

DOI:10.3969/j.issn.2097-0706.2023.08.002

基于多维数据与深度学习的区域发电碳排放因子预测研究

Prediction on the regional carbon emission factor for power generation based on multi-dimensional data and deep learning

李方一^{1,2}, 李楠^{1,2}, 周琰^{1,2}, 谢武^{1,2}
LI Fangyi^{1,2}, LI Nan^{1,2}, ZHOU Yan^{1,2}, XIE Wu^{1,2}

(1.合肥工业大学管理学院,合肥 230009; 2.能源环境智慧管理与绿色低碳发展安徽省哲学社会科学重点实验室(合肥工业大学),合肥 230009)

(1.School of Management, Hefei University of Technology, Hefei 230009, China; 2.Anhui Key Laboratory of Philosophy and Social Sciences of Energy and Environment Smart Management and Green Low Carbon Development, Hefei University of Technology, Hefei 230009, China)

摘要:在碳交易背景下,对电力企业进行实时、准确、全面的碳排放计量是开展发电结构调整、技术创新、供需联动、碳交易等工作的基础。受制于数据采集与传输系统的限制,动态碳排放因子的测算与预测目前仍难以完全实现。采用深度学习方法,将双重注意力机制与传统的门控循环单元(GRU)神经网络融合,构建了GRU-Attention预测模型。以合肥市2022年的电力数据为样本,结合合肥市平均气象数据,对GRU模型、长短时记忆(LSTM)模型、基于双重注意力机制的LSTM-Attention模型和GRU-Attention模型进行训练,以实现小时级别的碳排放因子预测。利用不同的评价指标对4种预测模型进行对比,与GRU, LSTM, LSTM-Attention模型相比,GRU-Attention模型预测精度更高,有助于实现发电碳排放因子的中长期预测。

关键词:碳排放计量;碳排放因子;门控循环单元;双重注意力机制;深度学习;中长期预测

中图分类号:TK 01:F 206 **文献标志码:**A **文章编号:**2097-0706(2023)08-0011-07

Abstract: With the support of carbon trading policy, the real-time, accurate and comprehensive measurement on power enterprises' carbon emissions is the basis for structure adjustment, technological innovation, supply and demand side interaction and carbon trading of power generation industry. The calculation and prediction on dynamic carbon emission factors is still limited by the data collection and transmission system. By taking deep learning, a prediction model, called GRU-Attention model, was built by combining dual attention mechanism with traditional Gate Recurrent Unit (GRU) neural network. Then, a GRU model, a Long Short-Term Memory (LSTM) model, a LSTM model based on dual attention mechanism (LSTM-Attention) and a GRU-Attention model were constructed and trained by the power data of Hefei in 2022 and average meteorological data of Hefei, to achieve hourly prediction on carbon emission factor. Comparing the prediction results made by the four models above, it is found that the prediction made by the GRU-Attention model is more accurate than that of the other three models, which can advance the mid- and long-term prediction on carbon emission factor.

Keywords: measurement of carbon emissions; carbon emission factor; Gate Recurrent Unit; dual attention mechanism; deep learning; mid- and long-term prediction

0 引言

2020年,我国政府正式提出了二氧化碳排放力争于2030年前达到峰值,努力争取2060年前实现

碳中和的“双碳”目标^[1]。2021年,全国碳排放交易市场正式上线,电力行业成为首个纳入全国碳市场的行业,共有2162家重点排放企业被纳入该市场,覆盖46亿t二氧化碳排放量^[2]。电力行业是我国最大的单一碳排放行业,其碳排放量约占各行业总排放量的51%。为了控制发电企业的碳排放,政府将电力行业率先纳入碳排放权交易系统,这体现了以

基金项目:国家自然科学基金项目(71902051)
National Natural Science Foundation of China(71902051)

碳市场引导和控制发电企业碳排放的重点政策目标。

国内外文献对碳排放强度、效率和因子的测量和预测进行了广泛且深入的研究。Ang^[3]首先提出了能源强度(国内生产总值(GDP)能耗)的概念。潘家华等^[4]在探索低碳经济的实现途径时,提出了碳生产力的概念(单位 GDP 产出的碳排放),用碳排放替代能耗来衡量低碳经济程度,更具有合理性。李小胜等^[5]根据数据包络分析模型,对各省份全要素生产率指数进行分解,得到了全国各省份的全要素碳排放效率。Zhang 等^[6]通过构建不同的空间计量经济学模型,得出我国碳排放效率具有显著的空间溢出效应这一结论。以上文献对碳排放效率指标进行了创新的定义,采用了一些可以衡量碳排放效率的指标,然而其中大多数指标是把我国各个行业作为一个整体来进行研究的,本文主要对电力行业的碳排放进行分析,如果盲目采用已有的碳排放效率公式,将会产生很大的偏差。因此,本文基于区域电网与发电企业采集的不同电源实时出力与火电机组碳排放数据,进行合肥市地级市层面发电侧动态碳排放因子的测算,以揭示碳排放因子的时间变化特征。

