我国整体发展受到影响导致 CO₂ 排放量下降, 也从侧面证明了 HP 滤波可以有效的提前显示出受某些因素影响的波动(如金融危机, 政策影响)。

2.4. 数据处理

在趋势成分数据上选择 Z-score 标准化, 周期成分数据标准化选择 MinMax 归一化(-1~1), Z-score 标准化公式为: $z = \frac{x - \mu}{\sigma}$ 。其中 μ 为 2000~2020 年 30 个省份的排放数据的均值, σ 为其标准差。

MinMax 归一化, 数学公式为: $x_{\text{norm}} = 2 * (x - x_{\text{min}}) / (x_{\text{max}} - x_{\text{min}}) - 1$, 在分离出的周期成分明显围绕零值上下震荡, 归一化到[-1, 1]可强化正负半周的对称特征。

不同周期的波动幅度差异被压缩, 模型更易捕捉波形模式而非绝对波动量级, 以此为基础搭建 LSTM 模型进行训练与预测, 采用自回归的方式预测 2021~2060 年的数据用于测试模型的泛化能力。

选择 5 年作为滑动窗口创建数据集, 趋势成分与周期成分预测使用相同模型结构, 使用均方误差损

失函数(MSELoss), 优化器选择 Adam, 使用在训练过程中验证损失最小的模型对我国 2021~2060 年的碳排放进行预测, 预测形式采用自回归模型。图 2 是该模型对未来的预测和训练以及验证时的预测值与真实值的对比。

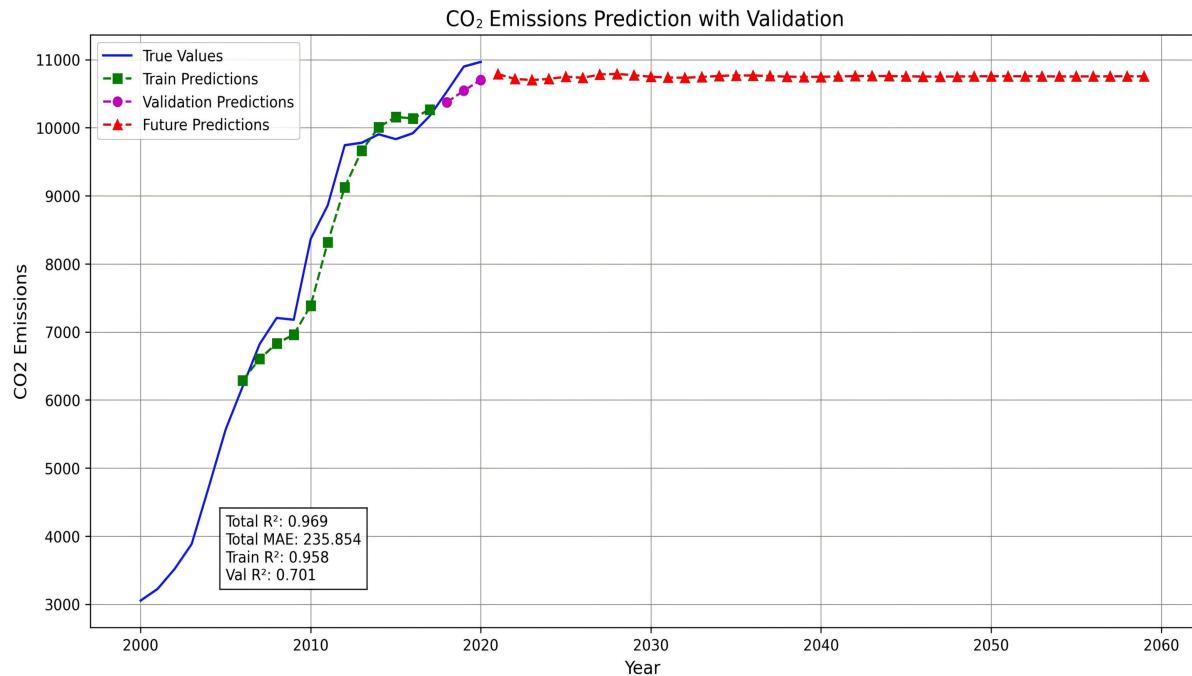


Figure 2. Comparison of actual and predicted values for HP + LSTM model
图 2. HP + LSTM 真实值预测值的对比

