

DOI:10.19322/j.cnki.issn.1006-4710.2025.04.005

<https://xuebao.xaut.edu.cn>

引文格式:高晓明,许文峰,邱浪,任高峰,郑一柳,么学春,徐琛.基于VMD-LSTM的高速公路综合场站碳排放预测研究[J].

西安理工大学学报,2025,41(4):499-508.

GAO Xiaoming, XU Wenfeng, QIU Lang, REN Gaofeng, ZHENG Yiliu, YAO Xuechun, XU Chen. Carbon emission prediction of expressway integrated station based on VMD-LSTM[J]. Journal of Xi'an University of Technology, 2025, 41(4): 499-508.

基于 VMD-LSTM 的高速公路综合场站 碳排放预测研究

高晓明^{1,2}, 许文峰^{1,2}, 邱浪³, 任高峰³, 郑一柳^{1,2}, 么学春^{1,2}, 徐琛³

(1. 中交建筑集团有限公司, 北京 100022; 2. 中交建筑集团东南建设有限公司, 福建 厦门 361000;

3. 武汉理工大学 资源与环境工程学院, 湖北 武汉 430070)

摘要: 高速公路综合场站是桥梁及公路建设中能源消耗与碳排放的关键节点。为实现对其碳排放的精准预测, 本文基于长修高速封丘至修武段综合场站 146 天的能耗监测数据, 创新性地构建了变分模态分解(VMD)联合长短期记忆网络(LSTM)的碳排放预测模型。结果表明: VMD-LSTM 模型能有效捕捉综合场站碳排放的周期性变化规律, 其预测值与实际值的趋势高度吻合; 该模型预测性能优异, 准确率(AR)达 94.32%, 均方误差(MSE)为 0.099 3, 均方根误差(RMSE)为 0.315 0, 决定系数(R^2)为 0.973 9, 显著优于传统 LSTM 模型。研究结果可为高速公路综合场站精准节能减排提供理论指导与技术支持。

关键词: 高速公路综合场站; 碳排放; 变分模态分解; 长短期记忆网络; 预测模型

中图分类号: X321

文献标志码: A

文章编号: 1006-4710(2025)04-0499-10

Carbon emission prediction of expressway integrated station based on VMD-LSTM

GAO Xiaoming^{1,2}, XU Wenfeng^{1,2}, QIU Lang³, REN Gaofeng³, ZHENG Yiliu^{1,2},
YAO Xuechun^{1,2}, XU Chen³

(1. China Communications Construction Group Co., Ltd, Beijing 100022, China;

2. China Communications Construction Group Southeast Construction Co., Ltd, Xiamen 361000, China;

3. School of Resources and Environmental Engineering, Wuhan University of Technology, Wuhan 430070, China)

Abstract: Highway integrated stations are critical nodes for energy consumption and carbon emissions in bridge and road construction. To achieve the accurate prediction of its carbon emission, this paper innovatively constructs a carbon emission prediction model combining variational mode decomposition(VMD) and long short-term memory(LSTM) networks, based on 146 days of energy consumption monitoring data from the integrated station of the Changxiu Expressway's Fengqiu to Xiuwu section. The results show that the VMD-LSTM model effectively captures the periodic variation patterns of carbon emissions at the integrated station, with its predicted values trending highly consistent with actual values trends. The model demonstrates excellent a predictive performance, achieving an accuracy rate (AR) of 94.32%, mean squared error (MSE) of 0.099 3, root mean squared error (RMSE) of 0.315 0, and coefficient of determination (R^2) of 0.973 9, significantly outperforming the traditional LSTM model. The research findings provide

收稿日期: 2024-10-24; 网络首发日期: 2025-04-11

网络首发地址: <https://link.cnki.net/urlid/61.1294.n.20250410.1706.002>

基金项目: 中国施工企业管理协会重大科研项目(2023-A-032)

第一作者: 高晓明, 男, 学士, 高级工程师, 研究方向为高速公路建设管理及建筑碳减排。E-mail: 516895748@qq.com

通信作者: 徐琛, 男, 博士, 特设副教授, 研究方向为隧道施工、机器学习及碳减排路径优化。E-mail: xuchen_office@163.com

the theoretical guidance and technical support for precise energy conservation and carbon reduction in highway integrated stations.

Key words: expressway integrated station; carbon emission; VMD; LSTM; prediction model

交通行业是推动经济发展、保障国家安全和促进创新环保产业发展的重要产业,同时也是我国的基础行业 and 主要碳排放产业之一,促进行业内达成“碳达峰、碳中和”对于我国减碳目标的实现具有举足轻重的作用。国际能源署数据显示,2022 年中国碳排放总量约为 121 亿吨,其中交通运输领域约占 10.4%,是除了电力、工业外第三大碳排放来源。高速公路综合场站是对桥梁及公路建设所需原材料进行初加工的临时场地和运输中枢,是能源消耗和碳排放的聚集地和高发地。在“双碳”战略背景下,高速公路综合场站作为交通基建临时性碳排放大户,因其高能耗、动态波动和短周期的特点,其碳排放预测面临时空异质性显著、多工序驱动机制复杂及传统模型适配性差等挑战。开展综合场站碳排放预测可为未来建设项目的精准碳评估、动态碳管理以及低碳技术应用提供科学依据,是推动交通建筑行业绿色转型和实现“双碳”目标的重要技术支撑。

