

基于长短期记忆网络的炼钢厂碳排放量预测方法

李风云¹, 窦泽慧¹, 李朋², 郭威¹

1. 东北大学计算机科学与工程学院, 辽宁 沈阳 110819;

2. 沈阳城市学院智能与工程学院, 辽宁 沈阳 110112

摘要

钢铁行业作为中国制造业碳排放量第二大的行业, 拥有较大的碳减排潜力。为便于相关部门对碳排放量进行监管和控制, 展开碳排放量预测研究。以某炼钢厂为研究对象, 首先, 分析炼钢过程中的二氧化碳排放, 确定了引起碳排放的10种能源物质, 据此收集了炼钢厂2001—2023年的基础能源数据, 依据碳排放核算方法由基础能源数据核算出碳排放量; 其次, 基于长短期记忆网络预测未来7年的碳排放量, 训练误差和测试误差均接近0.01, 实际误差为1 323 307.46 t二氧化碳, 并与其他3种预测模型进行对比, 结果表明所提预测模型的拟合精度较高、预测效果较好; 然后, 采用Mann-Kendall趋势检验法评估炼钢厂的整体碳排放趋势; 最后, 为积极响应低碳环保目标, 针对炼钢厂提出合理建议。

关键词

炼钢厂; 长短期记忆网络; 碳排放预测; 低碳环保

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.2096-0271.2024051

Carbon emission prediction method of steel plants based on long short-term memory network

LI Fengyun¹, DOU Zehui¹, LI Peng², GUO Wei¹

1. School of Computer Science and Engineering, Northeastern University, Shenyang 110819, China

2. School of Intelligent and Engineering, Shenyang City University, Shenyang 110112, China

Abstract

As the second largest carbon emitter in China, iron and steel enterprises have great potential for carbon emission reduction. In order to facilitate the supervision and control of carbon emissions by relevant departments, carbon emission prediction research is carried out. Taking a steelmaking plant as the research object, firstly, the carbon dioxide emissions in the steelmaking process were analyzed, and 10 energy substances that caused carbon emissions were determined. The basic energy data of the steelmaking plant from 2001 to 2023 were collected, and the carbon emissions were calculated from the

basic energy data according to the carbon emission accounting method. Secondly, based on the long short-term memory network to predict the carbon emissions in the next 7 years, the training error and test error were close to 0.01, and the actual error was 1 323 307.46 tons of carbon dioxide. Then, the Mann-Kendall trend test was used to evaluate the overall carbon emission trend of the steelmaking plant. Finally, some reasonable suggestions were put forward for steelmaking plants in order to actively respond to the goal of low-carbon environmental protection.

Key words

steel plant, long short-term memory network, carbon emission prediction, low carbon and environmental protection

0 引言

全球气候变暖是目前人类所面临的重要问题,而CO₂的排放是引起全球变暖的主要原因之一。中国作为世界上碳排放量最多的十大国家之一^[1],为解决全球气候变暖问题和积极响应低碳环保、绿色发展战略,我国积极采取措施^[2]。钢铁行业是CO₂的主要排放源,中国钢铁企业的碳排放量占全球的60%以上,是碳排放较多的行业之一^[3]。因此,推动钢铁企业实现科学、高效的碳排放结构转型至关重要。

国内外有很多学者研究了低碳排放的预测。Nazeri等^[4]提出基于GWO(grey wolf optimizer)改进的KELM(kernel based extreme learning machine)预测模型,具有较好的预测效果并且解决了局部最优解的问题,但模型针对的是中国整体工业的碳排放,不适合钢铁企业的碳排放预测。Liu^[5]使用情景分析和MK(Mann-Kendall)趋势检验法预测了某石化企业的碳达峰时间和峰值,并给出了多方面的碳减排路径措施,但采用的非参数统计检验偏重因果解释,无法估计趋势斜率。Fan等^[1]构建了钢铁企业能耗-碳排放预测模型,适合数据量偏小的场景,但预测精度较差。Fan等^[6]建立了ARIMA-LSTM预测模型,多元负荷数据的线性和非线性部分分别采用ARIMA和

