

# 中国碳排放预测的时空演变特征及驱动因素分析

## ——基于ARIMA-BP神经网络算法的研究

赵桑林<sup>1\*</sup>, 李哲彤<sup>2</sup>, 邓浩<sup>1</sup>, 游星<sup>3</sup>, 佟嘉昂<sup>4</sup>, 袁炳坤<sup>5</sup>, 胡邛昊<sup>1</sup>, 曾子豪<sup>1</sup>

1 湖南财政经济学院工程管理学院, 湖南长沙, 410205

2 湖南财政经济学院数学与统计学院, 湖南长沙, 410205

3 湖南财政经济学院经济学院, 湖南长沙, 410205

4 复旦大学经济学院, 上海杨浦 200433

5 中南大学能源科学与工程学院, 湖南长沙, 410083

\*联系作者: 1654952984@qq.com

收稿日期: 2024年8月21日

### 摘要

研究采用2000—2021年中国30个省份能源耗费数据, 基于ARIMA模型和BP神经网络模型, 测算并预测了2000—2035年中国30个省份碳排放总量, 采用ArcGIS和标准椭圆差对时空演变特征进行了可视化分析, 进一步利用LMDI模型对影响碳排放的驱动因素进行了分解。研究表明: (1) 2000—2035年, 我国碳排放总量逐年递增, 但碳排放增长率逐渐降低; 碳排放结构为“第二产业>居民生活>第三产业>第一产业”, 第二产业和居民生活碳的增长速度较快, 第一产业和第三产业变化趋势较小; (2) 我国各省碳排放的空间分布呈现典型的“东部>中部>西部”, “北部>南部”的分布格局, 碳排放中心有向西北移动的趋势; (3) 数字经济、产业结构高级化以及新质生产力发展水平较高的地区碳排放相对较少, 具有显著的组别差异效应; (4) 能源消费强度效应是驱动碳排放不断增长主要因素, 人均GDP和能源消费结构效应是抑制碳排放的主要因素, 产业结构和人口规模效应的影响相对较小。基于研究结论, 从能源结构、产业结构、新质生产力和数字经济等方面提出了政策建议。

### 关键词

碳排放; ARIMA-BP模型; LMDI分解; 时空演变; 标准椭圆差

## Analysis of Spatiotemporal Evolution Characteristics and Driving Factors of Carbon Emission Prediction in China— A Study Based on

文章引用: 作者 1, 作者 2, 作者 3. 文章标题[J]. 统计学与应用, 2024, \*(\*) : \*\*\*-\*\*\*.  
DOI: 10.12677/\*\*.2024.\*\*\*\*

# ARIMA-BP Neural Network Algorithm

Zhao Sanglin<sup>1\*</sup>, Li Zhetong<sup>2</sup>, Deng Hao<sup>1</sup>, You Xing<sup>3</sup>, Tong Jiaang<sup>4</sup>, Yuan Bingkun<sup>5</sup>, Hu Zhihao<sup>1</sup>, Zeng Zihao<sup>1</sup>

<sup>1</sup>School of Engineering Management, Hunan University of Finance and Economics, Changsha, Hunan 410205

<sup>2</sup>School of Mathematics and Statistics, Hunan University of Finance and Economics, Changsha, Hunan 410205

<sup>3</sup>School of Economics, Hunan University of Finance and Economics, Changsha, Hunan 410205

<sup>4</sup>School of Economics, Fudan University, Yangpu, Shanghai 200433

<sup>5</sup>School of Energy Science and Engineering, Central South University, Changsha, Hunan 410083, China

Received: 2024.8.21

## Abstract

Based on the energy consumption data of 30 provinces in China from 2000 to 2021, the total carbon emissions of 30 provinces in China from 2000 to 2035 were measured and predicted based on the ARIMA model and BP neural network model. The results show that: (1) From 2000 to 2035, China's total carbon emissions will increase year by year, but the growth rate of carbon emissions will gradually decrease; The carbon emission structure is "secondary industry > residents' daily life > tertiary industry > primary industry", the secondary industry and residents' living carbon growth rate is relatively fast, and the change trend of the primary industry and the tertiary industry is small. (2) The spatial distribution of carbon emissions in various provinces in China presents a typical distribution pattern of "eastern > central > western" and "northern > south", and the carbon emission center has a tendency to move to the northwest. (3) The carbon emissions of the regions with higher levels of digital economy, industrial structure and new productivity are relatively small, which has a significant group difference effect. (4) The energy consumption intensity effect is the main factor driving the continuous growth of carbon emissions, the per capita GDP and energy consumption structure effect are the main factors inhibiting carbon emissions, and the impact of industrial structure and population scale effect is relatively small. Based on the research conclusions, policy suggestions are put forward from the aspects of energy structure, industrial structure, new quality productivity and digital economy.

## Keywords

CARBON EMISSIONS; ARIMA-BP MODEL; LMDI DECOMPOSITION; SPATIOTEMPORAL EVOLUTION;

Copyright © 2024 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

### 1.1 研究背景与意义

#### 1. 研究背景

首先，中国在碳减排方面承担着重要责任。我国强调“要积极稳妥推进碳达峰碳中和”，2000年以来我国碳排放总量持续快速上升，2023年的碳排放总量为126亿吨，占全球碳排放374亿吨的三分之一，是全球最大的碳排放国。（数据来源：中国能源统计年鉴）[1]

其次，碳排放区域差异显著。2023年碳排放最高的省份为山西，最低为青海，华东地区是最大的碳排放区域，占全国比重的30%左右，各省碳排放呈现显著的差异，实现碳排放市场的均衡协调是重要途径。

总之，如何控制碳排放总量，优化碳排放结构是实现“双碳”目标的必然选择。因此，基于以上现实问题，本文结合ARIMA时间序列分析与BP神经网络算法，对全国及各省的碳排放进行测算并预测，并对我国碳排放的空间演变特征进行了分析，采用LMDI对驱动因素进行分解，研究结论对我国不同地区因地制宜制定科学合理的减排政策提供决策参考。

## 2. 研究意义

(1) 更加全面的了解我国碳排放的区域分布特征和演变趋势。本文测度并预测了2000—2035年的碳排放总量，分析了不同区域、不同行业碳排放数据的历史变化轨迹和未来发展趋势，刻画了我国碳排放的空间分布特征，为政府制定更加精准的减排政策提供科学依据。