目前,碳排放量统计方法主要有质量平衡法、排放因子法和连续监测法,其中质量平衡法由于误差较大,在火电企业已不再使用^[7]。我国的碳排放量统计方法主体源于联合国政府间气候变化专门委员会(Intergovernmental Panel on Climate Change, IPCC)推荐的排放因子法。经过多年的探索和修订,当前我国火电行业碳排放量统计执行《企业温室气体排放核算方法与报告指南 发电设施(2022 修订版)》,碳排放量主要由化石燃料燃烧排放量和外购电力折算排放量 2 部分组成。连续监测法的企业应用技术规范与计算要求则可参考国内 2022 年 3 月实施的 DL/T 2376—2021《火电厂烟气二氧化碳排放连续监测技术规范》。近两年,连续监测法已进入试点阶段,相关标准正在逐步建立,不久的将来,连续监测法有极大可能被纳入碳排放统计方法。

相关学者已对电力行业的碳排放开展了研究。林明廷等^[8]提出了一种燃煤电厂碳排放在线监测和管理系统设计方案,包括碳排放计量、指标计算、碳排放预警、碳配额管理、数据统计及调度和考核方法。陈咏城等^[9]提出了一种火力发电厂二氧化碳烟气成分测量方法并应用于某台 660 MW 超超临界机组,该方法具有准确性高、实时性强的优点。王明等^[10]研究开发了一种可在线插拔的二氧化碳实时在线监测装置,采用实测法建立了基于现场监测数

据的火电机组二氧化碳排放量计算模型。李姚旺等^[11]以动态碳排放因子为引导信号,提出一种引导用户主动响应并降低系统碳排放的电力系统低碳需求响应机制。

现有的关于电力行业碳排放因子研究中,大多采用实测法或通过排放因子计量碳排放量。电力碳排放因子常年不变、实时性差,政府、电网、企业和用户都很难感受到低碳行为所产生的影响,一方面使得政府很难对低碳政策进行调整,电网不能及时得到反馈,对设备进行优化;另一方面,发电企业很难调整发电策略,用户无法得知自己的减碳行为给社会带来了多少好处,导致社会各界对减碳的信心和动力下降。本文在计算实时动态碳排放因子,保证数据时效性的同时展开分析,为调整用电时序、促进清洁能源消纳提出建议。

目前,针对发电碳排放因子预测的研究较少,许多现有成果都是采用影响因子分析法来预测碳排放量。由于电力碳排放因子预测影响因素较多,各因素数据获取困难,导致影响因子预测有较大局限性。时间序列预测注重序列的时间相关性,暂时忽略了其他因素的影响,可以作为有效的替代模型。近年来,卷积神经网络(Convolutional Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)在碳排放因子预测方面被广泛使用。许多学者利用 CNN 特征提取能力和长短期记忆(Long Short-Term Memory, LSTM)网络处理时间序列的能力构成组合预测模型 CNN-LSTM^[12]。一方面,预测精度要求不断提高使得模型复杂度持续增加,导致模型训练时间较长;另一方面, CNN 模型超参数的选择会极大地影响模型的预测性能。通过元启发式优化算法^[13-15](如麻雀搜索算法(Sparrow Search Algorithm, SSA)、哈里斯鹰优化(Harris Hawks Optimization, HHO)算法、野狗优化算法(Dingo Optimization Algorithm, DOA)等)对参数进行优化是一种有效的方法。李雅丽等^[16]的研究表明, SSA 在各方面都优于其他群优化算法,但其迭代后期种群多样性明显降低,容易导致其陷入局部最优。

随着电力市场的发展和新能源发电方式的突破,电力系统产生的数据量呈几何级数增长,数据的类型和来源也越来越多,这对传统的碳排放因子预测提出了极大挑战。深度学习算法在处理大数据量问题时具有良好的特征提取能力,符合碳排放因数预测需要从大量数据中提取典型特征的需求,故深度学习算法近年来被大量应用到碳排放因数预测中。文献[17]通过隔离森林算法挖掘异常历