LSTM进行预测,该模型综合了两种算法的优点,但仅适用于数据集偏小的场景。Zhang等^[7]使用线性回归构建了隧道建设的碳排放预测模型,而线性回归算法仅适合线性数据。Cai等^[8]构建了灰色模型GM(1,1)进行能源消耗和碳排放的预测,而GM(1,1)适用于中短期和指数级数据的预测,难以对大而复杂的数据集进行预测。Liu等^[9]提出了PSO-ELM(particle swarm optimization extreme learning machine)预测模型,虽然该模型复杂度小且训练快,但对大规模数据易出现无法收敛的问题。通过分析发现,现有模型大多基于小数据集进行预测,若应用于大规模数据集,容易出现无法收敛、预测精度低等问题,还有些算法不适用于非线性复杂数据集的预测。

针对现有预测模型不适合非线性复杂数据、精度较低和场景未涉及炼钢企业等问题,本文对某炼钢厂展开了碳排放预测方法研究。

1 算法和模型介绍

1.1 温室气体碳排放量核算方法

依据《中国钢铁生产企业温室气体排放核算方法与报告指南(试行)》^[10],炼钢厂企业的碳排放总量涉及4个部分:化石燃料燃烧的碳排放量 C_1 、企业净购入热力和电力的碳排放量 C_2 、工业生产过程的碳排

放量 C_3 和固碳产品隐含的碳排放量 C_4 。在工业生产过程中, C_3 和 C_4 在实际核算时难以衡量, 且两者的碳排量总占比很小, 约为2%, 故忽略 C_3 和 C_4 ^[11], 碳排放总量 C 的计算如式(1)所示。

$$C = C_1 + C_2 \quad (1)$$

根据《中国钢铁生产企业温室气体排放核算方法与报告指南(试行)》^[10]计算化石燃料燃烧的碳排放量和电力的碳排放量, 分别如式(2)、式(3)所示。

$$C_1 = \sum_{i=1}^n F_i \times CV_i \times CCF_i \times COF_i \times \frac{44}{12} \quad (2)$$

其中, n 是产生 CO_2 的主要化石燃料类别数, $n=8$; i 是第 i 种产生 CO_2 的化石燃料, F_i 是第 i 种化石燃料的消耗量, 单位为t, CV_i 是第 i 种化石燃料的平均低位发热值, 单位为每吨百万焦耳(10^6 kJ/t), CCF_i 是第 i 种化石燃料的含碳量^[12], 单位为每百万焦耳二氧化碳吨($tCO_2/10^6$ kJ), COF_i 是第 i 种化石燃料的碳氧化率, 44是 CO_2 的相对分子质量, 12是C的相对原子质量。

$$C_2 = AD_h \times EF_h + AD_e \times EF_e \quad (3)$$

表1 能源系数

主要能源	平均低位发热值/ 10^6 kJ·t ⁻¹	单位热值含碳量系数	碳氧化率
洗精煤	26.3	0.0254	90%
无烟煤	20.3	0.02749	94%
烟煤	19.6	0.02618	93%
焦炭	28.4	0.0295	93%
天然气	389.3	0.0153	99%
焦炉煤气	160.7	0.0121	99%
高炉煤气	33.4	0.0708	99%
转炉煤气	70.4	0.0496	99%

表2 净购入热量、电量排放因子

净购入能量	排放因子	单位
热量	0.11	tCO ₂ /GJ
电量	0.5257	tCO ₂ /MWh

其中, AD_h 是炼钢厂的净购入热量, 单位为百万焦耳(10^6 kJ), EF_h 是热力产生 CO_2 的排放因子, 单位为每百万焦耳二氧化碳吨(tCO_2/GJ), AD_e 是炼钢厂的净购入电量, 单位为兆千瓦时(MWh), EF_e 是电力产生 CO_2 的排放因子, 单位为每兆千瓦时二氧化碳吨(tCO_2/MWh)。

某炼钢厂的8种主要能源物质的能源系数见表1。

某炼钢厂的净购入热量、电量排放因子见表2。

1.2 LSTM预测模型

LSTM是特殊形式的循环神经网络, 如图1所示。它由遗忘门、记忆门和输出门组成。遗忘门决定哪些信息被遗忘, 如式(4)所示; 记忆门决定哪些新信息被保留, 并控制新信息的输入比例, 如式(5)所示; 输出门生成当前时刻的结果和隐藏状态, 如式(6)所示。

$$f_t = \sigma(w_f \times [h_{t-1}, x_t] + b_f) \quad (4)$$

其中, f_t 是遗忘门的输出结果, x_t 是当前时刻的输入数据, h_{t-1} 是前一时刻的输出, w_f 代表权重, b_f 代表偏置, σ 代表sigmoid激活函数。

$$\begin{cases} i_t = \sigma(w_i \times [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(w_c \times [h_{t-1}, x_t] + b_c) \end{cases} \quad (5)$$