同时根据该模型预测结果, 在 2030 年左右我国的碳排放确实没能达到承诺在 2030 年达到碳顶峰的要求, 受到疫情原因模型预测增长缓慢, 直到 2030 年在该模型上依旧为增长态势, 则实际意义更是如此, 因此我国在节能减碳的政策依旧要加大力度。

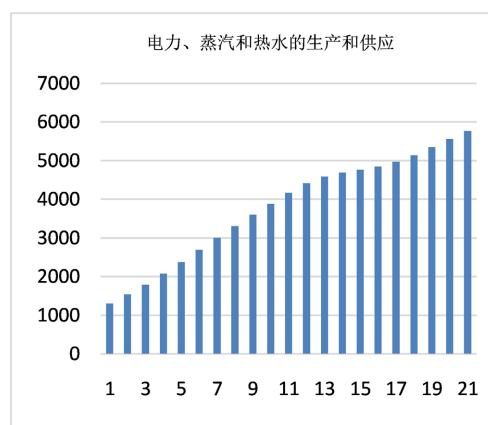


Figure 3. Trend component chart of the production and supply of electricity, steam and hot water
图 3. 电力、蒸汽和热水的生产和供应趋势成分图

在对全国 47 个行业的分析中, 通过对电力、蒸汽和热水的生产和供应的经过 HP 滤波后, 如图 3 为电力、蒸汽和热水的生产和供应经 HP 滤波后的趋势成分, 发现其趋势成分依旧为不断增大, 且对 CO₂

的排放做主要贡献源头, 以 2019 年和 2020 年为例子分别占有: 51.63% 以及 52.42%, 因此针对这一部分的行业要重点减排。

2.5. 省级区域 HP 分解预测与评价

将 30 个省份的原始数据进行 HP 滤波分解。

从结果上来看各省市的 CO_2 排放与城市群分布以及地理邻近性有较大关系, 京津冀城市表现为排放总量共同增长以及河北省增速不断增大, 长三角城市群以上海市作为中心城市进行产业升级, 成渝地区则开始与周边省市排放量同步下降, 长江中下游地区呈现增长态势[11], 东北地区辽宁增长迅猛, 从分类上来看, 在趋势成分的分析中将这 30 个省份分为三类, 第一类为已经达到 CO_2 排放顶峰型, 第二类为趋势增长缓慢型, 第三类为持续增长型, 如下表 4 所示:

Table 4. Classification of HP trend components

表 4. HP 趋势成分分类

类型	代表省份
CO_2 排放顶峰型	北京、上海、河南、吉林、四川等
趋势增长缓慢型	安徽、湖南、贵州、黑龙江、海南等
持续增长型	福建、新疆、广东、河北、山西等

使用 HP + LSTM 模型对第二类与第三类省份进行 CO_2 排放的预测, 结果显示: 河北、江西、宁夏、重庆, 这些省份的预测如图 4 所示均不能在 2030 年前达到 CO_2 排放顶峰, 针对这些省份相较于全国碳排放的政策制定上要更有力度。建议制定差异化奖罚制度以控制排放, 同时要结合省份特征如(河北的产业结果, 宁夏的能源结构)合理制定措施。

