

基于 LASSO-GSWOA-KELM 模型的石化行业碳排放预测研究

余博, 王尹*, 柴俊松, 乔子恒, 孙野
(南京财经大学金融学院, 江苏南京 210023)

摘要:石化行业是碳排放的重要来源,构建精确预测石化行业碳排放的模型对我国实现“双碳”目标具有重要意义。通过采用 STIRPAT 模型和 LASSO 回归筛选影响碳排放的关键因素,并利用全局搜索策略的鲸鱼优化算法优化 KELM 模型以提高预测精度,构建了 LASSO-GSWOA-KELM 模型。实证结果显示,该模型预测精度超过其他模型,证明该模型为准确预测石化行业碳排放提供了有效工具。预测结果显示,我国石化行业碳排放将继续增长但增速放缓,预计在 2029 年达峰值。针对研究结果,提出了发展 CCUS 技术、淘汰落后产能、建立绿色金融体系等建议,为石化行业减排提供理论和决策支持。

关键词:石化行业;碳排放预测;鲸鱼优化算法;KELM;机器学习

中图分类号:X322

文献标志码:A

文章编号:0253-4320(2024)S2-0378-08

DOI:10.16606/j.cnki.issn0253-4320.2024.S2.067

Prediction of carbon dioxide emission in petrochemical industry based on LASSO-GSWOA-KELM model

YU BO, WANG Yin*, CHAI Jun-song, QIAO Zi-heng, SUN Ye

(School of Finance, Nanjing University of Finance and Economics, Nanjing 210023, China)

Abstract:The petrochemical industry is a significant source of carbon dioxide emission. Constructing a model for accurately predicting carbon dioxide emission in the petrochemical industry is of significance for China to achieve “carbon dioxide emission peaking and carbon neutrality” goals. LASSO-GSWOA-KELM model is constructed through adopting STIRPAT model and LASSO regression to screen key factors affecting carbon dioxide emission, and optimizing KELM model by the whale optimization algorithm, which utilizes global search strategy, to improve prediction accuracy. Empirical results show that the prediction accuracy of this model surpasses those of other models, proving that this model provides an effective tool for accurately predicting carbon dioxide emission in the petrochemical industry. The prediction results show that the carbon dioxide emission in China’s petrochemical industry will continue to grow but at a slowing pace, and is expected to peak in 2029. According to the study results, it is suggested to develop CCUS technology, eliminate outdated production capacity, and establish a green financial system, providing theoretical and decision-making support for emissions reduction in the petrochemical industry.

Key words: petrochemical industry; carbon emission prediction; whale optimization algorithm; KELM; machine learning

在全球气候变暖背景下,减少温室气体排放成为国际共识,尤其是二氧化碳(CO₂)排放控制。我国作为全球生态文明建设的重要参与者、贡献者、引领者,面对气候变化挑战,提出了“双碳”目标:2030年前碳排放达峰,2060年前实现碳中和。与此同时,我国工业部门面临“三高”问题(高能耗、高投入和高污染),科学合理预测未来工业碳排放对于实现“双碳”承诺至关重要。石化行业作为主要能源消耗和温室气体排放源对实现全球减排目标至关重要。据统计,目前我国石化行业每年二氧化碳排放

量约为 4.2 Gt,在我国二氧化碳总排放量中占比 4%,因此,石化行业二氧化碳减排和资源化利用已成为人们关注的焦点。

石化行业在本文指的是石油天然气开采业、石油加工及炼焦加工业、化学纤维制造业、化学原料及化学制品制造业、橡胶制品业、塑料制品业 6 个子部门的总和。石化行业作为全球能源消耗和碳排放的主要来源之一,其在节能减排及应对气候变化的努力中扮演着关键角色,拥有实现节能减排巨大潜力。本文通过构建 LASSO-GSWOA-KELM 模型对我国

收稿日期:2024-04-18;修回日期:2024-07-26

作者简介:余博(1989-),男,博士,副教授,硕士生导师,主要研究方向为宏观金融管理、金融风险与金融计量;王尹(2002-),男,本科生,研究方向为金融学,通讯联系人,wangyin0602@gmail.com。

石化行业碳排放量进行预测分析,以把握我国石化行业低碳转型的进程,探寻我国能否尽早实现碳达峰这一重要任务,同时为我国石化行业可持续发展提供理论与决策参考,以期为加快我国碳减排进程贡献力量。