其中, i_t 是记忆门sigmoid函数的输出结果, 决定将更新哪些值, \tilde{C}_t 是当前时刻激活函数tanh的输出结果, w_i 和 w_c 代表权重, b_i 和 b_c 代表偏置, σ 代表sigmoid激活函数。

$$\begin{cases} C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \\ O_t = \sigma(w_o \times [h_{t-1}, x_t] + b_o) \\ h_t = O_t \times \tanh(C_t) \end{cases} \quad (6)$$

其中, C_t 是当前时刻记忆细胞的状态, C_{t-1}

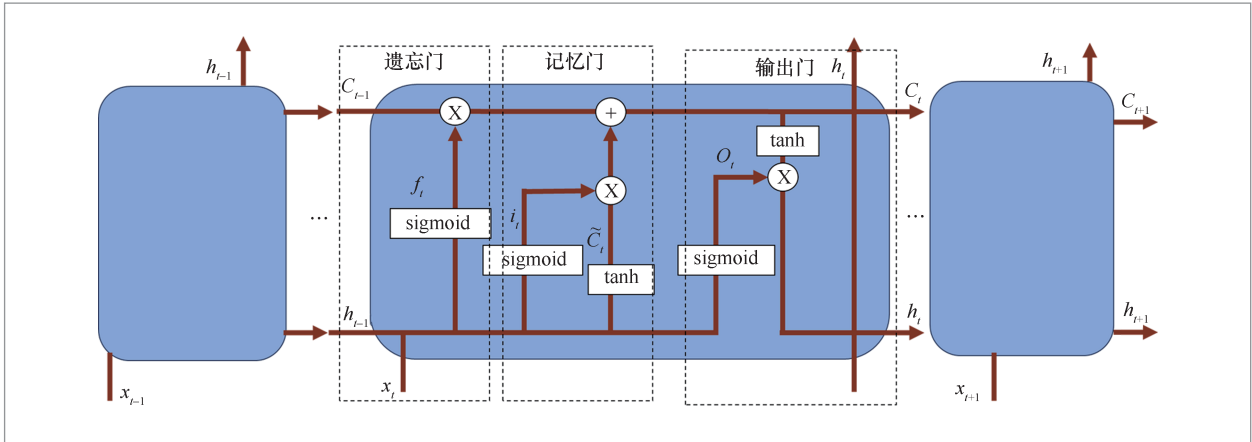


图1 LSTM 网络结构

是上一时刻记忆细胞的状态, O_t 是输出门的激活函数sigmoid的输出结果, h_t 是当前时刻的输出。

LSTM能够捕捉数据的长期依赖性以及适合非线性数据预测, 而炼钢厂的碳排放量与时间呈非线性关系, 时间跨度较长, 因此选取LSTM构建预测模型, 实现碳排放量预测。

1.3 MK趋势检验法

MK趋势检验法的优点是计算简便、功能强大, 待检验的样本数据可以不遵循某种分布、可以存在异常数据^[13]。

假设时间序列数据为 $X=[x_1, x_2, x_3, \dots, x_n]$, 零假设 H_0 (样本数据没有单调趋势), 备择假设 H_1 (样本数据存在单调趋势), 检验统计量 S 如式(7)所示。

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(x_j - x_i) \quad (7)$$

$$\text{sgn}(x_j - x_i) = \begin{cases} 1, & x_j - x_i > 0 \\ 0, & x_j - x_i = 0 \\ -1, & x_j - x_i < 0 \end{cases} \quad (8)$$

其中, $\text{sgn}()$ 代表符号函数, 当输入值大于0时, 符号函数结果为1; 当输入值等于0时,

符号函数结果为0; 当输入值小于0时, 符号函数结果为-1。 n 是峰值年后的样本数量(年数), 当 $n \geq 8$ 时, 检验统计量 S 服从均值为0、方差为 $\text{Var}(S)$ 的正态分布, 方差 $\text{Var}(S)$ 如式(9)所示。

$$\text{Var}(S) = \frac{n(n-1)(2n+5) - \sum_{i=1}^g t_i(i-1)(2i+5)}{18} \quad (9)$$

