引用格式:邓星,陈文君,王璞.考虑重点行业电力消费的城市区域碳排放预测及影响因素分析[J].电力科学与技术学报,2025,40(6):184-192.
Citation: DENG Xing, CHEN Wenjun, WANG Pu. Prediction of carbon emissions and analysis of influencing factors in urban areas considering electricity consumption in key industries[J]. Journal of Electric Power Science and Technology,2025,40(6):184-192.

考虑重点行业电力消费的城市区域碳排放预测及影响因素分析

邓　星,陈文君,王　璞
(国网江苏省电力有限公司南京供电分公司,江苏 南京 210019)

摘　要:在“双碳”背景下,碳排放量的核算结果是各级政府制定碳减排政策的重要依据之一。由于计算区域碳排放量所需数据的获取难度较大,故依赖这些数据的传统计算方法对城市区域级别的碳排放量计算适用性不佳、准确率较低。为此,提出一种考虑重点行业电力消费的城市区域碳排放量预测与影响因素分析方法。先挖掘区域重点企业、住宅和交通电力-能源-碳排放转换关系,并基于这些企业的碳排放量数据计算各行业在该区域的碳排放量;再利用动态时间规整(dynamic time warping,DTW)模型,计算这些行业与该区域的电力碳排放量关联度,并通过箱线图筛选区域重点电力消费行业;然后,建立基于长短期记忆网络(long short-term memory,LSTM)的区域碳排放量预测模型,得到区域碳排放量的预测结果,搭建基于可拓展的随机性的环境影响评估模型(stochastic impacts by regression on population affluence and technology,STIRPAT)的区域碳排放量影响因素分析模型;最后,以中国东部某城市新区为研究对象,展开实证分析,预测该新区2022年的碳排放量,并分析该新区碳排放量变化的主要影响因素。该研究可为考虑重点行业电力消费的城市区域碳排放预测提供参考。

关　键　词:区域碳排;动态时间规整;长短期记忆网络;可拓展的随机性的环境影响评估模型
DOI:10.19781/j.issn.1673-9140.2025.06.018　　**中图分类号**:TP301.6　　**文章编号**:1673-9140(2025)06-0184-09

Prediction of carbon emissions and analysis of influencing factors in urban areas considering electricity consumption in key industries

DENG Xing, CHEN Wenjun, WANG Pu
(Nanjing Power Supply Company, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210019, China)

Abstract: In the context of "carbon peaking and carbon neutrality", carbon emission accounting results are an important basis for the government to formulate carbon emission reduction policies. Due to the difficulty in obtaining data required by regional carbon emission calculation, traditional calculation methods depending on these data have weak applicability and low accuracy for carbon emission calculation in urban areas. To this end, a method for predicting carbon emissions and analyzing influencing factors in urban areas considering the electricity consumption in key industries is proposed. The conversion relationship of electricity, energy, and carbon emissions in the regional key enterprises, residential buildings, and transportation is explored. The carbon emissions of various industries in the region are calculated based on the carbon emission data of these enterprises. The dynamic time warping (DTW) model is used to calculate the correlation between these industries and electricity-related carbon emissions in the region, and key electricity consumption industries in the region are selected through box plots. A regional carbon emission prediction model is established based on a long short-term memory (LSTM) network, and the prediction results of regional carbon emissions are obtained. A regional carbon emission influencing factor analysis model is constructed based on stochastic

收稿日期:2023-06-15;**修回日期**:2023-08-02
基金项目:国网江苏省电力有限公司重点科技项目(J2022163)
通信作者:陈文君(1984—),女,博士,高级工程师,主要从事新型电力系统规划和电力碳排放等方面的研究;E-mail:1309236286@qq,com

impacts by regression on population affluence and technology (STIRPAT) model. By taking the urban new district in the eastern region as an example, the carbon emissions of this new district in 2022 are predicted, and the main influencing factors of the changes in carbon emissions of the new district are analyzed. A reference is provided for carbon emission prediction in urban areas considering electricity consumption of key industries.