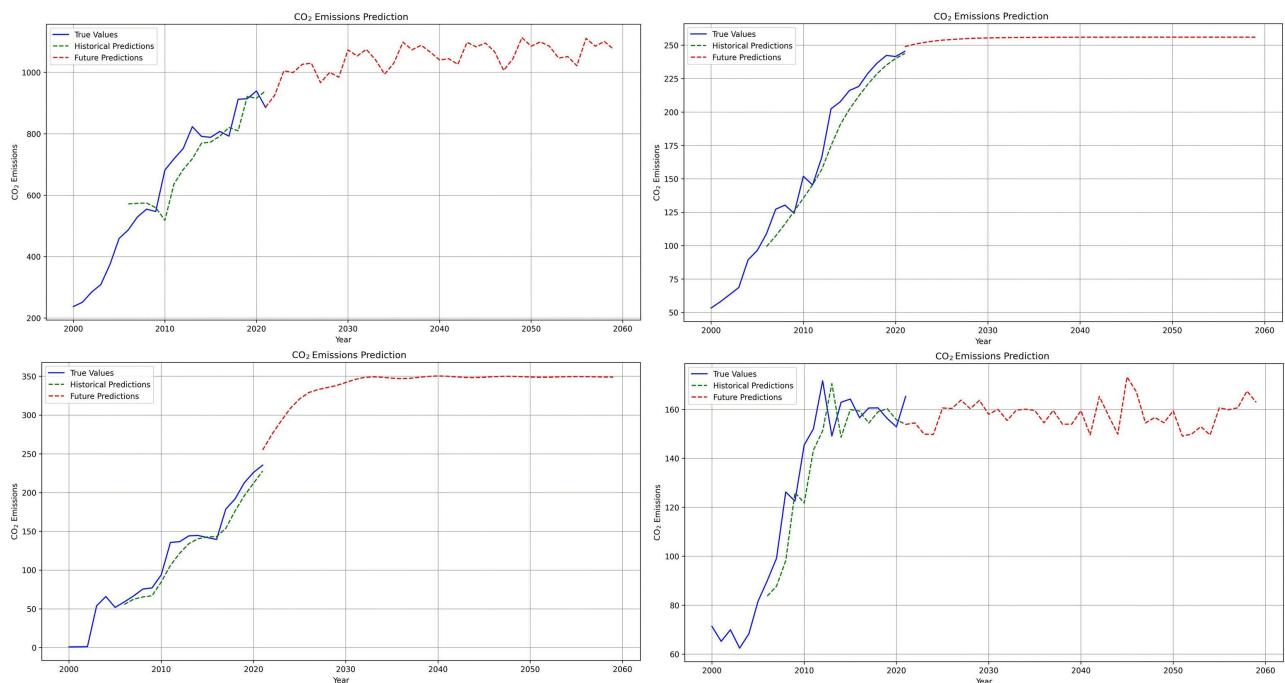


Figure 4. Forecast chart of four provinces

图 4. 四个省份预测图

3. 模型对比

以 2000~2020 年作为数据样本, 选择 ARIMA [12] (1, 1, 1) 作为模型来对原始时间序列进行预测, 最终得到的图 5 如下所示:

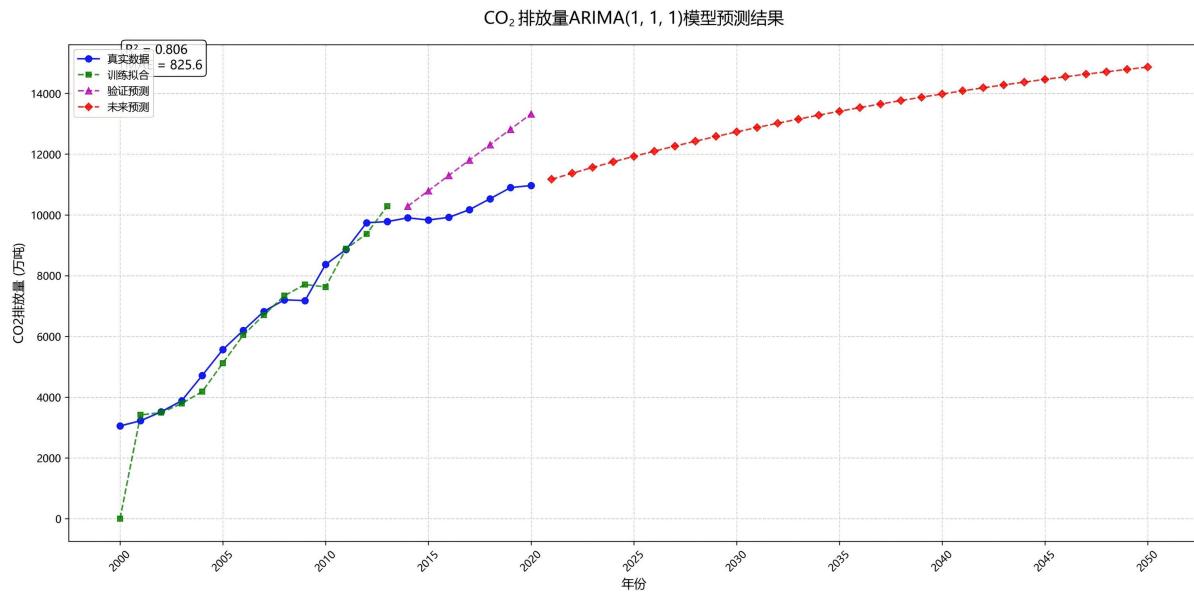


Figure 5. Forecast of ARIMA

图 5. ARIMA 的预测

可以看到验证预测部分明显偏离真实数据, 导致了 R^2 的下降以及 MAE 的增加, 该模型针对 2000~2020 年 30 个省份 CO₂ 总的排放数据泛化能力极差, 而且通过该模型对未来的预测来看, 我国的碳排放将一直不断增加直到 2060 年但在 2020 年之前我国已经有相关的减排政策而且随着时间的推进成效越来越大, 可见 ARIMA 模型的预测结果并不准确, 因此传统的 ARIMA 模型基于历史的 CO₂ 排放数据仅能对时间规律进行探讨无法捕捉潜在的因子, 具有一定的局限性。

4. 政策建议

差异化治理策略: 高排放区域需聚焦产业结构优化与技术升级, 中西部省份应推动农业与工业协同低碳发展。

动态监测机制: 结合模型预测结果建立碳排放动态预警系统, 及时调整政策响应。

基金项目

2025 年辽宁省大学生创新创业训练计划项目经费支持, 项目编号 S202510146040。

参考文献

- [1] 蔡博峰, 曹丽斌, 雷宇, 等. 中国碳中和目标下的二氧化碳排放路径[J]. 中国人口·资源与环境, 2021, 31(1): 7-14.
- [2] 高子茗, 吕洋. 限行政策出台、交通行为塑造与碳减排效应[J/OL]. 管理评论, 1-15. <https://doi.org/10.14120/j.cnki.cn11-5057/f.20250414.001>, 2025-12-16.
- [3] Shan, Y., Guan, D., Zheng, H., Ou, J., Li, Y., Meng, J., et al. (2018) China CO₂ Emission Accounts 1997-2015. *Scientific Data*, 5, Article No. 170201. <https://doi.org/10.1038/sdata.2017.201>
- [4] Shan, Y., Huang, Q., Guan, D. and Hubacek, K. (2020) China CO₂ Emission Accounts 2016-2017. *Scientific Data*, 7,

- Article No. 54. <https://doi.org/10.1038/s41597-020-0393-y>
- [5] Guan, Y., Shan, Y., Huang, Q., Chen, H., Wang, D. and Hubacek, K. (2021) Assessment to China's Recent Emission Pattern Shifts. *Earth's Future*, **9**, e2021EF002241. <https://doi.org/10.1029/2021ef002241>
- [6] Shan, Y., Liu, J., Liu, Z., Xu, X., Shao, S., Wang, P., *et al.* (2016) New Provincial CO₂ Emission Inventories in China Based on Apparent Energy Consumption Data and Updated Emission Factors. *Applied Energy*, **184**, 742-750. <https://doi.org/10.1016/j.apenergy.2016.03.073>
- [7] Xu, J., Guan, Y., Oldfield, J., Guan, D. and Shan, Y. (2024) China Carbon Emission Accounts 2020-2021. *Applied Energy*, **360**, Article 122837. <https://doi.org/10.1016/j.apenergy.2024.122837>
- [8] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [9] 王丹. 基于 HP 滤波和相似性度量的新方法在时间序列中的应用[D]: [硕士学位论文]. 南充: 西华师范大学, 2019.
- [10] 张连城, 韩蓓. 中国潜在经济增长率分析——HP 滤波平滑参数的选择及应用[J]. 经济与管理研究, 2009(3): 22-28+86.
- [11] 于卓立, 李卓然. 基于面板数据的省级碳排放模型构建及预测分析[J]. 经济研究导刊, 2023(22): 38-40.
- [12] 张巨峰. 基于 ARIMA 模型的甘肃省碳排放预测分析[J]. 山西大同大学学报(自然科学版), 2024, 40(4): 31-36.