其中, g 是分组数, t_i 是第 i 组数据点的个数, 此时 $g=n, t_i=1$ 。标准化 S , 如式(10)所示。

$$Z_c = \begin{cases} \frac{S-1}{\sqrt{\text{Var}(S)}}, & S > 0 \\ 0, & S = 0 \\ \frac{S+1}{\sqrt{\text{Var}(S)}}, & S < 0 \end{cases} \quad (10)$$

β 用来检验单调趋势是单调上升还是单调下降, 如式(11)所示, $\text{Median}()$ 代表计算中位数函数。

$$\beta = \text{Median}\left(\frac{x_i - x_j}{i - j}, \forall j < i\right) \quad (11)$$

$Z_{1-\alpha/2}$ 表示 Z_c 的下 $\alpha/2$ 分位点, α 为统计学中的显著性水平, 常取0.025、0.01和0.05。 $|Z_c| \geq Z_{1-\alpha/2}$ 说明峰值年后的碳排放量存在单调趋势, $\beta < 0$ 时, 表明碳排放量显著下降, $\beta > 0$ 时, 表明碳排放量显著上升。

$|Z_c| < Z_{1-\alpha/2}$ 说明峰值年后的碳排放量不存在显著单调趋势。

2 碳排放预测及趋势评估模型

为了解炼钢厂直至2030年的碳排放量,建立碳排放预测及趋势评估模型,如图2所示,该模型包含两部分:一部分是基于LSTM的碳排放预测模型;另一部分是基于MK趋势检验法的碳排放趋势评估模型。

2.1 基于LSTM的碳排放预测模型

基于炼钢厂的基础能源数据,利用LSTM网络进行时序预测,预测出2024—2030年的碳排放量,预测模型的具体流程如下。

- 将2001—2023年每月的碳排放量使用最小-最大缩放器归一化至 $(-1, 1)$,碳排放量最小、最大值分别为29 692 959.7 tCO₂、93 179 005.2 tCO₂,并以17:3的比例将数据集划分为训练集和测试集。

- 使用Pytorch框架创建LSTM模型,神经网络涉及Lstm和Linear两层,模型的输入单元数、隐层单元数和输出单元数分别设为1、100和1,因数据是单变量数据,故模型输入和输出单元数均设置为1。