随着人工智能的发展,许多学者开始将机器学习方法应用于实际工程的数据分析中^[1-2]。在碳排放预测领域,国内外学者已针对机器学习方法的应用开展了大量研究。胡剑波等^[3]基于 LSTM 模型预测出我国碳排放强度的变化趋势,并建立 ARIMA-BP 神经网络模型作为验证。王火根等^[4]采用 IO-SDA 法测算了中国不同行业 2017—2020 年的碳排放量,并结合预测数据分析了 2020—2060 年的碳排放变化趋势及其驱动因素。胡剑波等^[5]基于 2000—2020 年中国工业行业相关数据,构建了反向传播(BP)神经网络预测模型,预测了 2020—2030 年中国工业的碳排放量。刘淳森等^[6]基于可拓展的随机性环境影响评估(STIRPAT)模型,选取人口、机动车保有量和能源强度等 8 个变量作为影响因素,构建了中国交通运输业 LSTM 碳排放预测模型。Tang 等^[7]通过筛选交通运输碳排放的关键影响因素,提出了一种基于麻雀搜索算法(SSA)的改进 LSTM 预测模型。Wu 等^[8]基于情景分析法和循环神经网络,构建了 LSTM 碳排放情景预测模型。Kong 等^[9]采用集合经验模态分解(EEMD)和 VMD 相结合的二次分解技术对原始数据进行处理,使用 LSTM 对碳排放量进行预测。Wang 等^[10]使用麻雀搜索算法对 LSTM 的超参数进行优化,提出了燃煤电厂 SSA-LSTM 碳排放回归预测模型。池小波等^[11]提出了一种分量增广输入的 WPD-ISSA-

CA-CNN 碳排放量预测模型。肇晓楠等^[12]通过将滑动窗口与 LSTM 网络相结合,构建了铁路运输碳排放量预测模型。鲍学英等^[13]运用轻量级梯度提升机(LightGBM)算法构建了碳排放预测模型,并通过可解释机器学习模型分析了影响因素对碳排放的贡献。王庆荣等^[14]采用一种融合变分模态分解(VMD)、麻雀搜索算法(SSA)和最小二乘支持向量机(LSSVM)的预测模型对交通运输业碳排放量进行了精准预测。对于较小区域的碳排放预测,也有学者做了相关研究。胡雨沙等^[15]针对制浆造纸过程中的碳排放预测,提出了一种基于 VMD-BO-BPNN-QR 的区间预测模型。杨历夏等^[16]提出了一种改进麻雀算法优化的 BP 神经网络模型,该模型通过小样本数据实现了车削加工碳排放与加工时间的高精度多目标预测。曾弘锐等^[17]基于案例分析,构建了铁路隧道施工 WOA-BP 碳排放预测模型。

综上所述,在碳排放预测领域,学者们通过使用机器学习模型取得了一定的研究成果,但目前仍存在以下问题:1)现有研究大多聚焦于较大尺度的碳排放预测,如全国、省域或某一行业的碳排放预测,对于较小区域的碳排放预测研究较少;2)部分模型预测精度有限,误差较大;3)数据集大多来源于统计与核算,而不是基于现场监测数据。基于以上问题,本文先根据监测所得高速公路综合场站化石燃料消耗量与电力消耗量,计算出 2024 年施工期 146 天的每日碳排放总量,而后以此时间序列为数据集,利用变分模态分解将时间序列数据分解为多个模态分量,然后使用每一模态分量的训练集数据训练 LSTM 模型,使用测试集数据进行预测,最后将每一模态分量的预测结果合并作为最终预测结果。同时,建立 LSTM 模型与之进行对比,以验证 VMD-LSTM 模型的适用性与优越性。

1 项目概况

长修高速封丘至修武段 SG-2 标段位于新乡市原阳县、新乡县境内,起点桩号 K75+000,终点桩号 K105+000。标段长 30 km,桥梁总长 9.92 km,桥梁比 33.07%。综合场站建设在主线路桩号 K104+100 右侧 840 m 处,占地 90 068 m²,约 135 亩。综合场站由混凝土拌合站、沥青搅拌站、水稳拌合站、梁场、钢筋场、驻地六部分组成(见图 1)。该场站建设有排碳耗能智能动态监测系统。该系统以高速公路综合场站的

“三站两场一驻地”为监测对象,通过在现场布置电表、气体计量器、水量计量器等相关设备来监测耗油量、耗电量、耗水量、碳排放量和水泥等原材料用量。



图1 高速公路综合场站

Fig. 1 Expressway integrated station

2 研究方法

2.1 变分模态分解原理

变分模态分解^[1](variational mode decomposition, VMD)是一种信号处理方法,用于将复杂信号分解为若干个具有不同频率特征的本征模态函数(intrinsic mode function, IMF)。与传统的经验模态分解相比,VMD 在处理非线性、非平稳信号方面具有更好的鲁棒性和稳定性。其核心思想是通过变分框架寻找各个模态,使每个模态的频谱尽可能集中,从而实现信号的分解。