1 国内外文献综述

1.1 国外石化行业研究现状

国外对碳排放影响因素的研究开始较早,通过将目标变量分解为几个影响因素的组合来研究不同因素对碳排放量的影响程度^[1]。Brizga 等^[2]以 3 个波罗的海沿岸国家为目标,采用 SDA 方法对影响 CO₂ 排放量的因素进行分解,得出对二氧化碳排放量起主要推动作用的因素是最终需求。Kim 等^[3]采用了多区域投入产出(MRIO)分析和结构分解分析(SDA)方法,研究 2000—2014 年间韩国贸易的碳排放量的增长驱动因素,研究表明,从贸易区域来看,中国与韩国的贸易增长对其进出口贸易隐含碳排放的上升有显著影响;结构分析显示,排放强度的提升抑制了排放增长,而需求的增加则推动了排放的上升。在碳排放预测的研究中,Tudor 等^[4]通过指数平滑状态空间模型(ETS)、霍尔特-温特斯模型(HW)、BATS/TBATS 模型等一系列方法,得出大气中温室气体(GHG)的释放是全球变暖现象的一个主要(也可能是最重要的)因素,并表明了巴林并未减少其 CO₂ 排放,并且无法满足其根据多哈修正案对京都议定书的假定义务。Rahman 等^[5]通过 ARIMA 模型对孟加拉国二氧化碳排放量进行了建模和预测,得出该模型具有所有选择标准度的最小值,在解释数据序列的变异性 and 预测能力方面表现出了良好的性能,并预测出孟加拉国 2016、2017、2018 的二氧化碳排放量。Thio 等^[6]基于 EKC 假设和 STIRPAT 模型分析了 10 个国家的碳排放驱动因素,得出影响温室气体排放的最主要因素是人均收入,而人口、能源使用、信息通信技术出口和进口是碳排放水平较高的关键影响因素。Sem 等^[7]通过运用 ARIMA 模型预测印度生铁制造业所产生的能源消耗和温室气体排放,以印度生铁制造组织月度能源消耗和温室气体排放数据作为 ARIMA 模型的输入数据,通过选择最佳的 ARIMA 模型来分析当前能源消耗和温室气体排放的趋势,以助推生铁制造这一能源密集型产业的发展。

1.2 国内石化行业研究现状

我国对碳排放的研究大多为对碳排放影响因素

的研究和对碳排放量的预测。在筛选影响因素方面,张巍^[8]通过应用 STIRPAT 模型对陕西省的碳排放进行分析,得出调整和优化能源消费结构、减少能源的消耗强度是降低碳排放量的核心策略。赵金辉等^[9]通过运用 LASSO 模型筛选出能源结构为影响河南省碳排放的关键因素,强调了在河南省减少碳排放的过程中,调整和优化能源使用结构的重要性。在碳排放预测方面,胡振等^[10]通过 BP 神经网络算法,将能够反映城市家庭消费模式的指标作为模型的神经网络输入层,将计算得到的城市家庭消费碳排放作为模型的神经网络输出层,建立了西安市家庭消费碳排放模型。高金贺等^[11]通过应用遗传算法(GA)优化的支持向量回归(SVR)模型,对北京市交通运输部门的碳排放量进行了预测分析,得出在 2020—2023 年期间,北京市交通运输相关的碳排放总量将持续增长,尽管增速有所放缓,但碳排放的压力仍然显著。王文佳等^[12]通过 GWO-LSTM 模型对辽宁省工业碳排放量进行了预测与分析,得出人口数量、城市化、能源消耗、人均工业 GDP、工业开放程度与碳排放量的关系。

综上,在碳排放预测领域,现有的碳排放研究在方法论上存在几个关键的局限性。首先,缺乏对选取指标之间相互关系的深入分析,未能有效地揭示不同因素对碳排放影响程度的差异性;其次,多采用单一的、固定的增长率进行未来碳排放量的预测,未能充分反映现实世界的动态变化和复杂性。针对以上问题,本文构建了 LASSO-GSWOA-KELM 模型来对石化行业的碳排放进行分析与预测,采用 STIRPAT 模型和 Pearson 相关性分析进行变量初筛,通过 LASSO 回归模型选取出 8 个影响因素,构建基于 GSWOA 改进的 KELM 预测模型,进而对 1998—2021 年的中国石化行业碳排放量进行预测与分析。

2 研究方法 with 原理

2.1 石化行业碳排放预测模型基本原理

2.1.1 LASSO 回归模型

LASSO 回归模型是一种用于数据降维的高效技术,能够有效地将非显著性变量系数降至零,提高模型的效率和预测准确性。这种方法同时适合于处理线性模型和非线性模型,如碳排放量预测等^[13],适用于石化行业碳排放影响因素的筛选。参数估计定义式见公式(1)。

$$\beta_{\text{LASSO}} = \operatorname{argmin} \left\{ \|y - \sum_{j=1}^p X_j \beta_j\|^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (1)$$

式中: λ 为正则化参数; β_j 为第 j 个预测变量的系数; p 为预测变量的总数; y 为响应变量向量, 是一个 $n+1$ 的向量, 其中 n 是样本数量。