Key words: regional carbon emission; dynamic time warping; long short-term memory network; stochastic impacts by regression on population affluence and technology

近年来，随着城市化、工业化、机动化的快速推进，全球碳排放量急剧增长[1]。为减少温室气体排放，减缓全球气候变暖，中国于2020年提出了“双碳”目标[2-3]。为尽快实现这一目标，中国国家和地方各级政府采取了许多有力的措施，国家统计局每年发布《中国能源统计年鉴》，地方政府也发布各地的碳排放清单，制定减排政策。

碳排放量预测为政府合理制定碳减排政策提供了数据支撑，相关研究也逐渐成为了研究重点。文献[4-6]以城市、行业为目标，研究了住宅、工业能源消耗造成的碳排放问题。文献[7]利用灰色预测模型，分析了中国水泥行业的碳排放问题。文献[8]采用多元线性回归，预测了不同情景下伊朗2030年的碳排放量。但总体而言，碳排放量具有非线性和波动性的特点，而传统的预测方法在处理非线性信号方面的能力不如机器学习的能力[9]。文献[10]结合经验模态分解(empirical mode decomposition, EMD)和机器学习模型，对碳排放量进行预测，有效地降低了碳排放量数据的非线性与波动性特征对预测结果的影响。文献[11]采用结合遗传算法的支持向量机，通过情景分析预测了2016—2020年北京市的碳排放量。文献[12]对比分析了神经网络、非线性自回归、高斯过程回归模型对巴林碳排放量的预测结果，发现神经网络的预测最准确。文献[13]利用多层人工神经网络模型来预测17个国家的碳排放量，分析了不同国家的碳排放量趋势。这些方法多从宏观角度，对不同国家、区域、重点城市与行业进行研究。但目前，从微观角度分析地级市、区的碳排放量预测研究较少。

碳排放影响因素分析对于碳排放量预测和节能减排方针制定极为重要。因此，应排除碳排放的冗余影响因素，提取独立、可靠的影响因素，提高对区域碳排放量的影响因素分析的合理性。文献[14]通过改进可拓展的随机性的环境影响评估模型(stochastic impacts by regression on population affluence and technology，STIRPAT)，分别从区域层面和宏观层面分析了中国住宅碳排放量的驱动因素。文献[15-16]采用对数平均迪氏指数分解模型(logarithmic mean divisia index，LMDI)，分析了城市碳排放量的影响因素，发现经济规模是中国碳排放增长的最重要的正向因素。文献[17]也采用LMDI分析了突尼斯交通碳排放量的影响因素。文献[18]基于系统动力学原理，分析了多种场景下电动汽车入网对区域碳排放量的影响，并通过算例验证了电动汽车入网的碳减排效益。

在中国的碳排放组成中，能源领域碳排放占比高达88%。其中，电力消费的碳排放又占到能源领域碳排放的40%以上[19-24]。由于各城市的区域能源消费统计数据不完整，故传统的排放因子法、物料平衡法等常用的区域碳排放计算方法并不适用。

针对这些情况，本文提出考虑重点行业电力消费的城市区域碳排放量预测及其影响因素分析模型。先挖掘区域重点企业、住宅和交通电力、能源消费-碳排放转换关系；再依据所属行业对用能企业进行分类，并核算行业和区域的碳排放量；然后，利用动态时间规整(dynamic time warping, DTW)方法，计算各用能行业、住宅和交通与区域电力碳排放的关联强度，并建立基于长短期记忆网络(long short-term memory，LSTM)的区域碳排放预测模型，得到区域碳排放量的预测结果；最后，搭建基于STIRPAT的区域碳排放量放影响因素分析模型，并以中国东部某城市新区为实证对象，对该新区的碳排放量进行预测，并分析其影响因素，对该方法的准确性与适用性进行验证。

1　考虑重点行业电力消费的城市区域碳排放量预测及其影响因素分析

本文研究的碳排放量区域是基于城市行政区划的。目前，城市区域级别的碳排放量预测可获取数据较少，相关影响分析与预测理论依据均较少，故本文提出考虑重点行业电力消费的城市区域碳排放量预测及其影响因素分析。该分析具体框架如图1所示。在图1中，C_m为用能行业总碳排放量；N为该行业参与碳排放计算的企业数；n为该行业