VMD 的目标是将输入信号 $f(t)$ 分解为 K 个模态函数 $\{u_k(t)\}_{k=1}^K$,每个模态函数具有中心频率 $\{\omega_k\}_{k=1}^K$ 。具体来说,VMD 通过求解以下优化问题来实现信号的分解:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + j \frac{1}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

式中: $\delta(t)$ 为狄拉克函数; ∂_t 为时间导数; j 为虚数单位; e 为自然常数; $*$ 表示卷积运算。

该优化问题的物理意义是使每个模态函数的频谱尽可能集中在其中心频率附近。为了求解上述优化问题,采用拉格朗日乘子法引入约束条件,并使用交替方向乘子法进行迭代求解。具体步骤如下:

1) 构造带有约束条件的拉格朗日函数。

$$\begin{aligned} \mathcal{L}(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + j \frac{1}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \end{aligned} \quad (2)$$

式中: α 为权重参数; $\lambda(t)$ 为拉格朗日乘子; $\langle \cdot \rangle$ 表示

内积运算。

2) 对于每个模态函数和中心频率,交替进行以下步骤直至收敛。

固定 $\{u_i\}_{i \neq k}$ 和 $\{\omega_i\}_{i \neq k}$,更新 $u_k(t)$:

$$u_k^{n+1}(t) = \arg \min_{u_k} \mathcal{L}(\{u_i^n\}_{i \neq k}, u_k, \{\omega_i^n\}, \lambda^n) \quad (3)$$

固定 $\{u_i^{n+1}\}$ 和 $\{\omega_i\}_{i \neq k}$,更新 ω_k :

$$\omega_k^{n+1} = \arg \min_{\omega_k} \mathcal{L}(\{u_i^{n+1}\}, \omega_k, \lambda^n) \quad (4)$$

更新拉格朗日乘子 $\lambda(t)$:

$$\lambda^{n+1}(t) = \lambda^n(t) + \tau \left(f(t) - \sum_{k=1}^K u_k^{n+1}(t) \right) \quad (5)$$

2.2 LSTM 原理

长短期记忆网络(long short-term memory, LSTM)是一种特殊的循环神经网络^[18],其通过门控机制有效解决了传统循环神经网络的长期依赖问题。LSTM 通过引入门控机制来控制信息的流动,从而能够学习到长期序列中的依赖关系。LSTM 的核心是一个细胞状态,它像一条输送带,信息可以被添加、移除或不变地传递下去。这些操作由遗忘门、输入门、输出门控制。遗忘门决定了哪些信息从细胞状态中丢弃。输入门有两个功能,一是决定哪些新信息存储到细胞状态中,二是负责创建新候选值。输出门决定了哪部分的细胞状态被输出为当前时间步的隐藏状态。LSTM 的网络结构如图 2 所示。




图2 LSTM 网络结构

Fig. 2 LSTM network structure

假设序列 x_t 表示时间步 t 的输入向量, h_t 是 LSTM 在时间步 t 的输出, c_t 是细胞状态,则每个门和细胞状态的更新过程如下。

1) 遗忘门赋予 LSTM 精细化的记忆管理能力,使其能自适应地平衡长期记忆与短期输入的关联性。遗忘门的输出是一个介于 0 到 1 之间的值,0 表示完全删除,1 表示完全保留。

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (6)$$

式中: W_f 为权重矩阵; b_f 为偏置项; σ 为激活函数。

2) 输入门由输入门控制与候选细胞状态组成,

前者用于决定哪些新信息将存储到细胞状态中,后者则负责创建新候选值。

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (7)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (8)$$

式中: W_i 和 W_c 分别为输入门控制和候选细胞状态的权重矩阵; b_i 和 b_c 为对应的偏置项。

3) 细胞状态根据遗忘门和输入门的结果进行更新。

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (9)$$

4) 输出门决定了哪部分的细胞状态将被输出。

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (10)$$

式中: W_o 和 b_o 分别为输出门的权重矩阵和偏置项。

5) 最终的隐藏状态 h_t 是细胞状态经过激活后的结果,然后乘以输出门的输出。

$$h_t = o_t \cdot \tanh(c_t) \quad (11)$$

2.3 评估指标选取

本文选用准确率(AR)、均方误差(MSE)、均方根误差(RMSE)、决定系数(R^2) 4 项评价指标来评估模型的预测性能。其中,AR 反映了预测的精确程度;MSE 表示预测值与真实值之间差异的平方平均值;RMSE 是 MSE 的平方根; R^2 则衡量了模型解释变量变异性的比例,反映了模型的拟合优度。其计算公式为:

$$R_{AR} = \frac{1}{n} \sum_{i=1}^n \left(1 - \frac{|y_i - \hat{y}_i|}{y_i} \right) \quad (12)$$

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

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

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

式中: y_i 、 \hat{y}_i 、 \bar{y} 分别为实际值、预测值、实际值均值; n 为测试样本数量。

各指标的取值范围及数值含义如表 1 所示。

表 1 评价指标取值范围

Tab. 1 Range of values for evaluation metrics

评价指标	取值范围	数值含义
R_{AR}	$[0, 1]$	越接近 1 预测效果越好
R_{MSE}	$[0, +\infty]$	越小预测效果越好
R_{RMSE}	$[0, +\infty]$	越小预测效果越好
R^2	$[-\infty, 1]$	越接近 1 预测效果越好