(2) 厘清了碳排放变化的具体驱动因素。通过LMDI模型，将影响碳排放变化的因素分解成能源消费结构、能源消费强度、人均GDP效应、人口规模效应、产业结构效应六个因素，分析各个因素对碳排放的促进和抑制作用，有助于更加清晰地认识到碳排放时空演变特征的深层次原因。

(3) 为各地区因地制宜的制定减排政策提供参考。针对不同区域、行业、产业结构、数字经济以及新质生产力的差异，作了分组分析。基于研究结论，为处于不同发展阶段的地区，因地制宜制定更加合理的减排政策提供科学依据。

## 1.2 国内外研究现状

### 1. 碳排放测度方法

目前主流的碳排放预测模型主要包括四种，一是STIRPAT模型。周带华等（2024）通过引入人口、经济、能源结构等因素，利用STIRPAT模型对江苏省工业领域的碳排放影响因素进行了深入分析，并预测了碳达峰的情况。[2]陆妍霏等（2024）在STIRPAT模型的基础上，结合岭回归模型对安徽省的碳排放时空格局演变与碳达峰路径预测。二是LEAP模型。LEAP模型具有结构灵活、数据需求较小以及能够反映技术进步和能源效率等特点。程澍（2023）基于LEAP模型对吉林省的能源消费结构、能源需求和碳排放趋势进行了预测。另一方面，陈传敏等（2024）利用LEAP模型对电网企业的碳排放情景进行了预测，并分析了减排潜力。三是LSTM模型。王燕（2005）基于LSTM模型通过挖掘历史碳排放数据中的时间依赖性和周期性规律，对未来碳排放趋势进行了预测。胡剑波等（2022）在LSTM模型基础上，结合ARIMA模型，得到了碳排放强度预测结果。四是ARIMA模型。[3]王南等（2023）将指数平滑法模型与ARIMA模型相结合预测了行业碳排放趋势，这种方法结合了时间序列的长期趋势和短期随机变化，从而提高了预测的准确性。

### 2. 碳排放驱动因素

碳排放驱动因素包括能源消费、能源技术以人口和经济发展三个方面。刘志红（2018）在其研究中详细测算了中国区域能源消费的碳排放，研究得出，能源强度、能源结构和产业结构是影响碳排放的重要因素，能源强度的降低清洁能源的推广和产业结构的升级是降低碳排放的关键途径。Zhu等人（2015）的研究则着重于减少中国化石燃料燃烧和水泥生产过程中的碳排放估计，通过改进燃烧技术和生产流程，可以有效降低碳排放。Suli等（2018）基于中国1997-2015年的碳排放账户，得出人口规模和经济发展是影响碳排放的重要因素。随着人口的增长和经济的快速发展，碳排放量呈现出逐年上升的趋势。[4]然而，通过提高能源效率和推广清洁能源，可以在一定程度上减缓碳排放的增长速度。

### 3. 文献评述

上述STIRPAT、LEAP、LSTM和ARIMA等碳排放测度方法在处理复杂非线性和时间序列深层模式时均存在局限，碳排放驱动因素未将能源、人口与经济置于统一框架分析。因此，本文构建了“ARIMA-BP神经网络模型”，不仅具有ARIMA模型在时间序列分析方面的优势，还能够通过BP神经网络模型处理非线性关系，提高预测的准确性和可靠性，更全面地捕捉中国碳排放时空特征，基于LMDI模型揭示其驱动因素，为碳排放管理和减排政策提供科学支持。[5]

## 1.3 研究思路与方法

### 1. 研究思路

本文总体按照“问题提出—理论准备—模型构建—实证分析—政策建议”的研究框架，具体按照如下逻辑思路

第一，对碳排放测算和影响因素的相关文献进行梳理。通过对碳排放、碳排放预测、双碳目标以及时间序列与神经网络算法在碳排放研究中的应用现状的梳理，为后续研究奠定基础。

第二，对碳排放的相关概念和理论模型进行阐述。对本文涉及的碳排放及测算的相关概念进行界定，对ARIMA模型、BP神经网络理论、LMDI碳排放因素分解模型进行分析，为模型构建提供理论支撑。

第三，对变量及数据来源进行说明，构建碳排放预测模型。首先，说明变量的选择和数据来源。然后，基于模型的适用性和预测精度，构建ARIMA—BP神经网络模型，确保模型能够准确预测和分析碳排放的时空演变特征。

第四，对我国各省碳排放总量及结构的时空演变特征及驱动因素进行分析。首先，基于ARIMA—BP神经网络模型对各产业、居民生活消费以及整体的碳排放进行预测，进一步分析数字经济的减碳效应以及碳排放的区域、产业结构以及新质生产力的组别差异。其次，在预测能源消费强度、各类能源占比以及人口规模与经济等碳排放影响因素的基础上通过LMDI碳排放因素分解方法，定量分析各因素对碳排放的贡献度，为政策制定提供科学依据。

最后，提出减碳的政策建议。总结全文研究结论，有针对性的提出政策建议。

### 2. 研究方法

文献分析与归纳演绎相结合。系统梳理碳排放测算、时间序列分析理论及神经网络算法的相关研究，明确相关研究的逻辑发展脉络，辨析当前研究的重点、不足，思考潜在的改进方向。

定性与定量分析相结合。定性分析主要探究双碳目标下碳排放的预测与优化策略，定量分析主要用来分析碳排放的时空演变特征。

理论模型与实证分析相结合。基于实际数据构建碳排放预测模型，并对模型进行检验与比较，对预测结果进行深入剖析，提出针对性的优化策略与建议。

## 2 碳排放预测的理论基础

### 2.1 碳排放测算概念界定

碳排放是指在生产、运输、使用及回收某产品时所产生的温室气体排放，碳排放因子法是常用的碳排放测算方法。本文基于联合国政府间气候变化专门委员会官网发布的指南和全国各省级单位推荐的碳排放因子法，对三大产业（第一产业、第二产业、第三产业）能源消费碳排放进行测算。[6]具体公式如下：

$$EC = \sum_{i=1}^3 \sum_{j=1}^6 E_{ij} r_j \times \frac{44}{12} \quad (1)$$

公式 (1) 中各变量解释如表1:

Table 1.Explanation of carbon emission measurement variables

表 1 碳排放测算变量解释

变量名	变量解释与赋值	单位
$EC$	能源二氧化碳排放量	万 tCO <sub>2</sub>
$i$	能源消费类别	\
$E_{ij}$	第 $i$ 产业中第 $j$ 种能源消费量	千克标准煤
$r_j$	第 $j$ 种能源的碳排放系数	tC/10 <sup>12</sup> J
44/12	碳与二氧化碳转换系数	\

注：由于数据缺失，计算能源碳排放时未包括消费部门电力、热力碳排放。

## 2.2 碳排放预测的理论模型

### 1.ARIMA 模型

ARIMA模型被广泛运用于各类时间序列数据分析和建模。碳排放总量是典型的时间序列数据，本文采用ARIMA模型进行初步预测。ARIMA模型本质是将非平稳的时间序列转化为平稳时间序列，建立一个因变量对滞后值以及随机误差项当前值和滞后值进行回归的模型。具体公式如下：

$$y_t = \mu + \sum_{i=1}^p \gamma_i y_{t-1} + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2)$$

公式 (2) 中  $y_t$  为当期值， $y_{t-1}$  前一期值， $\mu$  为常数项， $p$  为阶数， $\gamma$  为自相关系数， $\varepsilon$  为误差项， $q$  为当前误差与前几项误差的关系， $\theta$  为系数。

### 2.BP 神经网络模型

BP神经网络是一种多层的前馈神经网络，其主要的特点是信号是前向传播的，而误差是反向传播的。对于含两个隐含层的神经网络模型，参考胡占占等（2021）的研究，BP神经网络的过程主要分为两个阶段，第一阶段是信号的前向传播，从输入层经过隐含层，最后到达输出层；第二阶段是误差的反向传播，从输出层到隐含层，最后到输入层，依次调节隐含层到输出层的权重和偏置，输入层到隐含层的权重和偏置。具体流程见图1：[7]

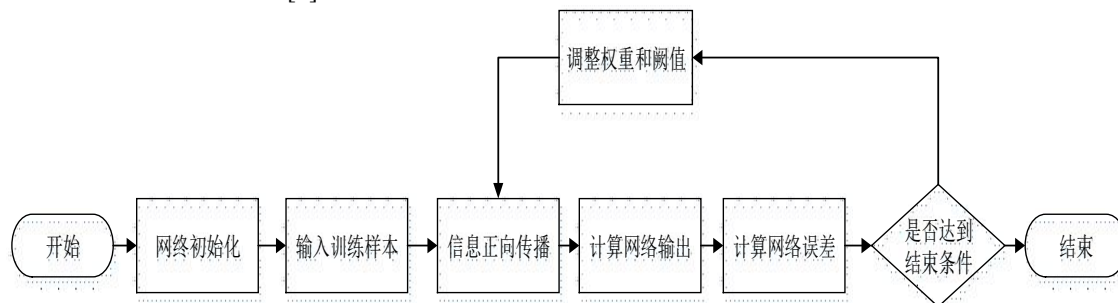


Fig.1 Flow chart of BP neural network model algorithm

图 1 BP 神经网络模型算法流程图

### 3.LMDI 碳排放因素分解模型

LMDI模型将碳排放分解为能源消费结构、碳排放系数、能源消费强度、产业结构、人均GDP、人口规模六个因素。能源消费碳排放公式可改写如下：

$$C = \sum_{i=1}^3 \sum_{j=1}^6 \frac{E_{ij}}{E_i} \frac{C_{ij}}{E_{ij}} \frac{E_i}{G_i} \frac{G_i}{G} \times P = \sum_{i=1}^3 \sum_{j=1}^6 s_{ij} \times f_{ij} \times e_i \times n_i \times r \times p \quad (3)$$

公式 (3) 中的变量及相关解释见表2。

Table 2 Explanation of variables in the formula of carbon emissions from energy consumption

表 2 能源消费碳排放公式变量解释

变量名	变量解释与赋值	单位
$P$	人口规模	万人
$G$	GDP	亿元
$E_{ij}$	第 $i$ 产业中第 $j$ 种能源消费量	千克标准煤
$C_{ij}$	第 $i$ 产业中第 $j$ 种能源碳排放量	万吨CO <sub>2</sub>
$s_{ij}$	第 $i$ 产业中第 $j$ 种能源的消费比例	%
$f_{ij}$	第 $i$ 产业中第 $j$ 种能源的碳排放系数	\
$e_i$	第 $i$ 产业的能源消费强度	\
$n_i$	第 $i$ 产业的 GDP 比例	%
$r$	人均 GDP	亿元/万人

为研究碳排放量的来源与影响因素，将LMDI分解公式转换为线性公式：

$$\Delta C = \Delta C_s + \Delta C_f + \Delta C_e + \Delta C_n + \Delta C_r + \Delta C_p \quad (4)$$

公式 (4) 中的变量解释见表3。碳排放因子基本保持不变，所以不存在碳排放效应，即  $\Delta C_f = 0$ 。

进而可测度每年的各因素效应：

$$\Delta C_s = \sum_{i=1}^3 \sum_{j=1}^6 w(C_{ij}^{t-1}, C_{ij}^t) \ln \frac{s_{ij}(t)}{s_{ij}(t-1)} \quad (5)$$

$$\Delta C_e = \sum_{i=1}^3 \sum_{j=1}^6 w(C_{ij}^{t-1}, C_{ij}^t) \ln \frac{e_{ij}(t)}{e_{ij}(t-1)} \quad (6)$$

$$\Delta C_n = \sum_{i=1}^3 \sum_{j=1}^6 w(C_{ij}^{t-1}, C_{ij}^t) \ln \frac{n_{ij}(t)}{n_{ij}(t-1)} \quad (7)$$

$$\Delta C_r = \sum_{i=1}^3 \sum_{j=1}^6 w(C_{ij}^{t-1}, C_{ij}^t) \ln \frac{r_{ij}(t)}{r_{ij}(t-1)} \quad (8)$$

$$\Delta C_p = \sum_{i=1}^3 \sum_{j=1}^6 w(C_{ij}^{t-1}, C_{ij}^t) \ln \frac{p_{ij}(t)}{p_{ij}(t-1)} \quad (9)$$