2.1.2 全局搜索策略的鲸鱼优化算法

全局搜索策略的鲸鱼优化算法具体优化方式如下: 受粒子群优化算法的启发, 引入惯性权重 ω 优化位置更新环节, 该惯性权重会随着迭代次数增加而增加, 不断扩大最优解的影响力。选用迭代次数 t 构成的自适应惯性权值见公式(2)。

$$\omega(t) = 0.2 \cos[(\pi/2) \cdot (1 - t/t_{\max})] \quad (2)$$

由于 \cos 函数在 $[0, \pi/2]$ 范围内的特性, 初始阶段较小的权值使得个体更倾向于探索新的区域, 而后阶段较大的权值使得个体更容易被最优解吸引, 从而加速收敛。改进后的位置更新公式见公式(3)、(4)。

$$X(t+1) = \begin{cases} \omega(t)X^*(t) - A \cdot |C \cdot X^*(t)|, p < 0.5 \\ \omega(t)X^*(t) + D \cdot e^{bl} \cos(2\pi l), p \geq 0.5 \end{cases} \quad (3)$$

$$X(t+1) = \omega(t)X_{\text{rand}(t)} - A \cdot |C \cdot X_{\text{rand}(t)} - X(t)| \quad (4)$$

在螺旋搜索模型中, 将参数改为随着迭代次数改变的动态变量, 以增强对未知区域的探索能力。新螺旋位置更新公式见式(5)。

$$\begin{cases} X(t+1) = \omega(t)X^*(t) + bD \cdot e^l \cos(2\pi l) \\ b = e^{5 \cdot \cos[\pi \cdot (1 - t/t_{\max})]} \end{cases} \quad (5)$$

引入的参数 b 可以动态调整螺旋形状, 能够更加精确地找到最优解。

现有算法更新位置时, 会以更新频率低的最优位置为目标, 导致搜索效率较低。通过引入邻域扰动策略, 可以随机搜索最优位置附近, 提高算法收敛速度与精度。邻域扰动公式见式(6)。

$$\bar{X}(t) = \begin{cases} X^*(t) + 0.5 \cdot \text{rand1} \cdot X^*(t), \text{rand2} < 0.5 \\ X^*(t), \text{rand2} \geq 0.5 \end{cases} \quad (6)$$

式中: rand1 和 rand2 为 $[0, 1]$ 之间均匀产生的随机数; \bar{X} 为生成的新位置。

对于生成的邻域位置, 采用贪婪的策略判断是否保留, 公式见式(7)。

$$X^*(t) = \begin{cases} \bar{X}(t), f(\bar{X}(t)) < f(X^*(t)) \\ X^*(t), f(X^*(t)) \leq f(\bar{X}(t)) \end{cases} \quad (7)$$

式中: $f(x)$ 为 X 的位置适应值。鲸鱼算法更新位置时, 若新生成位置更优, 则替换原位置, 成为新的全局最优; 否则, 保持原最优位置不变。

2.1.3 KELM 模型

ELM 是一种单隐层前馈神经网络, 其学习速度

快, 能够快速逼近目标函数。KELM 则是在 ELM 的基础上通过增加核函数将数据映射到高维空间, 从而提升模型的泛化能力, 保持了 ELM 的快速学习特性^[14], 能够有效地处理石化行业碳排放预测这类非线性问题。在 KELM 算法中, 核矩阵计算见公式(8)。

$$\begin{cases} \Omega_{\text{ELM}} = HH^T \\ \Omega_{\text{ELM}} = h(x_i)h(x_j) = K(x_i, x_j) \end{cases} \quad (8)$$

式中, $h(x)$ 为 KELM 隐含层的输出函数; $K(x_i, x_j)$ 为核函数; H 为隐含层的输出矩阵。

由此, 可得出 KELM 的输出函数见公式(9)。

$$\begin{aligned} f(x) &= h(x)\beta = h(x)H^T(I/C + HH^T)^{-1}T \\ &= \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T (I/C + \Omega_{\text{ELM}})^{-1}T \end{aligned} \quad (9)$$

式中: I 为单位矩阵; C 为正则化因子; β 为输出权重; T 为期望输出。

2.2 基于 LASSO-GSWOA-KELM 石化行业碳排放预测模型构建

2.2.1 石化行业碳排放流程

本文针对 1998—2021 年中国石化行业的碳排放量, 结合 LASSO 回归和 GSWOA-KELM 进行相关研究和预测。通过 STIRPAT 模型和 LASSO 回归对这些相关变量进行相关度和显著性筛选, 在特征提取后作为 KELM 模型的数据来源, 进而运用 KELM 模型进行预测。最后在此基础上利用 GSWOA 优化 KELM 模型的运算结果, 提升预测准确率, 构建 LASSO-GSWOA-KELM 模型以完成对石化行业碳排放预测。算法流程见图 1。

①运用 STIRPAT 模型进行相关变量选取, 后用 Pearson 相关性分析和 LASSO 回归模型进一步筛选。②对筛选后的变量数据进行归一化处理。③进行 GSWOA 和 KELM 模型的参数初始化, 通过 GSWOA 算法对个体位置进行更新, 并输出最优参数。④将最优值输入 KELM 模型, 训练核极限学习机并获得其输出值。⑤计算误差指标从而进行分析。⑥预测石化行业未来碳排放量。