2.4 碳排放量核算

2.4.1 核算方法

依据政府间气候变化专门委员会(IPCC)提供的国家温室气体清单指南,本文采用排放因子法来计算高速公路综合场站各阶段的碳排放量。排放因子法是 IPCC 提出的一种碳排放量估算方法,它依照碳排放清单列表,针对每一种排放源构造活动数据与排放因子,以投入的能源使用量和排放因子的乘积作为该排放项目的碳排放量估算值:

$$G_{HG} = A_D \times E_F \quad (16)$$

式中: G_{HG} 为二氧化碳排放量; A_D 是导致温室气体排放的生产或消费活动的活动量,如每种化石燃料的消耗量、石灰石原料的消耗量、净购入的电量、净购入的蒸汽量等; E_F 为单位生产或消费活动量的温室气体排放系数,包括单位热值含碳量或元素碳含量、氧化率等。 E_F 既可以采用 IPCC、美国环境保护署、欧洲环境机构等提供的已知数据,也可以基于代表性测量数据来推算。

2.4.2 核算边界

综合场站主要由混凝土拌合站、沥青搅拌站、水稳拌合站、梁场、钢筋场、驻地 6 个部分组成。图 3 为综合场站碳排放来源。

水稳拌合站专门用来拌合水稳料,水稳料一般包括水泥、粉煤灰、级配碎石和稳定土层料等。沥青拌合站专门用来拌合沥青熟料,主要拌合沥青(分为改性沥青、90# 沥青等)、机制砂、碎石、河沙、聚酯纤维、钢纤维和质纤维等原料组成的沥青稳定土。混凝土拌合站专门用来制作、搅拌混凝土料,它主要拌合附剂、沙、水泥和膨润土等。拌合站设备主要消耗电能,罐车、装载机和卡车等消耗柴油。梁场是生产桥梁预制混凝土简支梁的地方,简支梁生产完毕后,用运梁机和架梁机运输架设到施工场地上,预制梁生产涉及多种生产工艺和多套施工设备,是高速公路综合场站生产的主体部分,其生产设备主要消耗电能,移梁台车等运梁设备则消耗柴油。钢筋场承担钢筋的加工任务,施工时尽量集中加工钢筋,加工好的钢筋采用集中配送的方式,直接输送至各施工点,以减少二次搬运量。驻地是为了方便场站施工人员开展工作、生活而建设的区域,主要包括试验室、办公楼和生活区等。

2.4.3 核算模型

化石燃料燃烧是综合场站重要的碳排放来源,本文主要考虑罐车、装载机、卡车等车辆运输物料所产生的碳排放量,具体测算公式为:

$$E_{fue} = D_{fue} \times F_{fue} \quad (17)$$

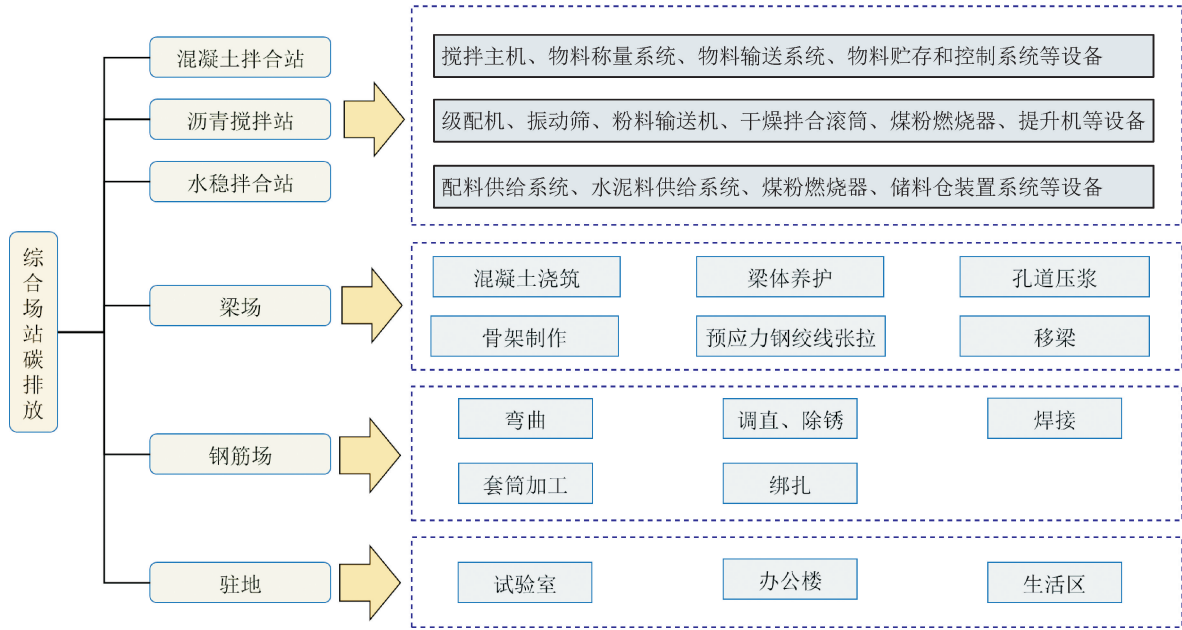


图 3 碳排放来源

Fig. 3 Carbon emission sources

式中: E_{fue} 为综合场站核算年度内化石燃料燃烧产生的 CO_2 排放量, tCO_2 ; D_{fue} 为综合场站核算年度内各种设备消耗的化石燃料量, t ; F_{fue} 为化石燃料的 CO_2 排放因子, tCO_2/t 。柴油的碳排放因子取 $1.7 \text{ tCO}_2/\text{t}$ 。