- 将预处理后的训练数据集输入LSTM模型中,迭代100次,得到训练结果。同时将测试数据集输入模型中,得到测试结果。记录LSTM模型的训练和测试精度。

2.2 基于MK的趋势评估模型

预测出未来7年的碳排放量后,使用MK

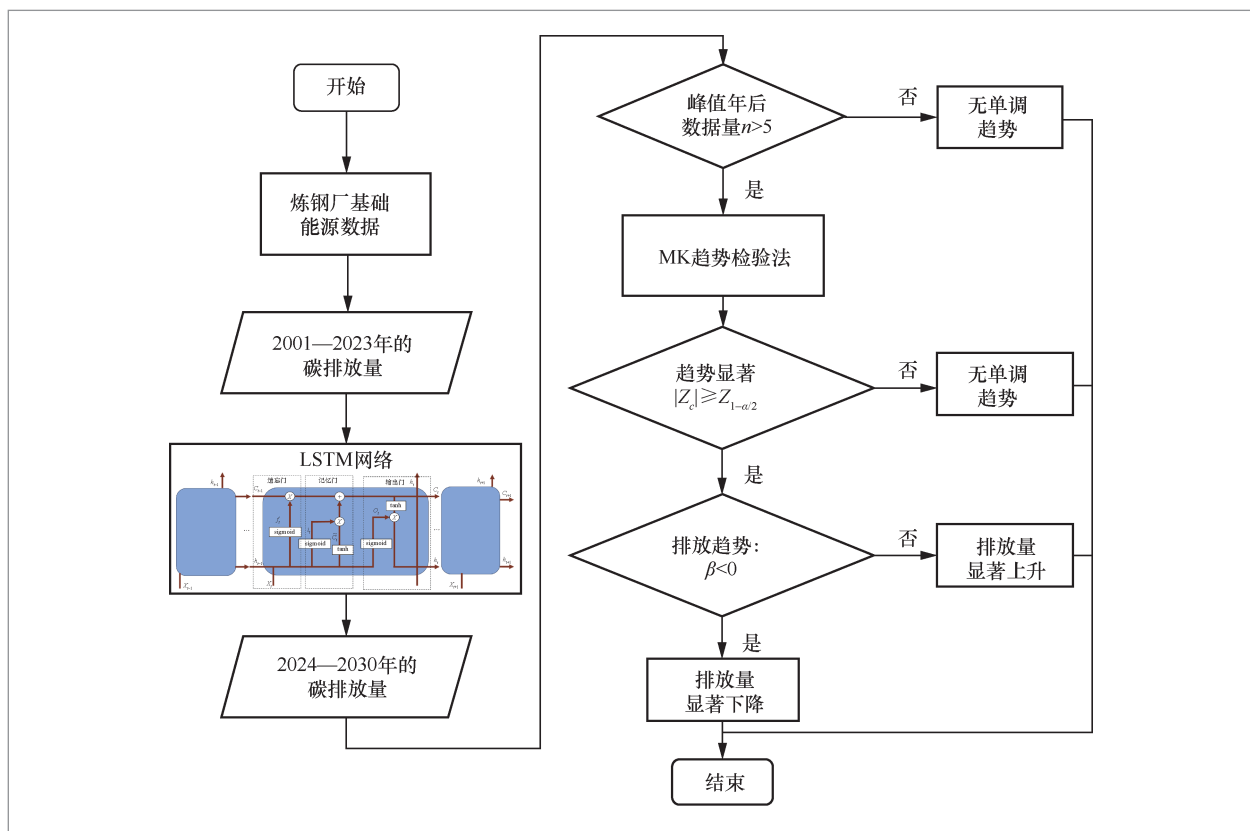


图2 碳排放预测及趋势评估模型

趋势检验法判断炼钢厂直至2030年的碳排放趋势情况,基于MK趋势检验法的趋势评估模型流程如下。

- 基于预处理的2001—2023年的碳排放量初始数据和LSTM预测出的2024—2030年的碳排放量数据,判断碳排放量峰值年后的数据量 n 是否大于5,若峰值年出现在2030年的近5年内,则说明碳排放量直至2030年无明显单调趋势。

- 当峰值年出现在2030年的近5年外,采用MK趋势检验法分析碳排放量是否存在显著的单调趋势,若 $|Z_c| < Z_{1-\alpha/2}$,说明峰值年后的碳排放量不存在显著单调趋势,即炼钢厂未来7年碳排放情况处于平稳排放状态。

- 若 $|Z_c| \geq Z_{1-\alpha/2}$ 且 $\beta < 0$,表明炼钢厂未来7年的碳排放量整体有显著下降趋势;若 $|Z_c| \geq Z_{1-\alpha/2}$ 且 $\beta > 0$,表明炼钢厂未来7年碳排放量整体有显著上升趋势。

3 实验

3.1 实验设置

为验证本文的碳排放预测模型的有效性,在某炼钢厂的模拟能源数据上进行实验。本文确定了炼钢过程引起碳排放的10种能源物质。由2001—2023年该钢铁厂10种能源物质每年的平均消耗量除以12,求出10种能源物质每月的平均消耗量,再用Python模拟出2001—2023年间10种能源物质的每月使用量,将此作为实验数据集。在模拟数据时,使模拟的每月数据围绕当月平均消耗量上下波动,并使节假日期间数据略低于月平均消耗量,从而保证模拟数据集接近真实炼钢厂每月能源物质的消耗量,由此保证模拟数据集的合理性。

本实验使用Windows11系统,硬件环境:CPU为Intel(R) Core(TM) i7-14650HX 2.20 GHz, GPU为NVIDIA GeForce RTX 4060,使用Python3.8.5编程语言,采用Pytorch1.13框架。

实验评价指标方面,使用均方误差MSE和均方根误差RMSE衡量预测效果的精度,如式(12)、式(13)所示。其中, y_i 是碳排放量真实值, \hat{y}_i 是碳排放量预测值。

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

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

3.2 实验结果

(1) 基于LSTM的碳排放预测实验

基于核算出的碳排放量数据,搭建LSTM神经网络,预测炼钢厂未来7年的CO₂排放量。图3为训练结果与训练损失,图3(a)表明原始数据和预测结果高度重叠,实际训练误差RMSE为686 483.30 tCO₂,图3(b)表明经过100次迭代,损失稳定在0.001附近,训练效果良好。