2.2.2 石化行业碳排放预测模型评价标准

为验证模型预测效果, 本文选取平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE)、均方误差 (MSE)、均方根误差 (RMSEP)、决定系数 (R^2) 作为评价指标。5 个评价指标计算如式(10)~(14)所示。

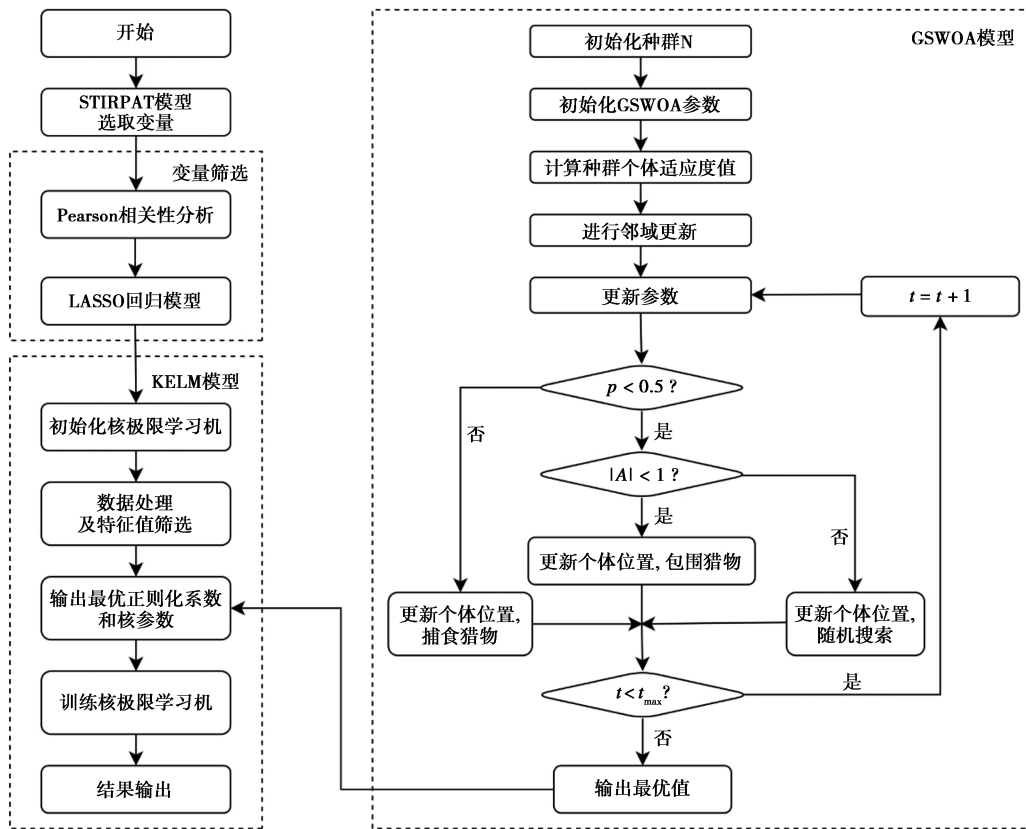


图1 算法流程图

$$MAE = (1/n) \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

$$MAPE = (1/n) \sum_{i=1}^n |(y_i - \hat{y}_i)/y_i| \times 100\% \quad (11)$$

$$MSE = (1/n) \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

$$RMSEP = \sqrt{(1/n) \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

式中: y_i 为每个样本的实际值, \hat{y}_i 为每个样本的预测值, \bar{y} 为所有实际值的平均值, n 为样本总个数, σ_{obs} 为实测值的标准差。

3 变量选取和处理

3.1 石化行业碳排放量估计

本文中石化行业碳排放量估算范围为化石燃料燃烧消耗产生的二氧化碳排放。研究内容包括石油天然气开采业、石油加工及炼焦加工业、化学纤维制造业、化学原料及化学制品制造业、橡胶制品业、塑料制品业 6 个子行业。

目前,联合国政府间气候变化专门委员会统一规定中提供的碳排放计算方法是依据不同能源消耗总量和相对应的碳排放系数,并计算不同能源碳排

放量之和,其计算公式见式(15)^[15]。

$$C_i = \sum_{i=1}^8 C_i = \sum_{i=1}^8 F_i \times CV_i \times CCF_i \times COF_i \times (44/12) \quad (15)$$

式中: C_i 为估算出的二氧化碳总量, i 为所选取的能源种类, F 为第 i 类能源的消费量,由第 i 类能源与煤炭的折算系数折算为标准煤单位消费量, CV 为平均低位发热值, CCF 为燃料的碳含量, COF 为碳氧化因子。各能源系数见表 1。