其中：

$$w(C_{ij}^{t-1}, C_{ij}^t) = \begin{cases} \frac{c_{ij}^t - c_{ij}^{t-1}}{\ln(c_{ij}^t / c_{ij}^{t-1})}, & C_{ij}^t \neq C_{ij}^{t-1} \\ C_{ij}^t \text{ 或 } C_{ij}^{t-1}, & C_{ij}^t = C_{ij}^{t-1} \end{cases} \quad (10)$$

### 3.数据及模型构建

#### 3.1 变量与数据来源

##### 1.数据来源

本文研究的能源相关数据主要来源于《中国能源统计年鉴》，GDP、产业以及人口等数据来自《中国统计年鉴》以及各省统计年鉴，碳排放因子来源于国际能源署碳排放计算的具体参数指标，对于部分缺失数据，在相关政府统计网站采取手动收集方式进行补充。为了避免计算重复，能源平衡表内加工转换以及损耗的能源量不计入总量计算。

##### 2.变量说明

首先将产值分类为第一产业，第二产业和第三产业<sup>1</sup>，计算每个产业的单位GDP能耗，两者相乘得到各产业能源消耗量。本文取前十年碳排放因子的平均值作为2022—2035年的碳排放因子值，使用各产业能源消耗量乘以碳排放因子，再乘以转换系数并求和得到碳排放总量。因此，本文涉及到的变量主要包括三大产业能源消耗量，各产业产值，人口与经济变量，主要变量的描述性统计见表4。

#### 3.2 ARIMA—BP 神经网络模型构建

首先，使用ARIMA模型对数据进行预测，并获得预测误差序列。其次，建立一个包含1个神经元和3个神经元的2层隐含层BP神经网络。将误差数据按照时间顺序传入神经网络，输入节点设置为4，输出节点设置为1。通过滚动窗口的方式，将上一期的误差继续传入神经网络，作为输入的一部分，不断修正并预测模型。[8]最后，运用组合模型对碳排放强度的变动进行预测。具体步骤如下：

##### 1.ARIMA 模型构建

ARIMA模型的构建分为以下三个过程：

(1) 时间序列的平稳性检验。本文采用ADF方法检验时间序列的平稳性，伴随概率的t统计量为-1.86~-1.90，无法在5%的显著性水平下拒绝存在单位根的原假设，对各序列取1阶差分得到DCI序列，再次进行ADF检验，伴随概率t统计量为-2.97~-2.99，在1%的统计性水平上拒绝了单位根假设，经过1阶差分后的碳排放强度序列是平稳的。

(2) 确定ARIMA模型的阶数P。本文采用自相关(AC)系数与偏自相关(PAC)系数，依据AIC等定阶原则。根据AC和PAC图像及数据与检验表综合分析采取(1, 1, 0)模型。

(3) 参数估计与诊断检验。检验模型参数的显著性是为了确定哪些参数对模型的解释能力是有效的。有效性检验可以帮助确定模型是否能够准确地预测或解释数据。同时需要检验残差序列是否为白噪声序列，以确保模型的残差没有遗漏的信息或结构。

##### 2.BP 神经网络模型构建

由于碳排放强度受到经济因素和碳排放活动的复杂影响，很难完全考虑到所有影响因素的变化。因此，在对趋势进行拟合后，本文采用BP神经网络模型对ARIMA模型中潜在的遗漏信息进行进一步挖掘，更准确的对碳排放强度变动进行预测。具体步骤为：

##### (1) 神经网络模型选择与结构设计

①网络初始化。根据输入样本确定输入维数，确定输入层和激励函数设置g(x)为Sigmoid函数。表达式如下：

$$g(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

1 第一产业包括农林消费部门，第二产业包括工业消费部门和能源消费部门，第三产业包括建筑消费部门和交通消费部门。

## ②隐含层和输出层的输出

BP神经网络包括三层，即输入层、输出层和输出层，设输入层、隐含层和输出层节点个数为 $m$ 、 $n$ 和 $s$ 。本文设置五个输入层两个隐藏层。

隐含层输出公式如下所示：

$$H_k = f(\sum_{i=1}^m x_i \cdot w_{ik} - a_k) \quad (12)$$

其中， $i=1,2,\dots,m$ ， $k=1,2,\dots,n$ ， $w_{ik}$ 是输入层到隐含层的连接权重系数， $a_k$ 是偏置。

输出层的输出公式为：

$$Q_j = \sum_{k=1}^n (H_k w_{kj}) - b_j \quad (13)$$

其中， $j=1,2,\dots,s$ ； $w_{kj}$ 是隐含层到输出层的连接权重系数， $b_j$ 是其偏置。

## ③计算误差

误差是指输入层的输出与期望输出之间的差，公式为

$$e_j = \hat{Q}_j - Q_j \quad (14)$$

其中 $\hat{Q}_j$ 表示期望输出值， $Q_j$ 为真实值。

## ④更新权重

输入层到隐含层的权值更新公式：

$$w_{ik} = w_{ik} + \theta H_k \cdot (1 - H_k) \cdot x_i \cdot \sum_{j=1}^s w_{kj} e_j \quad (15)$$

$$w_{kj} = w_{kj} + \theta H_k e_j \quad (16)$$

## ⑤更新阈值

输入层到隐含层的阈值更新公式：

$$a_k = a_k + \theta H_k \cdot (1 - H_k) \cdot x_i \cdot \sum_{j=1}^s w_{kj} e_j \quad (17)$$

$$b_j = b_j + e_j \quad (18)$$

## ⑥判断结束条件

误差在合理范围内则结束计算，否则重新计算隐含层和输出层，返回步骤二。

## (2) 训练与测试数据集划分

将2000—2021年的21年以及ARIMA模型预测的2022—2035年的15年数据，共36年数据中三大产业产值、单位产业产值能耗、各产业能耗的前30%作为模型测试集，70%作为模型的训练集。

## (3) BP神经网络拟合效果

本文采用均方误差MSE、RMSE、拟合优度 $R^2$ 等来评估模型效果。MSE取值越小，模型准确度越高， $R^2$ 越接近于1模型准确度越高。

## 3.ARIMA—BP神经网络模型优势

将ARIMA模型与BP神经网络模型相结合，相较于单独的预测估计，更适合本文碳排放预测分析：

(1) 复杂模式捕捉能力。传统的时间序列模型对数据质量敏感，对数据的质量要求较高，如果数据存在缺失值、异常值或噪声较大等问题，会影响模型的拟合效果和预测精度。神经网络具有很强的非线性映射捕捉能力，能够捕捉复杂的时间序列模式和趋势。BP神经网络可以逼近任意的非线性映射关系，且学习算法属于全局逼近算法，具有较强的泛化能力，能很好的解决ARIMA模型的不足，可以更好地处理非线性映射关系和长期依赖性。[9]