史负荷数据并对挖掘后的数据进行清理和分析,之后再利用 LSTM 网络学习时序特性,根据带有时序特性的历史数据进行最终预测,较好地提高了预测精度。文献[18]先通过 CNN 提取特征,再通过 LSTM 网络学习负荷的长短期依赖关系,提取结果相较于手动方式更全面且误差更小。文献[19]通过 RNN 捕捉时间上相隔很远的数据间的相关关系,然后用 Zoneout 技术解决梯度消失问题。这一方法使得需要训练的网络参数大幅减少,提高了训练效率和训练精度。文献[17]提出了一种通过双向门控循环单元(Gate Recurrent Unit, GRU)网络预测模型分析过去和未来的电力信息,并以此学习电力信息的非线性和周期性。上述方法虽然能较好地处理时序上的相关性问题,但均忽视了各输入特征在实际运行中的关联关系,存在一定的片面性,还需要进一步优化。

现有研究已经可以对碳排放因子进行较为准确的预测,但仍存在许多不足。(1)已有研究得到的大多是点预测结果,即某一时刻确定的碳排放因子估计值,很难满足碳排放因子长期预测的需求;而对碳排放因子变化趋势进行预测的研究多偏向于短期预测,难以满足中长期碳排放管控和规划的实际需求。(2)在需要处理海量数据的前提下,影响碳排放因子的因素种类多且杂,这些因素同时具有线性和非线性特征,现有研究在处理这种复杂的影响因子方面仍存在较大不足,常常忽视输入特征之间的关联关系,有可能导致预测过程中出现高度不确定性,引发预测精度下降。因此,面对纷繁复杂的天气因素,本文利用双重注意力机制对传统的 GRU 模型进行修正和改进,以便更加准确地对发电碳排放因子进行中长期预测。

1 区域发电碳排放因子测算方法

火电部门碳排放的产生仅限于电力生产阶段,由于缺少火电行业电力生产直接监测数据,已有文献一般用能源的消耗量来估算二氧化碳的排放量。本文按照“生产地负责”原则进行核算,采用 IPCC (2006)中的“方法 1”估算我国火电行业的碳排放量,计算公式如下

$$E_{\text{CO}_2} = \sum_{i=1} E_{\text{CO}_2, i} = \sum_{i=1} C_i f_i = \sum_{i=1} C_i Q_{\text{L}} c_{\text{G}} R_i \times \frac{44}{12}, \quad (1)$$

式中: i 为能源种类; E_{CO_2} 为碳排放量; C_i 为能源消费量; f_i 为第*i*类能源的碳排放系数; c_{G} 为第*i*类能源的平均单位热值含碳量; Q_{L} 为第*i*类能源的平均低位发热量; R_i 为第*i*类能源的碳氧化率;44/12为二氧化碳与碳分子比值。

由于安徽省火电机组所用燃煤多为烟煤,本文采用文献[20]中烟煤的碳排放系数 2.757 g/g 为火电煤耗的碳排放系数。

根据火力发电量和清洁能源发电量可计算得出不同时刻火力发电量实时占比,根据实时监测的火力供电煤耗量和供电量数据可计算出不同地区的基准碳排放因子,火力发电占比与基准碳排放因子的乘积即为动态发电碳排放因子。区域发电碳排放因子计算公式为

$$f_{p,t} = \frac{E_{\text{CO}_2, p}}{f_p^b} \cdot \frac{W_{p,t}}{W_{p,t}^a}, \quad (2)$$

式中: $f_{p,t}$ 为*t*时期*p*区域的火力发电碳排放因子, g/(kW·h); f_p^b 为*p*区域的基准火电碳排放因子; $W_{p,t}$ 为*t*时期*p*区域的火力发电量, MW·h; $W_{p,t}^a$ 为*t*时期*p*区域的发电总量,包括火电、风电、生物质能、水电、光伏等, MW·h。

2 基于双重注意力机制的 GRU 模型

注意力机制是一种资源分配机制,注意力机制的基本思想就是让模型自己学习如何分配自己的注意力,即为输入信号加权。使用注意力机制的直接目的是为输入的各个维度打分,然后按照得分对特征加权,以评估不同输入对最终输出的贡献率并突出重要特征的影响,为开展后续研究提供便利。目前,注意力机制已经成为深度学习的重要方法之一,在自然语言处理、机器翻译、目标物体检测、图像分类与图像描述、语音识别等领域里得到了广泛应用并取得了较为显著的成果。

本文所构建的基于双重注意力机制的 GRU (GRU-Attention)模型包括输入向量、特征注意力层、GRU 网络层、时序注意力层和全连接层输出,其完整结构如图 1 所示。