图4为测试结果与测试损失,图4(a)中蓝线是原始测试数据,橙线是预测数据,两者高度重叠,实际测试误差RMSE为1 323 307.46 tCO₂,图4(b)表明经过100次迭代后,测试损失稳定在0.01附近,测试效果良好。

图5为LSTM预测结果,显示了2024—2030年的碳排放量。蓝色线是炼钢厂每月的CO₂排放量,橙色线是训练集预测的碳排放量,红色线是测试集预测的碳排放量,绿色线是预测的未来7年的碳排放量,粉色线是在测试集中预测的未来7年的碳排放量。为使模型能学到碳排放量规律以及保证模型的泛化能力,设置训练和测试期间的的时间跨度




图3 训练结果与训练损失




图4 测试结果与测试损失

为12个月,在真实数据、测试集上预测未来7年碳排放量时,设置时间跨度分别为108、40个月。

最终预测评价结果如下:训练集的MSE=0.000467、RMSE=0.0216,都

比较接近0.01,说明训练集的回归拟合精度较高;测试集的MSE=0.001737、RMSE=0.0417,同样接近0.01,说明测试集的回归拟合精度较高;对比发现粉色线和绿色线基本重合,即在真实数据下预测

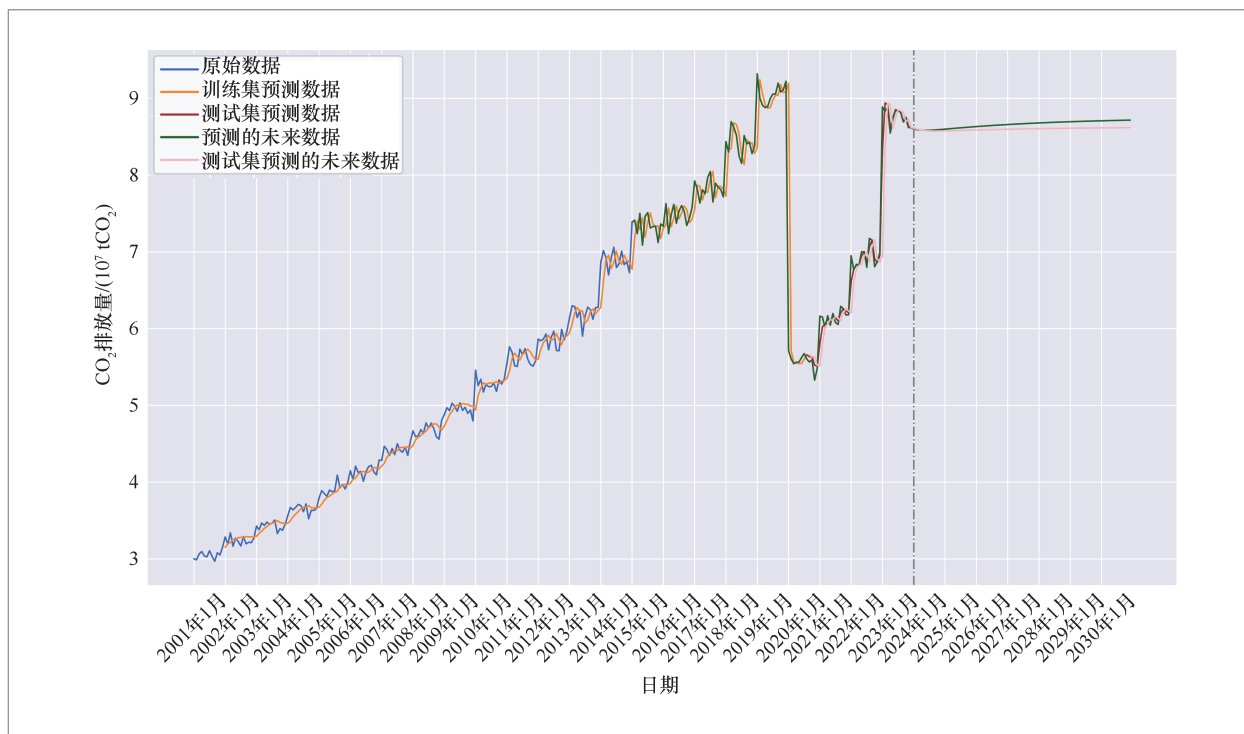


图5 2001—2030年训练和测试以及预测的碳排量

的未来7年的碳排放量和在测试集中预测的未来7年碳排放量非常接近,说明模型具有较强的泛化能力。由此可知,构建的LSTM碳排放预测模型效果较好。

(2) 预测模型实验效果验证

为验证基于LSTM的碳排放预测模型的效果,与其他3种预测算法建立模型进行对比,见表3,对比算法分别为ARIMA (autoregressive integrated moving average mode)、BP (back propagation) 神经网络和Prophet。