表1 各能源系数

能源名称	平均低位发热量/ ($\text{kJ} \cdot \text{kg}^{-1}$)	折标准煤系数/ ($\text{kg 标煤} \cdot \text{kg}^{-1}$)	单位热值含碳量/ ($\text{TC} \cdot \text{TJ}^{-1}$)	二氧化碳排放系数/ ($\text{kg CO}_2 \cdot \text{kg}^{-1}$)
煤炭	20934	0.7143	26.37	1.9027
焦炭	28470	0.9714	29.50	2.8639
原油	41868	1.4286	20.10	3.0240
汽油	43124	1.4714	18.9T	2.9287
煤油	43124	1.4714	19.60	3.0372
柴油	42705	1.4571	20.20	3.0998
燃料油	41816	1.4286	21.1T	3.1705
天然气	38979	1.3300	15.30	2.1649

注:数据来源于《综合能耗计算通则》、《省级温室气体清单编制指南》、《中国能源统计年鉴》。

将估算出的石化行业二氧化碳排放量按照年份绘制折线图,见图 2。




图 2 石化行业二氧化碳排放量

3.2 STIRPAT 模型选取变量

STIRPAT 模型是 IPAT 框架的高级迭代版本。IPAT 方程由 Ehrlich^[16] 引入,他将人类活动对环境的影响分解为 3 个主要部分:人口规模(P)、富裕程度(A)和技术水平(T)。Waggoner^[17] 通过将该模型技术部分细分为单位 GDP 的环境影响,构建了一种更为精确的 ImPACT 模型。Rosa^[18] 的研究指出了 ImPACT 模型的局限性,为了克服这一点,Rosa 引入了 STIRPAT 模型,这是一个灵活可扩展的框架,能够更准确地评估环境影响,同时也引入随机变量,见公式(16)。

$$I = aP^b A^c T^d e \quad (16)$$

其中, a 代表常数, b 、 c 、 d 是弹性指数,分别代表人口规模、富裕程度和技术水平对环境的影响, e 是模型误差。

本文采用 STIRPAT 模型对变量进行选取,共选取 11 个变量作为石化行业碳排放的影响因素(见表 2)。

表 2 石化行业碳排放影响因素

结构	指标	简称	数据来源
人口规模	中国人口总数	TP	中国统计年鉴
	石化行业从业人数	EP	中国工业统计年鉴
富裕程度	人均 GDP	GC	中国统计年鉴
	石化行业资产规模	AS	中经网
	石化行业固定资产投资	FI	中经网
	石化行业增加值	VA	中国工业统计年鉴
	产业结构	IS	石化行业增加值/ 工业总产值
技术水平	石化行业劳动生产率	LP	石化行业增加值/ 从业人数
	石化行业碳排放强度	CI	二氧化碳排放量/ 石化行业增加量
	石化行业能源效率	EE	石化行业增加值/ 能源消费量
	石化行业能源消费结构	EC	煤炭消费量/能源 消费总量

表 2 数据时间范围为 1998—2021 年,其中能源消费量来自于《中国统计年鉴》。1998—2007 年行业增加值数据通过《中国工业统计年鉴》得出,《中国工业统计年鉴》自 2008 年起未再公布规模以上工业分行业增加值的数据,因而本文通过增加值的实际增长率对缺失数据进行估算,即石化行业全口径下增加值的实际增长率=石化行业规模以上企业增加值的实际增长率×全部工业增加值的实际增长率/工业规模以上企业增加值的实际增长率。其中,规模以上企业增加值的实际增长率来源于 Wind 数据库,全部工业增加值的实际增长率与工业规模以上企业增加值的实际增长率数据来源于国家统计局。

3.3 Pearson 相关性分析

Pearson 相关性分析是一种统计方法,用于衡量两个连续变量之间的线性相关程度。这种分析的结果是一个介于-1 和 1 之间的相关系数,可以提供变量之间正相关、负相关或无相关的证据^[19]。根据 Pearson 相关性分析表(见表 3),石化行业从业人数与二氧化碳排放量存在中度相关,石化行业碳排放强度、石化行业能源消费结构、产业结构存在高度相关,其余变量存在强相关。为保证预测准确性,采用 Lasso 回归对变量进行进一步筛选。

表 3 Pearson 相关性分析表

相关性	变量	Pearson 相关系数
强相关	TP	0.983
	FI	0.991
	VA	0.991
	TP	0.983
	GC	0.975
	LP	0.961
高度相关	EE	0.921
	CI	-0.847
	EC	0.661
中度相关	IS	-0.647
	EP	0.543

3.4 LASSO 回归筛选变量

为了精确分析和预测我国石化行业的碳排放量,研究采用了 LASSO 回归模型对碳排放的潜在影响因素进行选择。将所选的 11 个变量进行标准化处理,消除量纲影响并提高模型的稳定性和准确性。数据集的数据量为 23,因而设置 LASSO 模型采用五折交叉验证法来确定惩罚系数 λ 的值,选择在 LASSO 模型中均方误差最小的惩罚系数,提高模型