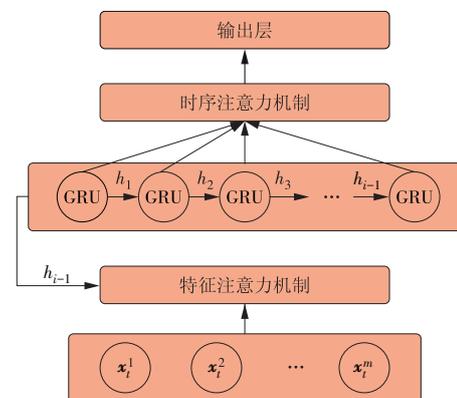


图 1 GRU-Attention 模型结构

Fig. 1 Structure of the GRU-Attention model

首先,将输入向量 x_i^m 结合前一时刻 GRU 网络的隐藏状态 h_{i-1} 输入特征注意力层提取特征,寻找特

征间潜在的相关关系并计算得到各特征量对当前预测的影响权重,得到加权后的输入特征;随后将加权后的输入特征输入 GRU 网络层,经过 2 层 GRU 网络层学习特征提取隐藏的时序关联信息,得到各历史时刻的隐藏层状态 h_i ;在此基础上,通过时序注意力层计算出时间序列上各历史时刻输出信息与当前时刻数据的相关性,利用时序注意力机制对其分配相应的时间注意力权重,以增强关键历史时刻信息的表达,得到改进后的当前时刻隐层状态输出;最后将处理后的隐层状态输入全连接层,得到最终预测结果。

本文对传统特征注意力模型进行了创新,将特征注意力模型里用于特征权重计算的 Sigmoid 函数换成 $\text{RELU}(\cdot)$ 函数,再把最终赋予权重的 Softmax 函数换成 Sigmoid 函数。由于 Softmax 函数在赋予权重时通过指数函数先拉大了输入向量元素之间的差异,然后才归一化为一个概率分布,这可能导致 Softmax 函数输出的结果过于离散,在实际测试过程中易带来特征忽视问题,所以本文采用先 $\text{RELU}(\cdot)$ 函数将特征单侧抑制到正区间,再利用 Sigmoid 函数运算,有效避免出现特征忽视问题。

为了评估 GRU-Attention 模型的预测效果,基于统计学的观点,引入 4 个常用的统计指标来衡量模型碳排放因子预测结果的精确性。相对均方误差 (RMSE) 用来测量预测值与目标值之间的偏差,可以很好地度量预测精度,是最常用的评价指标之一。

$$\delta_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (3)$$

式中: y_i 为实际值; \hat{y}_i 为预测值。

决定系数 R^2 代表模型中因变量可由自变量解释的方差百分比,较高的 R^2 表示模型解释了更多的可变性,例如, $R^2=0.6$ 表明因变量的可变性的 60% 可以由回归模型解释。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \in [0, 1], \quad (4)$$

式中: \bar{y} 为平均值。

平均偏差 (MBE) 用于描述模型的整体预测偏差, δ_{MBE} 可以为正数或负数,表示模型的预测偏差方向。正数表示模型的预测值偏高,负数表示模型的预测值偏低。绝对值较大的 δ_{MBE} 表示模型的预测偏差较大。

$$\delta_{\text{MBE}} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n}. \quad (5)$$

平均绝对误差 (MAE) 用来衡量预测值与真实值之间的平均绝对误差, MAE 越小表示模型越好,其定义如下

$$\delta_{\text{MAE}} = \sum_{i=1}^n |y_i - \hat{y}_i| \in [0, +\infty]. \quad (6)$$

3 数据

目前,主要能源类型包括化石能、电能、生物质能、太阳能、水能、风能和核能,以化石能源为代表的传统能源对碳排放贡献最大。本文采用 2022 年合肥市各种能源发电量及实时监测的火力发电煤耗计算合肥市碳排放因子。

以合肥市 2022-01-01—12-31 T 00:00—23:00 的平均气温、湿度、气压、降水量、经向风速、纬向风速、地面风速、风向信息作为气候信息,以开展后续的模型测试和预测研究。

将每小时的发电碳排放因子数据和气象信息对应,便于后续分析。利用 Python 进行数据清洗,处理原始数据中的空值以及碳排放因子和时间的缺失值,将经过处理的数据导入模型进行分析。数据集划分成训练集和测试集,以 2022 年合肥市样本数据的 70% 作为训练集,以剩余 30% 的样本数据作为测试集。深度学习模型的输入与输出指标见表 1,由于数据类型不同,数值差异也较大,对各指标进行归一化处理以避免影响模型训练效果。