(2) 多特征处理。神经网络可以同时处理多个特征作为输入，而传统的时间序列模型通常只考虑单变量的时间序列。神经网络能够更好地利用与时间序列相关的其他特征来提高预测性能。

(3) 长期预测能力。神经网络的递归结构（如长短期记忆网络或门控循环单元）使其能够更好地处理长期预测问题。相对于传统的时间序列模型，神经网络在长期预测上可能具有更好的性能。

## 4. 碳排放预测分析

### 4.1 中国碳排放的总体特征分析

#### 1. 全国碳排放总量预测分析

中国总体碳排放量的变动趋势如图8所示。碳排放总量为三大产业碳排放与居民生活消费碳排放之和组成。2000—2035年，我国碳排放总量逐年递增，由25.75亿吨增长到213.51亿吨，增长了829%。碳排放增长率逐渐降低，从2000年的4.8%降低到2035年的1.7%，2018年之前，我国碳排放总量增速较为缓慢，2018年之后增速较快。碳排放总量持续增加涉及经济、能源、生活方式等多方面原因，尤其是能源需求量的持续增加，导致碳排放不断增长。同时，由于我国坚持贯彻绿色发展理念，推动减污降碳协同增效，煤炭清洁化低碳化高效利用、风能太阳能等新能源发展迅速，绿色低碳技术大力研发，碳排放增长率逐渐降低。[10]

#### 2. 各产业碳排放预测分析

由图8可知，2000—2035年，第一产业碳排放由0.44亿吨增长到0.92亿吨，增长208%，第二产业碳排放由20.70增长到142.78亿吨，增长690%，第三产业碳排放由0.73亿吨增长到6.63亿吨，增长了910%，由此可见，第二产业碳排放量最高，第一产业碳排放量最低，第二产业的碳排放量逐渐增加，趋势变幅较大，第一产业和第三产业碳排放量逐渐增加，趋势变化较小。经济发展进入新时代，转向高质量发展阶段，产业结构进一步转型升级，第二产业比重将呈现持续稳步下降的态势，中国正在努力推动制造业的升级，向高端制造业转型。这将涉及到先进制造技术的研发和应用，如人工智能、大数据、机器人技术等。随着科技的不断发展，农业现代化将成为未来的主要趋势，农业现代化将大大提高农业生产效率，并提升农产品的质量和竞争力。在新一代产业转型升级、新型城镇化和居民消费品质升级等背景下，我国第三产业服务业发展迎来新机遇，在经济发展中的主导产业进一步凸显。[11]

#### 3. 居民生活消费碳排放预测分析

2000—2035年，我国居民生活碳排放量快速增长，从最低的3.88亿吨增长到最高的63.17亿吨，增长1642%。随着城镇化的推进，居民碳排放总量呈现显著上升的状态，城镇化表现为低人口密度扩张，促使碳排放不断增长。中国正处于城市化快速发展阶段，人们对生活质量的要求逐渐提高，各种能源商品及服务的消费支出相应增加，碳排放总量不断增加。居民生活碳排放量的增加说明应提倡低碳生活，推广公共交通、鼓励步行和自行车出行，推动绿色建筑，建设节能环保的建筑，降低建筑能耗，推动实现消费升级的同时，减少生活消费碳排放总量，促进绿色发展。[12]

### 4.2 中国碳排放的空间分布特征

由图9可知，我国各省碳排放的空间分布呈现典型的“东部>中部>西部”，“北部>南部”的分布格局，说明我国碳排放的区域差异明显。具体来看，2000—2035年，我国各省碳排放不断增加，2000年碳排放较多的省份主要集中在东部地区（图9.a），2021年碳排放较多的省份主要为东部和北部省份（图9.b），2035年这种发展趋势更加明显（图9.c）。由标准椭圆差分析可得，我国的碳排放中心有向西北移动的趋势。说明我国电力供应和重工业向西北迁移的同时，末端治理设施处理能力未能及时跟上。[13]

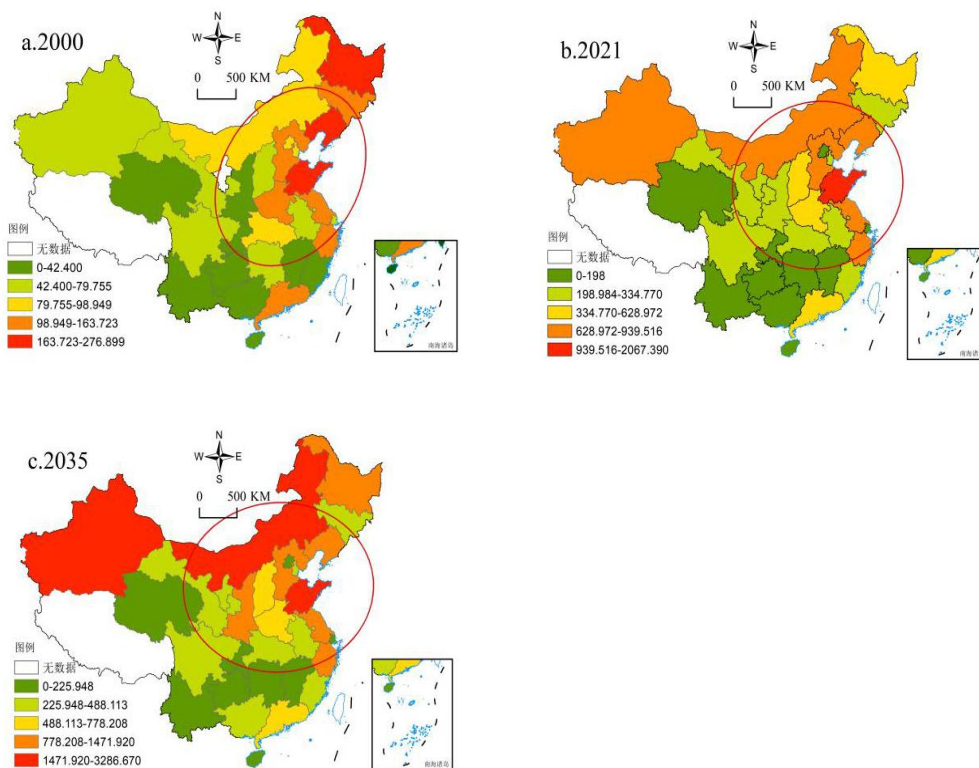


Fig. 2 Spatial distribution of carbon emissions in each province from 2000 to 2035