工业生产过程中的碳排放是指除化石燃料燃烧之外的物理或化学变化所造成的二氧化碳排放。施工过程中, 化学反应的碳排放测算宜包括生产混凝土所产生的二氧化碳排放, 具体测算公式为:

$$E_{\text{pro}} = \sum_{i=1}^n (A_i \times E_i) \quad (18)$$

式中: E_{pro} 为综合场站核算年度内化石工业生产活动产生的 CO_2 排放量, tCO_2 ; A_i 为综合场站核算年度内第 i 种工业生产过程的的活动数据, 主要指综合场站预制梁生产所消耗的混凝土数量, t ; E_i 为第 i 种工业生产活动的碳排放因子, tCO_2/t 。混凝土碳排放因子取 $0.002146 \text{ tCO}_2/\text{t}$ 。

电力消耗是综合场站最主要的碳排放来源, 本文主要考虑钢筋场、梁场、拌合站等场站的耗电设备工作所产生的碳排放, 具体公式为:

$$E_{\text{ele}} = \sum_{j=1}^n (D_j \times F_{\text{ele}}) \quad (19)$$

式中: E_{ele} 为综合场站核算年度内消耗电力所产生的 CO_2 排放量, tCO_2 ; D_j 为综合场站核算年度内第 j 种耗电设备运行所消耗的电量, $\text{MW} \cdot \text{h}$; F_{ele} 为工业用电的碳排放因子, $\text{tCO}_2/(\text{MW} \cdot \text{h})$ 。全国电网推荐的碳排放因子为 $0.5703 \text{ tCO}_2/(\text{MW} \cdot \text{h})$ 。

人工碳排放量主要是指综合场站现场工作人员在工业生产和建筑施工等人类活动中消耗能源所产生的碳排放量, 主要通过测算人员每日衣食住行的能源消耗量, 再经过换算, 得到综合场站人工碳排放量, 具体公式为:

$$E_{\text{per}} = \sum_{k=1}^n (k \times F_{\text{per}}) \quad (20)$$

式中: E_{per} 为综合场站核算年度内人工产生的碳排放量, tCO_2 ; k 为综合场站核算年度内的第 k 天; F_{per} 为人工碳排放因子, $\text{tCO}_2/(\text{人} \cdot \text{日})$ 。人工碳排放因子取 $0.0004604 \text{ tCO}_2/(\text{人} \cdot \text{日})$ 。

根据综合场站 2024 年的施工期监测数据, 由以上核算模型可计算出每日的碳排放总量, 其变化趋势如图 4 所示。对于所得的 146 组时间序列数据, 将其中前 80% 作为训练集(117 组数据), 后 20% 作为测试集(29 组数据), 以备使用。




图 4 碳排放量变化

Fig. 4 Changes in carbon emissions

2.5 模型构建

由于 VMD 与 LSTM 模型中的参数会对最终预测结果产生较大影响,因此选取合适的参数组合是获得良好预测结果的关键。本文使用网格搜索方法分别对 VMD 的 K 、 α (表 2),LSTM 的单元数量、批次大小、学习率、训练周期(表 3)进行寻优,目标函数为 MSE。网格划分规则见表 4。构建 VMD-LSTM 模型如图 5 所示,具体流程如下:

- 1) 设定 VMD 的参数 K 、 α 的候选值范围(表 4),对于每个 (K, α) 组合,应用 VMD 将原始时间序列数据分解为多个模态分量;
- 2) 计算每个 (K, α) 组合分解后的多个模态分量之和与原始数据间的 MSE,选取最小 MSE 所对应的参数 K 、 α ;
- 3) 利用所得 K 、 α 对原始数据进行变分模态分解,得到 n 个模态分量;

4) 将每个模态分量中前 80% 的数据作为训练集,后 20% 的数据作为测试集,确定 LSTM 的参数范围;对于每一个模态分量,使用表 4 中的候选值构建 LSTM 模型;

5) 创建一个包含所有超参数组合的网格,对于每个超参数组合,使用交叉验证方法训练 LSTM 模型,并计算其 MSE 作为评估指标,然后记录每个组合的 MSE 值;

6) 找出最小 MSE 值对应的超参数组合,使用最佳超参数组合重新训练模型;

7) 使用最佳 LSTM 模型对每个模态分量进行预测,将所有模态分量的预测结果合并成最终的预测结果;

8) 计算测试集中预测值的 AR、MSE、RMSE 和 R^2 ,评估预测效果。

表 2 VMD 参数及其影响
Tab. 2 VMD Parameters and their impact

参数	影响
模态数量(K)	K 值较小会导致分解出来的模态分量较少,无法充分捕捉到信号中的所有细节特征。 K 值较大会得到更多的模态分量,这样能够更精细地描述原始信号,但会导致某些模态过于细微或重复,增加了解释难度。
加权参数(α)	当 α 较小时,算法对模态之间的频域分离要求较弱,使得模态之间在频域上的重叠较多。 当 α 较大时,算法倾向于将模态在频域上严格分离,减少模态间的频谱重叠。 当 α 过大时,可能会导致过拟合问题,即生成的模态分量可能不符合实际信号的特点。