表 1 深度学习模型的输入与输出指标

Table 1 Input and output indicators of the deep learning model

指标	最小值	最大值	平均值	中位数	标准差	方差
气温/ $^{\circ}\text{C}$	-8.52	14.52	1.78	1.08	4.73	22.36
湿度/%	22.56	100.00	63.63	68.07	20.43	417.49
气压/hPa	1 010.890	1 035.030	1 022.120	1 020.777	6.200	38.430
降水量/($\text{mm}\cdot\text{h}^{-1}$)	0	0.450 0	0.130 0	0	0.060 0	0.003 6
经向风速/($\text{m}\cdot\text{s}^{-1}$)	-4.490	6.960	0.690	0.920	3.070	9.430
纬向风速/($\text{m}\cdot\text{s}^{-1}$)	-10.250	4.480	-0.980	-0.796	3.440	11.820
地面风速/($\text{m}\cdot\text{s}^{-1}$)	1.067	11.210	4.360	4.010	3.560	1.890
风向/ $^{\circ}$	1.05	358.59	199.18	213.25	106.27	11 293.87
输出指标 碳排放因子/[$\text{g}\cdot(\text{kW}\cdot\text{h})^{-1}$]	529.000	810.000	714.000	733.000	62.200	3 868.142

4 结果与讨论

4.1 合肥市发电结构特征分析

合肥市位于华东地区,地处安徽省中部、江淮之间,介于北纬 $30^{\circ}57'$ — $32^{\circ}32'$,东经 $116^{\circ}41'$ — $117^{\circ}58'$,水力、风力发电资源相对稀缺,主要依靠火力发电满足居民需求与社会发展。截至2022年年末,合肥市本地电源装机总容量约为7.75 GW,其中燃煤火电装机容量约为4.59 GW,新能源发电装机容量约为3.16 GW。合肥市2022年全年发电量约为255亿 $\text{kW}\cdot\text{h}$,其中火力发电占比为85.8%,风力发电占比为0.9%,生物质能发电占比为5.1%,光伏发电占比为8.2%,无水力发电。

2022年合肥市的月度发电量与结构如图2所示。从图2可以看出,火力发电量占比较高且呈现明显的季节特征:6—8月为高位;4—5月,9—11月为低位;12—次年3月火力发电量较高。由于气温原因,夏季和冬季制冷和取暖所需用电量提升,导致发电量较高。

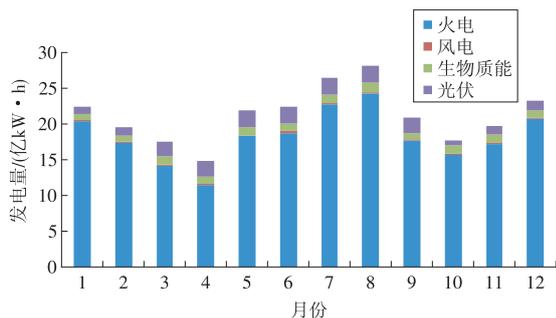


图2 2022年合肥市月度发电量与结构

Fig. 2 Monthly power generation and its composition of Hefei in 2022

4.2 发电碳排放因子变化特征分析

图3为合肥市2022年动态碳排放因子时间序列曲线,由图3可见:全年的动态碳排放因子呈现明显的季节特征,总体变化趋势与火力发电量相同;1月的碳排放因子处于全年的最高位,然后开始逐月递减,4月到达谷值;从5月开始,随着气温的升高和用电量的提升,碳排放因子呈逐月增长趋势,直至8月达到次峰值;9月、10月随着气温的回落及用电量的减少,碳排放因子逐月减小,直至11月气温降低,用电需求增加,碳排放因子又随之增大。

图4为合肥市4个季节的日度碳排放因子变化曲线,日间碳排放因子低于夜间碳排放因子,并于10:00—12:00到达谷值,12:00后碳排放因子不断增加,这种趋势与气象因素及光伏发电有关。