图 2 2000—2035 年各省碳排放历年空间分布图

注：该图基于自然资源部标准地图服务网站下载的审图号为 GS(2019)1822 号的标准地图制作，底图无修改

本文进一步将各省份碳排放分为2000-2021年和2022-2035年两个时间段，分别求各省份碳排放的平均值。

2000—2021年，我国各省平均碳排放量中山东省最高，平均碳排放量为9.4亿吨，海南省最低，平均碳排放量为0.12亿吨，山东省平均碳排放量是海南省的78.25倍。由于山东省的产业结构以重工业为主，如钢铁、化工、建材等，这些行业在生产过程中需要大量的能源，且能源利用效率较低，导致二氧化碳排放量大，并且山东省的能源消费结构以煤炭为主。虽然近年来山东省在逐步调整能源结构，加大天然气、可再生能源等清洁能源的利用力度，但在短时间内，煤炭消费的主导地位仍难以改变。[14]其次山东省拥有大量的高耗能、高排放（“两高”）行业企业，如火电、钢铁、化工等，这些企业是二氧化碳排放的主要来源。海南岛的碳排放量相对于其他地区比较低，主要原因是海南岛的经济结构以服务业和农业为主，工业相对较少，且旅游业作为经济支柱，海南岛政府采取了一系列环保措施，比如鼓励使用清洁能源，限制高污染工业的进入，开展植树造林等环保活动。此外，海南岛还有丰富的海洋资源，发展海洋经济也是降低碳排放的途径之一。尽管如此，海南岛作为全球环境问题共同治理中的一个重要参与者，仍在不断推进绿色发展，加强碳排放管控和减缓气候变化的影响。

我国各省平均碳排放量，山东省最高，平均碳排放量为27.21亿吨，青海省最低，平均碳排放量为0.93亿吨，并且其他省份平均排放量相比2000年到2021年都有所增加，且变动趋势较大，其原因是我国工业化和经济增长导致了能源消耗的增加，尤其是燃煤和石油等化石燃料的使用，这些能源的燃烧会释放大

ChinaXiv:202408.00129v2

量的二氧化碳。我国人口不断增长，城市化进程迅速加速。导致了建筑物、道路和基础设施的增加，需要更多的能源供应。同时，城市中交通量和工业活动也会导致二氧化碳排放量的增加。其中江苏，浙江在全国排名下降变化较大，内蒙古，新疆上升变化较大。其原因在于江苏、浙江作为发达地区，能源利用效率高，光伏发电、生物质能等高新技术使碳排放量得到了极大的减小。新疆和内蒙古在近年来经济快速发展，导致能源消耗增加，尤其是制造业和电力煤气等部门大量消耗化石能源，低能源利用效率和落后的生产工艺导致能源消费强度的上升，增加了碳排放。城镇化进程中的城市人口增长、人均能源消耗上升以及城市建设投资增加等，都消耗了大量能源，从而提升了碳排放量。[15]

### 4.3 中国碳排放的组别效应分析

#### 1. 数字经济的减碳效应

为了探究数字经济的减碳效应，将2000-2035年各省碳排放量按不同数字经济发展水平分成高低组，进行差异分析。参照赵涛等（2020）的做法，以2022年数字经济水平的均值为标准，将全国30个省分为高数字经济发展水平省和低数字经济发展水平省<sup>2</sup>。由表5可知，数字经济发展高水平省份组与数字经济发展低水平省份组在碳排放上的均值分别为334.127和384.774；采用Welch's方差检验，P值小于0.05，说明不同数字经济发展水平省份在碳排放上存在显著差异。从平均碳排放水平来看，高数字经济发展水平组的碳排放量明显低于低数字经济发展水平组，表明数字经济发展水平较高的地区具有更明显的减碳效应。主要原因是在数字经济发展较高的地区，由于技术创新、产业结构优化和政策推动等多种因素的综合作用，数字经济的减碳效应更为明显。[16]

Table 3 The decarbonization effect of the digital economy

表3 数字经济的减碳效应

组别	样本量	平均值	标准差	Welch's 方差检验
高数字经济	324	334.127	318.049	F=3.997 P=0.046**
低数字经济	756	384.774	499.073	
总计	1080	369.581	452.882	

#### 2. 碳排放的区域差异

本文将各省分成东、中、西部三大区域，对区域碳排放强度差异进行分析。由表6可知，不同区域的碳排放强度存在显著差异。东部地区的平均碳排放强度为1.69%，在三个区域中最低。东部地区的经济发展最先进，产业结构更加优化，高新技术产业、服务业等低碳产业占比较高，这些产业通常对能源利用效率较高，因此碳排放强度较低。中部地区的平均碳排放强度为2.15%，略高于东部地区。中部地区正处于工业化快速发展阶段，这些产业在生产过程中通常需要消耗大量的化石能源，导致碳排放强度相对较高。随着中部地区经济结构的逐步优化和转型升级，碳排放强度逐渐降低。西部地区的平均碳排放强度为2.27%，是三个区域中最高的。这与西部地区的经济发展相对滞后，产业结构不够优化，更加依赖传统的高碳产业，如煤炭、石油化工等因素有关。

Table 4 Regional differences in carbon emissions

表4 碳排放的区域差异

组别	样本量	平均值	标准差	Welch's 方差检验
东部	242	1.693	1.264	F=10.354 P=0.000***
中部	176	2.150	1.569	

2 高数字经济发展水平组为上海、北京、天津、广东、江苏、浙江、海南、福建、陕西，低数字经济发展水平组为云南、内蒙古、吉林、四川、宁夏、安徽、山东、山西、广西、新疆、江西、河北、河南、湖北、湖南、甘肃、贵州、辽宁、重庆、青海、黑龙江。