可解释性。如图 3 所示,随着惩罚系数的逐步增加,模型的均方误差逐渐上升,最佳的惩罚系数 λ 为 0.005 29。




图 3 LASSO 回归交叉验证过程

注:上横坐标为不同 λ 对应变量数。

使用最佳的惩罚系数 λ 重新训练 LASSO 模型,并输出模型系数。系数结果代表每个变量的影响强度,系数为 0 的无贡献变量被模型自动排除。表 4 为在 λ 不同取值下各变量惩罚系数的标准化系数。由表 4 可知,当 λ 为 0.005 29 时,劳动生产率、能源消费结构的惩罚系数收敛为 0,故排除。

表 4 各变量标准化系数

变量	标准化系数	变量	标准化系数
固定资产投资	0.3907	能源效率	0.0722
行业增加值	0.2562	碳排放强度	-0.0215
资产规模	0.1620	产业结构	-0.0090
中国人口总数	0.0989	人均 GDP	0.0006

4 实证分析

4.1 模型参数设置

选取 1998—2021 年中国人口总数、人均 GDP、固定资产投资、从业人数、劳动生产率、石化行业资产规模、能源效率、行业增加值这 8 个因素作为输入变量,输出变量设置为二氧化碳排放量。考虑到数据量级差异,首先进行数据归一化处理。利用改进鲸鱼优化算法(GSWOA)来优化 KELM 模型中的核函数参数 γ (此处用 Y 表示)和正则化系数 C ,设定迭代次数和种群规模分别为 20 和 50,训练集比例设定为 0.8。为了比较 GSGWO-KELM 模型与 WOA-ELM 模型的性能优劣,对这两个模型进行对比分析。

为了直接展示本研究模型的卓越性能,并确定改善的 KELM 模型中最佳的核函数参数 σ 和正则化参数 C ,比较了利用 GSWOA 和 WOA 策略优化的 KELM 模型在迭代过程中的适应度曲线(见图 4、图 5)。比较结果显示,GSWOA 在收敛效率和优化

精度方面相比 WOA 策略表现出显著的优势,证明了 LASSO-GSWOA-KELM 优化策略的优越性。




图 4 GSWOA-KELM 优化策略





图 5 LASSO-WOA-ELM 优化策略

4.2 预测误差分析

为了深入比较各模型的预测能力,本研究采用了 MSE、MAE、RMSEP、MAPE 和 R^2 作为评估预测模型性能的指标。模型的误差指标和训练效果的对比结果展示见表 5、图 6。使用 LASSO 结合 LASSO-

表 5 误差指标的对比

名称	LASSO-GSWOA-KELM	LASSO-WOA-ELM	LASSO-BP 神经网络回归	LASSO-随机森林回归	LASSO-EXTRA TREES 回归
MAE	2.986900	5.979800	8.334	12.223	12.504
MSE	11.310400	57.506200	128.091	223.610	213.838
RMSEP	3.363100	7.583300	11.318	14.954	14.623
MAPE	0.018148	0.022492	3.165	9.012	4.932
R^2	0.999160	0.983840	0.990	0.983	0.983



1—GSWOA-KELM 预测值;2—BP 预测值;
3—随机森林预测值;4—WOA-ELM 预测值;
5—EXTRA TREES 回归预测值;6—真实值

图 6 不同模型的实验对比结果

GSWOA-KELM 模型进行的二氧化碳排放量预测,性能超过了其他对比模型。LASSO-WOA-ELM 模型和 LASSO-EXTRA TREES 回归预测紧随其后。此外,LASSO-GSWOA-KELM 模型在大多数年份的预测误差最小,进一步验证了其预测精确度的优越性。

4.3 碳排放预测结果

4.3.1 数据预测解释

中国人口总数:《世界人口展望(2022)》对中国 2022—2100 年的总人口进行了预测。预测结果显示,中国自 2022 年起的总人口数量将逐年下降,并且这种下降趋势将逐年加剧。因此,本文采用该数据对中国的总人口变化进行分析和预测。

行业增加值:本文关注的石化行业中的行业增加值是特定报告期内货币形式表现的工业生产活动的最终产出。通过对 1998—2022 年的行业增加值进行研究,发现其增长趋势接近线性。因此,本文采用线性回归模型对 2023—2030 年的行业增加值进行预测。

人均 GDP:根据“十四五”规划,中国 GDP 年均增速预计在 5%~5.5% 之间。本文设定在 2023—2025 年期间,年增长率保持在 5% 的基准线上,随后每 5 年为一个阶段,增速逐步下降 1%。基于此设定,对 2023—2030 年中国的 GDP 数据进行了预测。

固定资产投资:《2024 中国经济预测与展望》中预测 2024 年中国固定投资(不含农户)在较大概率率的基准情景下增长 4.7% 左右。同时,固定资产投资直接影响着生产力和产出水平,对 GDP 增长产生直接影响,故本文以上文 GDP 增速对未来几年的固定资产投资进行预测。