从监测数据与计算结果看,合肥市夏、秋季的碳排放因子较高,春季较低,冬季晚间的碳排放因

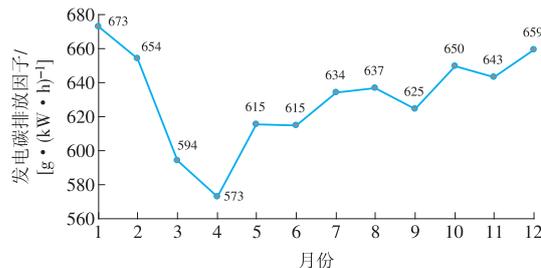


图3 2022年合肥市发电碳排放因子月度变化曲线

Fig. 3 Monthly variation of the carbon emission factor of Hefei in 2022

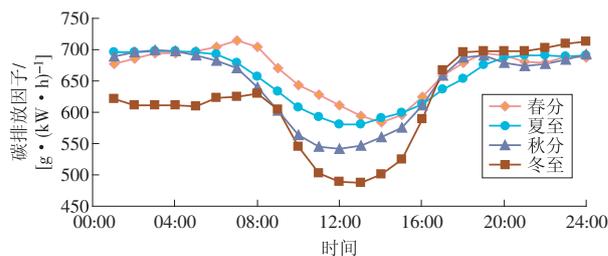


图4 2022年合肥市发电碳排放因子日度变化曲线

Fig. 4 Daily variation of the carbon emission factor of Hefei in 2022

子处于高位,午间的碳排放因子处于低位且低于其他季节,这与前文发电量的统计情况一致。受气候因素的影响,夏秋季合肥市整体气温偏高,居民用电需求高,致使碳排放因子也趋于高位;冬季气温降低,居民电力取暖需求增加,晚间用电需求增加,致使碳排放因子在晚间处于高位。

4.3 不同模型的预测效果对比

将处理后的数据集分别输入LSTM模型、GRU模型、基于双重注意力机制的LSTM (LSTM-Attention)模型和GRU-Attention模型。网络训练过程是通过对大量样本的有监督学习,使连接网络节点的权值更趋合理,实现相对误差的收敛。GRU-Attention模型参数见表2。

表2 GRU-Attention模型参数

Table 2 Parameters of the GRU-Attention model

神经网络层	类型	激活	可学习参数量
输入层	序列输入	$9 \times 1 \times 1$	0
全连接层	全连接	$9 \times 1 \times 1$	72
ReLU层	Relu	$9 \times 1 \times 1$	0
Sigmoid层	sigmoid	$9 \times 1 \times 1$	0
Multiplication层	按元素相乘	$9 \times 1 \times 1$	0
LSTM层	GRU	$10 \times 1 \times 1$	480
LSTM层	GRU	20×1	1 500
全连接层	全连接	1×1	20
输出层	回归输出	1×1	0

基于采集到的天气预报数据,各模型对2022年10月中连续一周共168 h的预测结果如图5—8所示。

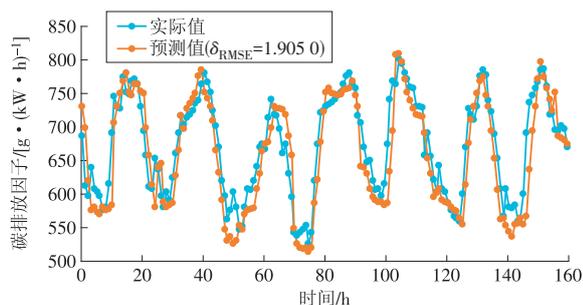


图 5 LSTM 模型预测结果

Fig. 5 Prediction result made by the LSTM model

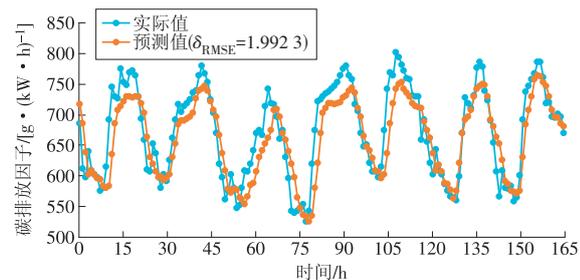


图 6 GRU 模型预测结果

Fig. 6 Prediction result made by the GRU model

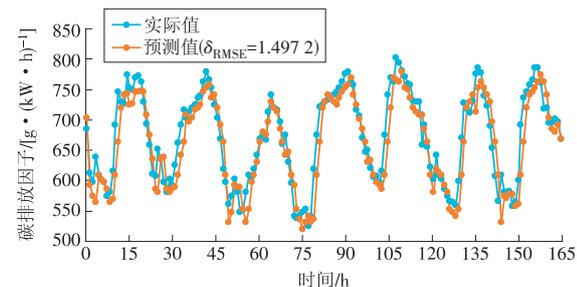


图 7 LSTM-Attention 模型预测结果

Fig. 7 Prediction result made by the LSTM-Attention model

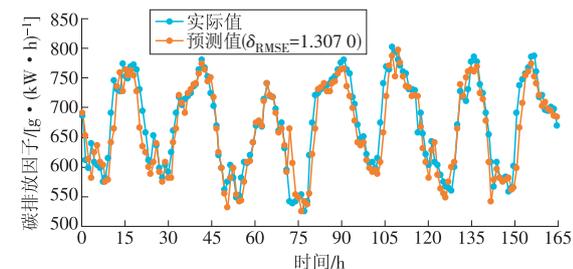


图 8 GRU-Attention 模型预测结果

Fig. 8 Prediction result made by the GRU-Attention model

各模型预测结果误差对比见表 3。由表 3 可见：相对于其他 3 种模型，GRU-Attention 模型 4 项指标均有一定程度的优势，表明 GRU-Attention 模型在大样本下进行区域碳排放预测的误差比其他传统模型小，体现了该模型在区域碳排放预测的优越性；此外，运用了特征注意力机制的模型预测结果明显优于未采用特征注意力机制的模型。