组别	样本量	平均值	标准差	Welch's 方差检验
西部	242	2.266	1.748	
总计	660	2.025	1.556	

### 3.碳排放的产业结构差异

本文参照干春晖等（2011），将第三产业与第二产业产值的比值作为产业结构高级化的衡量指标，并以均值为标准将各省分为高低两组。由表7可知，高低组的平均碳排放强度分别为1.681和2.196，说明不同的产业结构高级化发展水平的省份在碳排放强度上存在显著差异。当产业结构高级化水平偏低时，可能更多地依赖于传统制造业、重工业等高碳产业，这些产业在生产过程中通常需要消耗大量的化石能源，导致碳排放强度较高。而产业结构高级化水平较高的地区，其中高新技术产业、服务业等低碳产业占据主导地位，这些产业通常对能源的需求较低，利用效率较高，且倾向于使用清洁能源技术，因此碳排放强度相对较低。

Table 5 Differences in the industrial structure of carbon emissions

表 5 碳排放的产业结构差异

组别	样本量	平均值	标准差	方差检验
低	441	2.196	1.588	F=16.388 P=0.000***
高	219	1.681	1.432	
总计	660	2.025	1.556	

### 4.碳排放的新质生产力差异

参照宋佳（2024）的研究，构建新质生产力指标体系，以均值为标准，将各省历年新质生产力发展水平分成高低两组。由表8可知，不同新质生产力区域的碳排放强度存在显著差异，高低组的平均碳排放强度为1.069和1.832，说明新质生产力发展水平较高的地区，碳排放强度相对较低。新质生产力是指创新起主导作用，摆脱传统经济增长方式、生产力发展路径，具有高科技、高效能、高质量特征，符合新发展理念的先质生产力质态，本质是先进生产力。因此，碳排放的新质生产力差异主要是由于通过技术创新力度、生产要素的优化配置程度、产业结构升级以及政策导向这四大因素影响，新质生产力发展水平高的地区能够有效降低碳排放强度，实现绿色低碳发展。

Table 6 New qualitative productivity differences in carbon emissions

表 6 碳排放的新质生产力差异

组别	样本量	平均值	标准差	Welch's 方差检验
高	98	1.069	0.731	F=69.910 P=0.000***
低	262	1.832	1.358	
总计	660	2.025	1.556	

## 5.碳排放驱动因素分析

### 5.1 碳排放驱动因素预测

#### 1.能源消费强度预测

三大产业碳排放强度MSE波动范围为0到0.633，回归系数较高接近于1，说明模拟预测效果较好，预测数据具有可信度。2000—2035年，我国产业能源消费强度为“第二产业>第三产业>第一产业”，其中第一产业能源强度由0.0039下降到0.0001，第二产业能源强度由0.0525下降到0.0041，第三产业能源强度由0.0024下降到0.0003，第二产业下降幅度最大，第一产业和第三产业的能源强度下降幅度较小。说明，我国能源消费强度的降低，主要集中在第二产业，虽然我国能源强度与欧美国家相比还存在一定差距，但是随着我国产业结构调整、能源结构多元化以及工业化水平不断地提高，能源强度仍有一定的下降空间。

## 2. 能源占比预测

能源占比为某产业能源消费量占总能源消费量比值，反映能源使用情况、能源消费结构以及产业结构变化，在决定碳排放上起到重要作用。2010—2035年，中国第一产业的煤炭能源使用占比降低，油品能源使用和电力能源使用占比提升，逐步实现从以煤为主的能源结构向多元化能源结构的转变。第二产业电力能源和天然气能源使用占比增加，煤炭，油品，热力能源使用占比减小，说明我国能源结构调整和技术升级。第三产业的热力能源、煤炭能源、油品能源使用占比降低，天然气能源和电力能源使用占比增加。随着清洁能源比重的提升，传统能源热力消耗的碳排放也在下降。

## 3. 人口规模与经济预测

我国人口规模预测MSE平均值为24.63，且人口预测回归系数  $R=1$ ，人均GDP预测MSE平均值为0.07855，且人均GDP预测回归系数  $R^2=0.99$ 。说明模型预测效果好。假设2024-2035年GDP增长率恒定为4%。由图14可知，2000—2023年，人口规模数量逐渐增加，从2000年的126743万人增长到2023年的140769万人，2024—2035年，人口规模数量逐渐减小。我国人口规模在2023年达到最大值，由于经济压力，生活成本等多方面压力，导致人们生育意愿下降，以及人口老龄化等因素导致了我国人口规模逐渐减小。

2000—2035年，由于经济发展、科技创新的推动以及稳定的社会环境等因素的共同作用，人均GDP呈现不断增长的趋势，从2000年的7942元，到2035年的164556元。2000—2035年，人均GDP增长率从9.7%到11.7%再到4.5%。由于新冠疫情的影响，导致当年人均GDP增长率下降到5.3%，此后我国经济快速恢复，人均GDP增长率达到5.9%，此后人均GDP增长率逐渐增加并趋于稳定。

## 5. 2LMDI 碳排放因素分解

利用LMDI分解方法对我国2000—2035年碳排放因素进行分解，能源强度、能源结构、产业结构、经济发展、人口规模的逐年效应与累计效应如图

由逐年分解结果可知，2000—2035年，能源消费强度效应变化较大，大部分年份对碳排放的增长具有促进作用，最高时为16816.83，且贡献最大。随着我国产业结构的调整、能源结构多元化以及工业化水平不断地提高，能源消费强度仍有下降空间。能源消费结构效应呈现波动起伏变化趋势，对碳排放增长影响相对较小，2020年以前对碳排放具有促进作用，之后主要呈现抑制作用，最高时为-10528.96。产业结构逐年效应变化较小，对碳排放增长影响较小，2019年份前对碳排放主要为抑制作用，之后的年份主要为促进作用。人均GDP对碳排放增长主要为抑制作用，最高时为-14812.49，且贡献率较高。人口规模效应对碳排放的影响较小。




Fig. 3 LMDI decomposition effect of carbon emissions from 2000 to 2035

图 3 2000—2035 年碳排放 LMDI 分解效应

## 6. 结论和建议

### 6.1 研究结论

(1) 利用ARIMA—BP神经网络模型预测了2000—2035年各省碳排放总量。总体上我国碳排放总量逐年递增，但随着产业结构的不断优化，碳排放增长率逐渐降低。从碳排放的具体结构变化来看，碳排放总量大小依次为“第二产业>居民生活>第三产业>第一产业”，其中第二产业和居民生活碳的增长速度较快，第一产业和第三产业变化趋势较小。