这3种预测模型和LSTM碳排放预测模型使用相同比例的训练集和测试集, BP神经网络的各层单元个数、训练Epoch与LSTM网络设置相同。对比发现,本文预测模型的训练集RMSE和所有数据的RMSE (第3列)均最小,其测试集RMSE比BP神经网络预测模型的大,可能是因为使用的测试集偏小。总体而言,本文构建的LSTM碳排放预测模型的误差较小,模

表3 预测模型对比

预测模型	训练集 RMSE/tCO ₂	测试集 RMSE/tCO ₂	RMSE/tCO ₂
ARIMA	2 987 420.86	1 720 405.38	5 883 841.33
BP神经网络	2 665 411.60	9 465 461.26	4 758 793.39
Prophet	4 016 236.33	13 856 957.34	7 019 111.70
LSTM	686 483.30	1 323 307.46	3 040 540.30

型效果较好。

(3) 基于MK的碳排放趋势评估

由现有数据核算出的碳排放量和LSTM预测的碳排放量求出2001—2030年的碳排放量,如图6所示。分析出2019年是钢铁厂碳排放峰值年,使用MK趋势检验法进行整体碳排放趋势评估。

- 针对炼钢厂峰值年后11年的MK趋势检验。以2019年为基准年,使用MK趋势检验法检验未来在2030年前的碳排放趋势情况,见表4,其中P为显著性水平。标准




图6 炼钢厂2001—2030年碳排放量

表4 炼钢厂11年的MK趋势检验($n=11$)

年份	S	$\text{Var}(S)$	Z_c	P	β	发展趋势
2020—2030年	41	165	3.11	0.0018	>0	上升趋势

化检验统计量满足 $|Z_c|=3.11>1.96$ (显著性水平 α 取0.025时, $Z_{1-\alpha/2}=1.96$),故拒绝原假设 H_0 ,说明碳排量有单调趋势,又因 $\beta>0$,显著性水平 $P=0.0018<0.05$ (显著性水平 α 取0.05),认为碳排量存在显著上升趋势。

● 针对炼钢厂各季节的MK趋势检验。为进一步探索炼钢厂各季节的碳排放情况,利用MK趋势检验法判断各个季节的碳排放趋势,见表5。春季、夏季、秋季和冬季的 Z_c 的绝对值大于1.96,故拒绝原假设 H_0 ,说明碳排放量有单调

趋势,又因各季节的 $\beta>0$,显著性水平 $P=0.0018<0.05$ 、 $P=0.0031<0.05$,认为炼钢厂在春、夏、秋、冬的碳排量均有显著上升趋势。

4 结束语

为缓解全球气候变暖,响应国家低碳战略目标,本文提出了碳排放预测及趋势评估模型,旨在预测炼钢厂直至2030年的碳排放量和评估整体排放趋势。本文详细介绍了基于LSTM的碳排放预测过程和基于MK趋势检验法的趋势评估过程。以某炼钢厂为研究对象,依据模拟的2001—2023年的能源数据预测未来7年的碳排放

量, 训练和测试误差均接近0.01, 说明碳排放预测模型拟合精度较高, 并与其他3种预测模型比较, 发现LSTM模型的RMSE较小, 验证了LSTM预测模型效果较好。由碳排放趋势评估实验可知, 某炼钢厂直至2030年整体碳排放量和各季节碳排放量存在显著上升趋势。据此, 建议炼钢厂综合多目标实施碳减排策略, 将碳排量减少至小于LSTM预测的碳排量, 调整企业结构, 包括调整生产强度和季节性生产量等, 同时研究探寻可行的碳转型方案, 以实现低碳环保企业战略。

参考文献:

- [1] FAN Z Y, FRIEDMANN S J. Low-carbon production of iron and steel: technology options, economic assessment, and policy[J]. *Joule*, 2021, 5(4): 829-862.
- [2] 魏子强, 温鹏, 梁志, 等. 计及需求响应比例的园区综合能源系统低碳经济调度方法[J]. *太阳能学报*, 2023, 44(10): 38-45.
WEI Z Q, WEN P, LIANG Z, et al. Low-carbon economy dispatching method of park integrated energy system considering demand response ratio[J]. *Journal of Solar Energy*, 2023, 44(10): 38-45.
- [3] ONARHEIM K, MATHISEN A, ARASTO A. Barriers and opportunities for application of CCS in Nordic industry—a sectorial approach[J]. *International Journal of Greenhouse Gas Control*, 2015, 36: 93-105.
- [4] NAZERI M, SOLTANAGHAEI M, KHORSAND R. A predictive energy-aware scheduling strategy for scientific workflows in fog computing[J]. *Expert Systems with Applications*, 2024, 247: 123192.
- [5] LIU J L. Path analysis of energy economic management standardization in the context of carbon neutralization and carbon peak[J]. *Frontiers in Ecology and Evolution*, 2023, 11: 1155401.

表5 炼钢厂各季节 MK 趋势检验

季节	S	$\text{Var}(S)$	Z_c	P	β	发展趋势
春	41.0	165.0	3.11	0.0018	>0	上升趋势
夏	41.0	165.0	3.11	0.0018	>0	上升趋势
秋	41.0	165.0	3.11	0.0018	>0	上升趋势
冬	39	165.0	2.96	0.0031	>0	上升趋势

- [6] FAN D Y, SUN H, YAO J, et al. Well production forecasting based on ARIMA-LSTM model considering manual operations[J]. *Energy*, 2021, 220: 119708.
- [7] ZHENG L, MUELLER M, LUO C B, et al. Predicting whole-life carbon emissions for buildings using different machine learning algorithms: a case study on typical residential properties in Cornwall, UK[J]. *Applied Energy*, 2024, 357: 122472.
- [8] CAI K, WU L F. Grey prediction of carbon emission and carbon peak in several developing countries[J]. *Engineering Applications of Artificial Intelligence*, 2024, 133: 108210.
- [9] LIU B, CHANG H D, LI Y, et al. Carbon emissions predicting and decoupling analysis based on the PSO-ELM combined prediction model: evidence from Chongqing Municipality, China[J]. *Environmental Science and Pollution Research International*, 2023, 30(32): 78849-78864.
- [10] 国家发展和改革委员会办公厅. 关于印发首批10个行业企业温室气体排放核算方法与报告指南(试行)的通知: 发改办气候[2013]2526号[S]. 2013.
General Office of the National Development and Reform Commission. Notice on printing and distributing the first batch of greenhouse gas emission accounting methods and reporting guidelines for enterprises in 10 industries (for trial implementation): fa gai ban climate [2013]No.2526[S]. 2013.
- [11] PRIARONE P C, CATALANO A R, SETTINERI L. Additive manufacturing

for the automotive industry: on the life-cycle environmental implications of material substitution and lightweighting through re-design[J]. Progress in Additive Manufacturing, 2023, 8(6): 1229-1240.

[12] 朱广新, 周春雷, 李俊妮, 等. 基于图模型的电力系统碳流计算优化研究[J]. 大数据, 2024, 10(2): 179-191.

ZHU G X, ZHOU C L, LI J N, et al.

Research on power system carbon flow calculation based on graph database and graph computing engine[J]. Big Data Research, 2024, 10(2): 179-191.

[13] ZHANG Z, ZHANG S Q, CHEN C M, et al. A systematic survey of air quality prediction based on deep learning[J]. Alexandria Engineering Journal, 2024, 93: 128-141.

作者简介



李风云 (1981-), 女, 博士, 东北大学计算机科学与工程学院副教授, 主要研究方向为工业互联网、车联网、网络安全、数据隐私保护。



竇泽慧 (2001-), 女, 东北大学计算机科学与工程学院硕士生, 主要研究方向为联邦学习、信息安全。



李朋 (1980-), 男, 沈阳市城市学院智能与工程学院讲师, 主要研究方向为工业互联网、联邦学习。



郭威 (2000-), 男, 东北大学计算机科学与工程学院硕士生, 主要研究方向为故障诊断、领域泛化、开集识别。

收稿日期: 2024-04-15

通信作者: 李朋, 512672446@qq.com

基金项目: 国家重点研发计划项目 (No.2022YFE0114200)

Foundation Item: The National Key Research and Development Program of China(No.2022YFE0114200)