5 结论

本文采用 2022 年合肥市各种能源的发电量及实时监测的火力发电煤耗计算合肥市动态发电碳

表 3 各模型预测结果误差对比

Table 3 Prediction errors made by different models

模型	R^2	δ_{MAE}	δ_{MBE}	δ_{RMSE}
LSTM	0.530 04	1.934 1	-0.295 11	1.905 0
GRU	0.500 02	2.173 5	-0.367 62	1.992 3
LSTM-Attention	0.864 27	1.032 5	-0.397 35	1.497 2
GRU-Attention	0.899 72	1.014 4	-0.166 08	1.307 0

排放因子，揭示合肥市 2022 年碳排放因子的年度与日度变化特征。合肥市发电碳排放因子年均值为 700 g/(kW·h)，月均值为 634~744 g/(kW·h)；夏季、冬季的碳排放因子高于春季、秋季，主要是因为夏季、冬季的用电需求高于春季、秋季，需要提高燃煤火电出力来满足用电需求；4 个季节全天 24 h 的碳排放因子均呈现日间低于夜间、中午处于低谷的特征，反映了光伏发电对降低碳排放因子的贡献。

基于文献研究和实际案例分析，提出了 GRU-Attention 碳排放因子预测模型。通过特征注意力机制分析相关输入特征的重要性和影响力，进而实现对输入特征的优化；同时，使用时序注意力机制，通过注意力权重的动态分配，挖掘输入特征间的潜在关联，找到历史时刻中的有效信息，从而优化模型的输出，提高模型预测的准确度并减少模型训练时长。以 2022 年合肥市碳排放因子真实数据为样本，用 GRU-Attention 模型进行预测，并与 3 个传统模型进行对比，结果表明，采用 GRU-Attention 模型可大幅降低预测误差，预测结果的 δ_{RMSE} , δ_{MAE} 值更低，而 R^2 值更高。由此可见，运用双重注意力机制对循环神经网络模型进行处理有助于提高碳排放因子的预测精度。

参考文献：

- [1]新华社. 中共中央 国务院关于完整准确全面贯彻新发展理念做好碳达峰碳中和工作的意见[EB/OL]. (2021-10-24)[2023-05-25]. http://www.gov.cn/zhengce/2021-10/24/content_5644613.htm.
- [2]中华人民共和国生态环境部. 碳排放权交易管理办法(试行)[EB/OL]. (2021-10-24)[2023-05-25]. http://www.gov.cn/zhengce/zhengceku/2021-01/06/content_5577360.htm.
- [3]ANG B W. Decomposition analysis for policy making in energy: Which is the preferred method?[J]. Energy Policy, 2004, 32(9): 1131-1139.
- [4]潘家华, 庄贵阳, 郑艳, 等. 低碳经济的概念辨析及核心要素分析[J]. 国际经济评论, 2010(4): 88-101.

PAN Jiahua, ZHUANG Guiyang, ZHENG Yan, et al. Clarification of the concept of low-carbon economy and analysis of its core elements [J]. International Economic