(2) 采用ArcGIS刻画我国各省碳排放的空间分布特征。各省碳排放的空间分布呈现典型的“东部>中部>西部”，“北部>南部”的不均衡分布格局，体现出碳排放在不同经济发展阶段性特征。由标准椭圆差分析可得，2000—2035年的碳排放中心有向西北移动的趋势。

(3) 基于新发展理念，将各省碳排放划分成不同组，进行组别效应的异质性分析。数字经济、产业结构高级化以及新质生产力发展水平较高的地区碳排放相对较少，具有显著的组别差异效应，说明产业结构和新型业态在减排作用中的重要性。

(4) 基于LMDI分解方法对2000-2035年能源碳排放的驱动因素进行分析。我国能源消费强度“第二产业>第三产业>第一产业”，碳排放强度降低主要集中在第二产业，能源结构逐步实现以煤为主向多元化能源结构的转变；能源消费强度效应是驱动碳排放不断增长的主要因素，人均GDP和能源消费结构效应是抑制碳排放的主要因素，人口规模效应在刚开始的年份对碳排放的增长具有促进作用，但后面大部分年份都为抑制作用，产业结构效应的影响相对较小。

### 6.2 政策建议

#### 1. 优化能源消费结构

一是进一步完善能源消耗总量和强度调控，重点控制化石能源消费，优化能源消费结构，逐步转向碳排放总量和强度“双控”制度。二是统筹产业结构调整、污染治理、生态保护、应对气候变化，通过优化能源系统、推广节能技术和设备等方式，大力发展清洁能源，推动以水电、核电等为代表的清洁能源，降低能源消耗，协同推进降碳、减污、扩绿、增长。三是有效落实节能优先方针，把节约集约利用能源资源贯穿于经济社会发展全过程、各领域和各环节，树立勤俭节约的消费观，加快形成能源节约型社会。

#### 2. 推进产业结构高级化

首先，推进农业现代化，推广绿色农业技术，鼓励农民采用保护性耕作、精准农业技术和生物技术等，提高农业生产的效率和质量，降低碳排放。优化农业产业结构，合理调整种植业、养殖业的结构，推动农业产业的转型升级。其次，推进制造业高端化，发展绿色制造技术，鼓励企业采用先进的生产技术和设备，提高生产效率和产品质量，降低能耗和碳排放。优化产业结构，加快淘汰落后产能和高污染产业，发展新兴产业和绿色产业，提高制造业的绿色低碳水平。最后，大力发展第三产业，发展绿色服务业，加强服务业的能源管理。

#### 3. 发展新质生产力

新质生产力发展水平高的地区碳排放强度较低，实现绿色低碳发展，新质生产力是降低碳排放的关键。通过推动创新技术和可持续发展，实现更高效、更清洁的生产方式减少碳排放；通过科技创新，提高生产效率，如积极培育新能源、新材料、先进制造、电子信息等战略性新兴产业，降低我国资源消耗和环境污染，实现可持续发展；基于碳排放的区域不平衡现状，建立和完善碳交易市场，为碳排放权交易提供平台。政府应出台相关政策，明确碳交易的规则 and 标准，为碳交易提供法律保障，加强对碳交易市场的监管力度。

#### 4. 推动数字化转型

数字经济发展水平高的地区碳排放强度低，发展数字经济是降低碳排放的重要途径，数字化转型可以减少对传统产业的依赖，降低能耗和碳排放。优化供应链管理，降低能源消耗，建设数字基础设施，如建设绿色数据中心，推广使用节能设备和技术，提高数据中心的能效水平。同时，利用可再生能源为数据中心供电，降低碳排放。推广5G和物联网技术，通过5G和物联网技术，实现设备间的互联互通，提高能源利用效率，减少不必要的能源消耗和碳排放。

#### 参考文献

- [1] Yuli S, Dabo G, Heran Z, et al. China CO<sub>2</sub>/sub emission accounts 1997-2015[J]. Scientific data, 2018,5(1):170201.
- [2] Zhu L, Dabo G, Wei W, et al. Reduced carbon emission estimates from fossil fuel combustion and cement production in China[J]. Nature, 2015, 524(7565):335-8.
- [3] 陈传敏,何宇,蔡萱,等.基于 LEAP 模型的电网企业碳排放情景预测及减排潜力分析[J/OL].华北电力大学学报(自然科学版),1-8[2024-04-27].
- [4] 程澍.基于 LEAP 模型的吉林省能源需求及碳排放研究[D].吉林大学,2023.
- [5] 干春晖,郑若谷,余典范.中国产业结构变迁对经济增长和波动的影响[J].经济研究,2011,46(05):4-16+31.
- [6] 胡剑波,罗志鹏,李峰.“碳达峰”目标下中国碳排放强度预测—基于 LSTM 和 ARIMA-BP 模型的分析[J].财经科学,2022,(02):89-101.
- [7] 胡占占,陈传法,胡保健.基于时空 XGBoost 的中国区域 PM<sub>2.5</sub> 浓度遥感反演[J].环境科学学报,2021,41(10):4228-4237.
- [8] 刘志红.中国区域能源消费碳排放测算、收敛及脱钩研究[M].北京:中国财政经济出版社,2018:29-43.
- [9] 陆妍霏,宣蔚,赵力伟.安徽省碳排放时空格局演变与碳达峰路径预测-基于 STIRPAT 扩展模型和岭回归模型[J].地域研究与开发,2024,43(01):146-152+173.
- [10] 宋佳,张金昌,潘艺.ESG 发展对企业新质生产力影响的研究—来自中国 A 股上市企业的经验证据[J/OL].当代经济管理:1-13[2024-04-30].
- [11] 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.
- [12] 王燕.应用时间序列分析[M].北京:中国人民大学出版社,2005.
- [13] 闫庆友,李雪婷.基于 GDIM 的山东省能源消费碳排放与经济发展脱钩研究[J].山东工业技术,2023,(02):3-13.
- [14] 周带华,马婷婷,李强,等.基于 STIRPAT 模型的江苏省碳排放影响因素与碳达峰预测研究——以工业领域为例[J].商展经济,2024,(06):146-150.
- [15] 朱娇.基于 DPSO-BP 模型中国八大工业部门碳排放达峰情景预测研究[D].中国矿业大学,2023.
- [16] 赵涛,张智,梁上坤.数字经济、创业活跃度与高质量发展—来自中国城市的经验证据[J].管理世界,2020,36(10):65-76.