资产规模:GDP 增长需要资本投入,这包括投资于生产设备、基础设施、研发等,这些投资最终会反映在资产的增长上。故本文引用对 GDP 的增长率预测数据估算资产规模的增长率数据并预测。

能源效率:近年来石化行业引入 CCUS 等先进技术有助于优化能源生产和利用,推动产业结构升级,提升能源利用效率。本文根据 CCUS 等减碳先进技术发展趋势,结合过去几年中国能源效率增幅,预测中国能源效率将以 0.5% 左右的速度持续增加。

碳排放强度:中国政府出台了一系列能源节约和能效改进政策,提高了能源利用效率。生产过程中的能源利用效率提升导致了单位产值的碳排放强度下降。结合过去碳排放强度减少情况,本文以每

年降低 3% 的幅度对中国碳排放强度进行预测。

产业结构:随着科技的发展和科技进步,一些传统的重工业正在逐渐被高技术产业所取代。中国政府积极推动供给侧结构性改革,促进工业产业结构的优化和调整。本文设定中国石化行业产业结构将逐渐优化,IS 维持在 12.6% 左右。

4.3.2 基于模型的碳排放量预测值

石化行业基于 LASSO-GSWOA-KELM 模型的碳排放量预测值如图 7 所示。从图 7 预测结果看,未来几年,石化行业的碳排放量仍在增长,幅度相较于 2022—2024 年有所降低。在国家低碳减排的大环境下,石化行业预计于 2029 年达到峰值,提前实现 2030 年碳达峰的目标。




图 7 基于 LASSO-GSWOA-KELM 模型的碳排放量预测值

5 结论与政策建议

本文针对石化行业碳排放量的预测分析,构建 LASSO-GSWOA-KELM 模型对中国石化行业 2022—2030 年的碳排放量进行预测,根据预测结果,2022—2030 年,碳排放量将呈现逐年增长的趋势,但增速将有所放缓,将于 2029 年达到峰值 446 786 万 t。到 2030 年,碳排放量预计将减少到 445 473 万 t,预测结果与中国的 2030 年碳达峰目标相吻合。预测结果表明,石化行业实现 2030 年碳达峰目标仍面临诸多挑战。首先,尽管碳排放预计在 2029 年达到峰值,但在此之前的几年内碳排放量仍将持续增长,意味着中国需要在石化行业采取更多的碳减排措施;其次,如果石化行业在 2029 年成功达到碳达峰,在后几年内仍需持续减少碳排放,以实现长期的碳中和目标。

在推进石化行业减碳降排上,我国应加速制定相关技术规范,鼓励企业研发 CCUS 关键性技术,降低捕集成本,大力发展 CCUS 技术,减少对传统碳资源的依赖作用。继续推进产业转型升级、淘汰落后产能,提升高端产品供给能力,减少石化行业碳排放

水平,推动石化产业迈向高端化、智能化、绿色化发展之路。加快建立绿色金融体系,通过绿色贷款、绿色债券、绿色基金、碳市场交易等多种绿色金融工具,获得资金支持,引导资本流向,推动技术创新,实现减排目标^[20]。随着经济的快速发展,炼制加工规模逐年增加,原油重质化和劣质化程度提高,原料改善和加工工艺转型升级的需求迫切,落后设备亟需淘汰升级^[21]。