表 3 LSTM 参数及其影响
Tab. 3 LSTM parameters and their impact

超参数	影响
单元数量	较少的单元数量会导致模型的学习能力受限,不足以捕获序列数据中的复杂模式,从而导致欠拟合现象,使得预测性能较差;较多的单元数量可以让模型学习更复杂的模式,提高其拟合能力,但过多的单元数量会导致过拟合现象。
批次大小	较小的批次可以提高模型的泛化能力并有助于避免过拟合,但因计算效率较低,整体训练速度可能会变慢;较大的批次可以提高计算效率,但会导致梯度估计不够准确,影响收敛速度和最终性能,并使模型难以逃出局部最小值。
学习率	较小的学习率会导致训练过程缓慢,并可能使模型困在局部最小值附近;而较大的学习率虽能加速训练过程,但若过大,会导致训练过程不稳定,甚至发散。
训练周期	较少的训练周期会导致模型欠拟合,而较多的训练周期虽可让模型更好地拟合数据,但若设置过高,会导致过拟合。

表 4 参数的网格划分
Tab. 4 Grid division of parameters

参数	候选值
模态数量(K)	$[2,10]$ 中的整数值
加权参数(α)	将 $[100,2000]$ 平均分为 100 段的端点值
单元数量	$\{32,64,128,256\}$
批次大小	$\{32,64,128\}$
学习率	$\{0.001,0.01,0.1\}$
训练周期	$\{10,40,70,100\}$

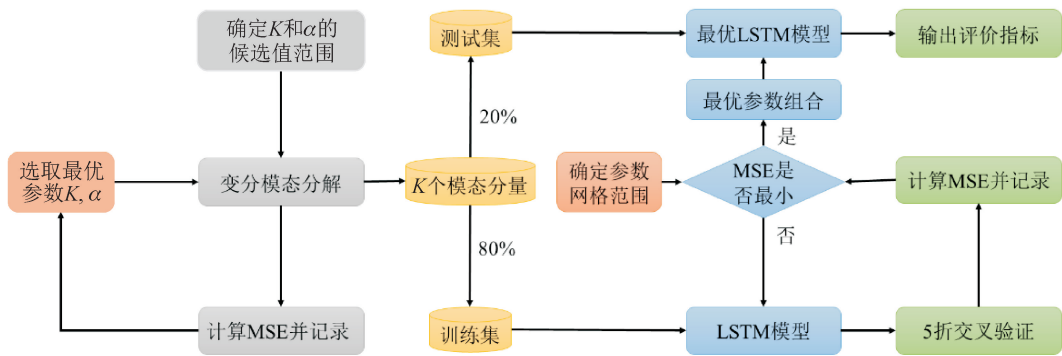


图 5 VMD-LSTM 模型
Fig. 5 VMD-LSTM model

3 预测结果与对比分析

3.1 VMD 分解结果

将原始碳排放量时间序列数据输入 VMD-LSTM 模型中,以分解后多个模态分量之和与原始数据间的 MSE 为适应度函数,利用网格搜索方法对参数

K, α 进行寻优,寻优结果为 $K=4, \alpha=176.76$,适应度值为 0.003 15。VMD 分解中其他参数设置如下:时间间隔 $\tau=1.0$ 、不保留直流分量 ($DC=False$)、初始化方法为随机初始化 ($init=random$)、容差 $tol=0.001$ 。依据上述参数执行 VMD 可得到 4 个具有不同中心频率的模态分量,如图 6 所示。




图 6 VMD 分解结果
Fig. 6 VMD decomposition results

3.2 预测结果

将所得 4 个具有不同中心频率的模态分量分别输入 LSTM 模型中,以 MSE 为适应度函数,使用 K 折交叉验证方法训练并评估 LSTM 模型,利用网格搜索方法对单元数量、批次大小、学习率、训练周期进行寻优,而后使用寻优所得参数训练模型,之后使用测试集进行预测,得到 4 个模态分量的预测结果,最后合并所有预测结果即为最终预测结果,如图 7 所示。




图 7 VMD-LSTM 模型预测结果

Fig. 7 VMD-LSTM model prediction results

从图 7 中可以看出,高速公路综合场站的碳排放量呈现周期性变化,一个周期约为 9~10 天,且周期内呈现先增加再减少的趋势。这是由于综合场站的生产计划、运输安排等使得物料产出具有周期性变化。预测结果中,预测值的周期性变化趋势与实际值的趋势吻合程度较高,说明模型对周期性变化的捕捉能力较强,具备较高的整体预测精度。

3.3 对比分析

为评估 VMD-LSTM 模型的预测效果与精度,本文构建了 LSTM 模型与之进行对比。由图 8 可以看出,LSTM 模型的预测值变化趋势与实际值变化趋势吻合程度较低,第 23、25 号预测值误差均已超过 100%,其余误差在 0%~40%,说明 VMD-LSTM 模型预测性能更好,预测精度更高。