- Review, 2010(4): 88-101.
- [5] 李小平, 张焕明. 中国碳排放效率与全要素生产率研究[J]. 数量经济技术经济研究, 2016, 33(8): 64-79, 161.
LI Xiaosheng, ZHANG Huanming. Study on the efficiency and the total factor productivity of carbon emissions in China [J]. The Journal of Quantitative & Technical Economics, 2016, 33(8): 64-79, 161.
- [6] ZHANG Q, YANG J, SUN Z, et al. Analyzing the impact factors of energy-related CO₂ emissions in China: What can spatial panel regressions tell us? [J]. Journal of Cleaner Production, 2017, 161: 1085-1093.
- [7] 陈公达, 邹祥波, 卢锐, 等. 中外火电企业碳排放统计方法与质量控制现状分析[J]. 热力发电, 2022, 51(10): 54-60.
CHEN Gongda, ZOU Xiangbo, LU Rui, et al. Domestic and international statistical methods and quality control status for carbon emission from fossil-fired power plants [J]. Thermal Power Generation, 2022, 51(10): 54-60.
- [8] 林玥廷, 李世明, 卢建刚, 等. 燃煤电厂碳排放在线监测和管理系统设计[J]. 自动化技术与应用, 2018, 37(4): 139-141.
LIN Yueying, LI Shiming, LU Jiangang, et al. Design of on-line monitoring and management system for carbon emission of coal-fired power plants [J]. Techniques of Automation and Applications, 2018, 37(4): 139-141.
- [9] 陈咏城, 唐雯, 马旭涛. 火力发电厂碳排放测量及分析[J]. 电站辅机, 2021, 42(3): 14-17.
CHEN Yongcheng, TANG Wen, MA Xutao. Measurement and analysis of carbon emission in thermal power plant [J]. Power Station Auxiliary Equipment, 2021, 42(3): 14-17.
- [10] 陈剑, 马大卫, 王正风, 等. 煤电机组 CO₂ 排放原位在线监测系统研发与应用[J]. 电力科技与环保, 2022, 38(5): 423-431.
CHEN Jian, MA Dawei, WANG Zhengfeng, et al. Development and application of on-line CO₂ emission monitoring system in coal-fired power plant [J]. Electric Power Technology and Environmental Protection, 2022, 38(5): 423-431.
- [11] 李姚旺, 张宁, 杜尔顺, 等. 基于碳排放流的电力系统低碳需求响应机制研究及效益分析[J]. 中国电机工程学报, 2022, 42(8): 2830-2842.
LI Yaowang, ZHANG Ning, DU Ershun, et al. Mechanism study and benefit analysis on power system low carbon demand response based on carbon emission flow [J]. Proceedings of the CSEE, 2022, 42(8): 2830-2842.
- [12] 李善寿, 马泉杰, 潘璐茜, 等. 基于 VMD 和 LSTM-CNN 的短期负荷预测模型研究[J]. 控制工程, 2023, 30(3): 1-11.
LI Shanshou, MA Xiaojie, PAN Luxi, et al. Research on short-term load forecasting model based on VMD and LSTM-CNN [J]. Control Engineering of China, 2023, 30(3): 1-11.
- [13] 毛清华, 张强. 融合柯西变异和反向学习的改进麻雀算法[J]. 计算机科学与探索, 2021, 15(6): 1155-1164.
MAO Qinghua, ZHANG Qiang. Improved sparrow algorithm combining Cauchy mutation and opposition-based learning [J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(6): 1155-1164.
- [14] YUAN N J, ZHENG Y, ZHANG L H, et al. T-Finder: A recommender system for finding passengers and vacant taxis [J]. IEEE Transactions on Knowledge and Data Engineering, 2013, 25(10): 2390-2403.
- [15] VERMA T, VARAKANTHAM P, KRAUS S, et al. Augmenting decisions of taxi drivers through reinforcement learning for improving revenues [C]//Proceedings of 2017 International Conference on Automated Planning and Scheduling. Palo Alto: AAAI Press, 2017: 409-417.
- [16] 李雅丽, 王淑琴, 陈倩茹, 等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用, 2020, 56(22): 1-12.
LI Yali, WANG Shuqin, CHEN Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms [J]. Computer Engineering and Applications, 2020, 56(22): 1-12.
- [17] LI X L, PAN G, WU Z H, et al. Prediction of urban human mobility using large-scale taxi traces and its applications [J]. Frontiers of Computer Science, 2012, 6(1): 111-121.
- [18] HWANG R H, HSUEH Y L, CHEN Y T, et al. An effective taxi recommender system based on a spatio-temporal factor analysis model [J]. Information Sciences, 2015, 314(12): 28-40.
- [19] LUO Z W, LYU H M, FANG F, et al. Dynamic taxi service planning by minimizing cruising distance without passengers [J]. IEEE Access, 2018, 6: 70005-70016.
- [20] 孙友源, 郑张, 秦亚琦, 等. 火电机组碳排放特性研究及管理建议[J]. 中国电力, 2018, 51(3): 144-149.
SUN Youyuan, ZHENG Zhang, QIN Yaqi, et al. Study on carbon emission characteristics and suggestions on carbon emission management of coal-fired power plant [J]. Electric Power, 2018, 51(3): 144-149.

(本文责编: 刘芳)

收稿日期: 2023-05-31; 修回日期: 2023-06-23
上网日期: 2023-07-26; 附录网址: www.iieneg.cn

作者简介:

李方一(1985), 男, 副教授, 博士, 从事大数据与能源环境管理等方面的研究, fyli@hfut.edu.cn.