参考文献

- [1] 于孟君.中国石化行业二氧化碳排放量因素分解及达峰路径研究[D].哈尔滨:哈尔滨理工大学,2021.
- [2] Brizga J, Feng K, Hubacek K. Drivers of greenhouse gas emissions in the Baltic States: A structural decomposition analysis[J]. *Ecological Economics*, 2014, 98: 22-28.
- [3] Kim T J, Tromp N. Analysis of carbon emissions embodied in South Korea's international trade: Production-based and consumption-based perspectives [J]. *Journal of Cleaner Production*, 2021, 320: 128839.
- [4] Tudor C. Predicting the evolution of CO₂ emissions in Bahrain with automated forecasting methods[J]. *Sustainability*, 2016, 8(9): 923.
- [5] Rahman A, Hasan M M. Modeling and forecasting of carbon dioxide emissions in Bangladesh using Autoregressive Integrated Moving Average (ARIMA) models[J]. *Open Journal of Statistics*, 2017, 7(4): 560-566.
- [6] Thio E, Tan M, Li L, et al. The estimation of influencing factors for carbon emissions based on EKC hypothesis and STIRPAT model: Evidence from top 10 countries[J]. *Environ Dev Sustain*, 2022, 24: 11226-11259.
- [7] Sen P, Roy M, Pal P. Application of ARIMA for forecasting energy consumption and GHG emission: A case study of an Indian pig iron manufacturing organization[J]. *Energy*, 2016, 116: 1031-1038.
- [8] 张巍.基于 STIRPAT 模型的陕西省工业碳排放量预测和情景分析[J]. *可再生能源*, 2017, (5): 143-149.
- [9] 赵金辉,李景顺,王潘乐,等.基于 Lasso-BP 神经网络模型的河南省碳达峰路径研究[J]. *环境工程*, 2022, 40(12): 151-164.
- [10] 胡振,龚薛,刘华.基于 BP 模型的西部城市家庭消费碳排放预测研究——以西安市为例[J]. *干旱区资源与环境*, 2020, 34(7): 82-89.
- [11] 高金贺,郑宝珠,周伟吴,等.基于 GA-SVR 的城市交通运输碳排放预测研究[J]. *东华理工大学学报(自然科学版)*, 2022, 45(3): 269-274.
- [12] 王文佳,潘昊,王国刚.基于 GWO-LSTM 模型的辽宁省工业碳排放预测及影响因素研究[J]. *环境科学与管理*, 2024, 49(1): 28-33.
- [13] 张新生,张玥.基于 Lasso-PSO-BP 神经网络的腐蚀管道失效压力的预测[J]. *材料保护*, 2020, 53(4): 46-52.
- [14] Sahil D, Virendra P V. GA based KELM optimization for ECG classification[J]. *Procedia Computer Science*, 2020, (167): 580-588.
- [15] 张新生,魏志臻,陈章政,等.基于 LASSO-GWO-KELM 的工业碳排放预测方法研究[J]. *环境工程*, 2023, 41(10): 141-149.
- [16] Ehrlich P, Holdren J. Impact of population growth [J]. *Science*, 1971, 171(3977): 1212-1217.
- [17] Waggoner P E, Ausubel J H. A framework for sustainability science: A renovated IPAT identity [J]. *Proceedings of the National Academy of Sciences*, 2002, 99(12): 7860-7865.
- [18] York R, Rosa E A, Dietz T. STIRPAT, IPAT and ImpACT: Analytic tools for unpacking the driving forces of environmental impacts[J]. *Ecological Economics*, 2003, 46(3): 351-365.
- [19] 徐维超.相关系数研究综述[J]. *广东工业大学学报*, 2012, 29(3): 12-17.
- [20] 张男.绿色金融助力石油石化企业绿色低碳发展[J]. *中外能源*, 2023, 28(10): 1-6.
- [21] 韩恒文,韩伟,程薇.石化行业 CO₂ 排放核算与减排技术进展[J]. *石油化工*, 2023, 52(12): 1754-1764. ■
- [3] Sheng M, Guo D, Zhang D. Study on preparation of bio-diesel with soybean oil[J]. *China Oil and Fats*, 2002, 27(1): 70-72.
- [4] Li J, Wang Z, Liu B. An experimental study on the emission characteristics of bio-diesel fuel [J]. *Automotive Engineering*, 2008, 130(7): 585-587, 596.
- [5] 陈韬,谢辉,吴志新,等.车用柴油机燃用生物柴油的排放特性[J]. *环境工程学报*, 2017, 11(11): 5972-5977.
- [6] 李婷.车用生物柴油的应用与发展趋向分析[J]. *当代化工研究*, 2016, (10): 87-88.
- [7] Mohd N C W, Noor M M, Mamat R. Biodiesel as alternative fuel for marine diesel engine applications: A review[J]. *Renew Sust Energ Rev*, 2018, 94: 127-142.
- [8] Chang Y C, Jia M, Li Y P, et al. Development of a skeletal oxidation mechanism for biodiesel surrogate [J]. *Proceedings of the Combustion Institute*, 2015, 35(3): 3037-3044.
- [9] Moazeni F, Chen Y C, Zhang G. Enzymatic transesterification for biodiesel production from used cooking oil: A review[J]. *Journal of Cleaner Production*, 2019, 216: 117-128.
- [10] Anwar M, Rasul M G, Ashwath N. A pragmatic and critical analysis of engine emissions for biodiesel blended fuels [J]. *Fuel*, 2020, 270: 117513.
- [11] 吴刚,江国和,杨智远,等.船用柴油机燃用生物柴油排放与消烟机理[J]. *哈尔滨工程大学学报*, 2019, 40(3): 468-476.
- [12] 王学春,方建华,陈波水,等.生物柴油中不饱和脂肪酸甲酯对内燃机油摩擦学性能的影响[J]. *润滑与密封*, 2015, 40(9): 78-82.
- [13] Bannister C D, Chuck C J, Hawley J G, et al. Factors affecting the decomposition of biodiesel under simulated engine sump oil conditions[J]. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 2010, 224(7): 927-940.
- [14] 牟明仁,郭雅琳,王鹏,等.出口车用柴油与进口生物燃料油质量对比分析[J]. *石化技术*, 2014, 21(2): 49-53.
- [15] 吴江,陈波水,方建华,等.生物柴油发动机润滑油氧化衰变特性模拟研究[J]. *车用发动机*, 2008, (6): 85-88. ■

(上接第 377 页)