图 8 LSTM 模型预测结果

Fig. 8 LSTM model prediction results

从图 9 可以看出,VMD-LSTM 模型的 4 个评价指标表现更优,其 AR、MSE、RMSE、 R^2 值分别为 94.32%、0.099 3、0.315 0、0.973 9,与 LSTM 模型相比,其 AR、 R^2 分别提升了 52.42%、195.12%,

MSE、RMSE 分别降低了 96.18%、80.47%。




图 9 各评价指标对比

Fig. 9 Comparison of various evaluation indicators

综上所述,与传统 LSTM 模型相比,VMD-LSTM 模型预测效果更好、误差更小、拟合程度更高。这是因为 VMD 能够将原始时间序列分解成多

个 IMF, 这些 IMF 往往包含了不同频率成分的信息, 可视为对原始信号的降噪处理和特征提取。分解后的 IMF 通常比原始信号更为线性和平稳, 这使得后续的 LSTM 模型更易捕捉到数据的趋势和模式。通过对不同频率的 IMF 单独进行建模, 可以减少模型之间的相互干扰, 从而提高整体的预测精度, 即使某些 IMF 受到噪声影响, 其他 IMF 仍然能够提供有用的信息, 因此整个预测模型会更加稳定。

3.4 不足与展望

本文提出了一个结合 VMD 与 LSTM 的高速公路场站碳排放预测模型。该模型使用 VMD 将碳排放量时间序列分解为多个 IMF 来捕捉时间序列的周期性变化, 而后使用 LSTM 对多个 IMF 分量进行预测, 从而实现每日碳排放量的预测。结果表明, 所提的 VMD-LSTM 模型比传统 LSTM 模型具有更好的泛化能力与预测精度。但是, 该方法还存在以下不足。

1) 数据覆盖的时空维度受限。现有研究仅基于场站施工期 146 天的碳排放总量数据进行建模, 存在时间跨度短、空间分辨率低的双重局限, 导致模型难以准确捕捉碳排放的长期演化规律及空间异质性特征, 制约了对碳排放源头的溯源分析能力。

2) 动态影响因素的耦合机制考虑不足。现有模型过度依赖历史碳排放数据, 未充分考虑施工动态因素(如工期调整、节假日停工、极端天气等)对碳排放的复杂影响, 且缺乏突发事件量化分析方法, 导致其在施工计划频繁变动场景下的预测稳定性不足, 仅适用于常规稳定工况。

未来研究需聚焦两个方向: 一是收集覆盖施工期全过程的碳排放数据, 结合建筑信息模型(BIM)、地理信息系统(GIS)建立三维模型, 利用时空图网络分析空间差异; 二是融合天气、施工记录等动态数据, 用贝叶斯网络分析突发事件的影响, 同时结合物理模型和数据驱动方法构建智能预测系统。此外, 还可开发分层预测架构, 加入行业知识图谱, 通过轻量化模型实现“整体预测-局部监测”同步输出, 最终提升复杂施工场景的预测可靠性, 以支持实时监测和低碳决策。

4 结 论

高速公路综合场站是桥梁及公路建设过程中能源消耗和碳排放的聚集地和高发地。为了实现高速公路综合场站每日碳排放量的精准预测, 本文创新性地采用了 VMD 与 LSTM 相结合的 VMD-LSTM 模型来预测高速公路综合场站的碳排放量变化。

1) 预测结果中, 预测值的周期性变化趋势与实际值的趋势吻合程度较高, 说明模型对周期性变化的捕捉能力较强, 具备较高的整体预测精度。

2) 与 LSTM 模型相比, VMD-LSTM 模型的准确率(AR)、均方误差(MSE)、均方根误差(RMSE)、决定系数(R^2)表现更优, 分别为 94.32%、0.099 3、0.315 0、0.973 9。这说明 VMD-LSTM 模型在预测高速公路综合场站的碳排放量时性能优异, 预测效果好、误差小、拟合程度高。

参考文献:

- [1] 彭康, 蒋丽忠, 周旺保, 等. 基于贝叶斯自优化 Bi-LSTM 组合网络的高速铁路轨道-桥梁系统震后响应预测方法(英文)[J]. 中南大学学报(英文版), 2024, 31(3): 965-975.
PENG Kang, JIANG Lizhong, ZHOU Wangbao, et al. A seismic response prediction method based on a self-optimized Bayesian Bi-LSTM mixed network for high-speed railway track-bridgesystem[J]. Journal of Central South University, 2024, 31(3): 965-975.
- [2] WANG Yili, LI Changsheng, WANG Xiaofeng. A multi-source information fusion layer counting method for penetration fuze based on TCN-LSTM[J]. Defence Technology, 2024, 33(3): 463-474.
- [3] 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(2): 89-101.
HU Jianbo, LUO Zhipeng, LI Feng. Prediction of China's carbon emission intensity under the goal of carbon peak—analysis based on LSTM and ARIMA-BP model [J]. Finance & Economics, 2022(2): 89-101.
- [4] 王火根, 汪钰婷, 肖丽香. 基于 IO-SDA 法的 2020~2060 年中国行业 CO₂ 排放预测与分析[J]. 中国环境科学, 2024, 44(3): 1743-1755.
WANG Huogen, WANG Yuting, XIAO Lixiang. Forecast and analysis of China's industrial CO₂ emissions from 2020 to 2060 based on the IO-SDA method [J]. China Environmental Science, 2024, 44(3): 1743-1755.
- [5] 胡剑波, 赵魁, 杨苑翰. 中国工业碳排放达峰预测及控制因素研究——基于 BP-LSTM 神经网络模型的实证分析[J]. 贵州社会科学, 2021, 381(9): 135-146.
- [6] 刘淳森, 曲建升, 葛钰洁, 等. 基于 LSTM 模型的中国交通运输业碳排放预测[J]. 中国环境科学, 2023, 43(5): 2574-2582.
LIU Chunsen, QU Jiansheng, GE Yujie, et al. LSTM model-based prediction of carbon emissions from China's transportation sector [J]. China Environmental

- Science, 2023, 43(5): 2574-2582.
- [7] TANG Jianxin, GONG Rizhao, WANG Huilin, et al. Scenario analysis of transportation carbon emissions in China based on machine learning and deep neural network models[J]. Environmental Research Letters, 2023, 18(6): 1-13.
- [8] WU Qixian, CHEN Yun, LI Congying, et al. Carbon emission scenario prediction for highway construction projects[J]. Frontiers in Environmental Science, 2024, 11(1): P1302220.
- [9] KONG Feng, SONG Jianbo, YANG Zhongzhi. A novel short-term carbon emission prediction model based on secondary decomposition method and long short-term memory network[J]. Environmental Science and Pollution Research, 2022, 29(43): 64983-64998.
- [10] WANG Xindong, YAN Chun, LIU Wei, et al. Research on carbon emissions prediction model of thermal power plant based on SSA-LSTM algorithm with boiler feed water influencing factors[J]. Sustainability, 2022, 14(23): P15988.
- [11] 池小波, 续泽晋, 贾新春, 等. 基于 WPD-ISSA-CA-CNN 模型的电厂碳排放预测[J/OL]. 控制工程, 1-8 [2025-06-03]. <https://doi.org/10.14107/j.cnki.kzgc.20220983>.
- CHI Xiaobo, XU Zejin, JIA Xinchun, et al. WPD-ISSA-CA-CNN model based carbon emission prediction in power plants[J/OL]. Control Engineering of China, 1-8 [2025-06-03]. <https://doi.org/10.14107/j.cnki.kzgc.20220983>.
- [12] 肇晓楠, 谢新连, 赵瑞嘉. 基于滑动窗口动态输入 LSTM 网络的铁路运输系统碳排放量预测方法[J]. 交通信息与安全, 2023, 41(1): 169-178.
- ZHAO Xiaonan, XIE Xinlian, ZHAO Ruijia. A method for predicting carbon emission of railway transportation system based on an LSTM network with dynamic input via sliding window[J]. Journal of Transport Information and Safety, 2023, 41(1): 169-178.
- [13] 鲍学英, 韩通, 霍雨雨. 铁路轨道工程物化阶段碳排放预测及影响因素研究[J]. 铁道科学与工程学报, 2024, 21(10): 4299-4310.
- BAO Xueying, HAN Tong, HUO Yuyu. Research on carbon emission prediction and influencing factors in the embodied stage of railway trackengineering[J]. Journal of Railway Science and Engineering, 2024, 21(10): 4299-4310.
- [14] 王庆荣, 王俊杰, 朱昌锋, 等. 融合 VMD 和 SSA-LSSVM 的交通运输业碳排放预测研究[J]. 环境工程, 2023, 41(10): 124-132.
- WANG Qingrong, WANG Junjie, ZHU Changfeng, et al. Carbon emission prediction of transportation industry based on VMD and SSA-LSSVM[J]. Environmental Engineering, 2023, 41(10): 124-132.
- [15] 胡雨沙, 周建钊. 基于组合方法的造纸过程二氧化碳排放区间预测模型的构建[J]. 中国造纸, 2025, 44(2): 57-64.
- HU Yusha, ZHOU Jianzhao. Study on interval forecasting model of carbon dioxide emission from paper-making process based on hybrid method[J]. China Pulp & Paper, 2025, 44(2): 57-64.
- [16] 杨历夏, 王宇钢, 唐祎晖, 等. 小样本条件下车削加工工艺碳排放多目标预测研究[J]. 机床与液压, 2025, 53(1): 73-79.
- YANG Lixia, WANG Yugang, TANG Yihui, et al. Study on multi-objective prediction of carbon emissions in turning processing under small sample conditions[J]. Machine Tool & Hydraulics, 2025, 53(1): 73-79.
- [17] 曾弘锐, 孙文昊, 何卫, 等. 基于机器学习的铁路隧道施工碳排放预测模型研究[J]. 现代隧道技术, 2023, 60(6): 29-39.
- ZENG Hongrui, SUN Wenhao, HE Wei, et al. Study on the carbon emission prediction model for railway tunnel construction based on machine learning[J]. Modern Tunnelling Technology, 2023, 60(6): 29-39.
- [18] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(A02): 1-6, 26.
- YANG Li, WU Yuqian, WANG Junli, et al. Research on recurrent neural network[J]. Journal of Computer Applications, 2018, 38(A02): 1-6, 26.

(责任编辑 周 蓓)