企业消耗的能源类型数量；E_{ij}为某行业第j个企业第i种能源的耗量；k_i为第i种能源转换为标准煤的转换系数；c_i为第i种能源的碳排放系数；C_c为住宅用能导致的二氧化碳排放量；e_i为第i类型能源使用量（e_1为电力使用量，e_2为天然气使用量，e_3为液化石油气使用量）；C_{road}为城市区域道路交通二氧化碳排放量；V_i为使用燃料i的车辆数量；D_i为使用燃料i的车辆平均行驶距离；C_i为使用燃料i的车辆燃料消耗量；ρ_i为燃料i的缺省发热值；$x_{j,i}$为第j个重点用能行业的第i类用能数据；C_t为城市在t时段的总碳排放量，j=1、2、3；C_z为城市区域碳排放总量；I为区域碳排放量；P为人口密度[24]；B为人均区域生产总值；T为技术水平；G为强关联行业能源消费结构（强关联行业能源消费在所属区域能源消费中的比重）；E为区域强关联行业能源强度；$\ln a$为常数项；ε为随机误差项；b、c、d、k分别为人口密度、人均区域生产总值、强关联能源消费结构、强关联行业能源强度的估计系数。

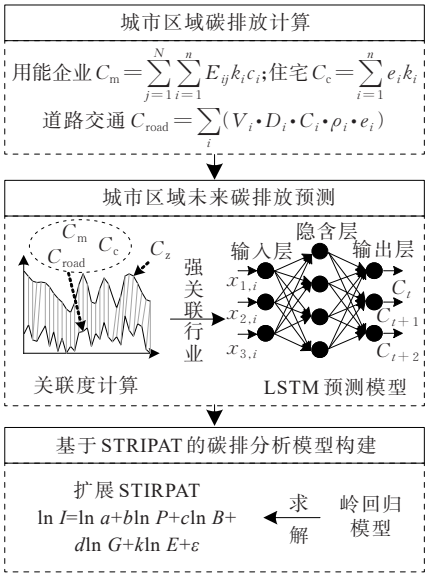

图 1 城市区域碳排放预测及影响因素分析框架

Figure 1 Framework for predicting carbon emissions and analyzing influencing factors in urban areas

在图 1 中，该框架分为 3 个模块。

1）模块 1。充分考虑区域级别能源数据获取的可行性与不同区域数据统计的差异性，构建城市区域内各行业企业、区域住宅和区域交通的碳排放量计算模型。

2）模块 2。先计算区域内各用能企业、区域住宅和区域交通的碳排放量，通过累加得到该区域的碳排放总量；再对该区域内企业按行业进行分类，统计各行业的碳排放量，得到不同行业和区域住宅、区域交通的碳排放量；然后，利用动态时间规划，计算各行业、住宅、交通碳排放量与该区域电力碳排放量的关联度，通过箱线图筛选该区域重点电力消费行业；最后，利用 LSTM 模型，训练强关联行业、住宅、交通等的碳排放量与该区域总碳排放量之间的映射，并通过该映射预测该区域未来碳排放量。

3）模块 3。构建基于 STIRPAT 的区域碳排放量影响因素分析模型。先选取区域人口密度、人均区域生产总值、强关联能源消费结构、强关联行业能源强度来扩展 STIRPAT 模型，再采用岭回归，分析计算各变量相关系数。

2 城市区域碳排量计算与分析体系

中国各城市的碳排放量数据统计主要来源于国家统计局发布的《中国城市统计年鉴》、《中国能源统计年鉴》等。这些统计数据较少涉及某一个具体城市的碳排放量数据，这给这些市级政府进一步分析其区域内的碳排放量趋势、制定符合其城市特色的节能减排措施、优化区域产业结构带来了困难与挑战。

能源消费是中国各城市碳排放的主要来源之一[19]。中国大部分城市的主要能源消费来自于工业企业，其次为住宅用能[20]。电网公司拥有区域内用能企业的用电数据，政府有关部门掌握辖区内用能企业的能源消费数据。本文先以电力、能源消费数据为基础，建立区域内用能企业电力、能源消费与用能企业碳排放量之间的关联模型；再依据所属行业对用能企业进行分类，计算各行业碳排放量，利用 DTW 法筛选区域重点碳排放量行业；最后，搭建考虑重点行业电力消费的区域碳排放预测模型，从而预测该城市的区域碳排放量。

2.1 城市区域碳排放量的计算

2.1.1 城市区域内用能企业碳排放计算

化石能源消费是城市碳排放的主要来源之一。联合国政府间气候变化专门委员会（intergovernmental panel on climate change，IPCC）发布的《国家温室气体清单指南》中相关碳排放量的计量式为

$$C_m=\sum_{j=1}^{N}\sum_{i=1}^{n}E_{ij}k_ic_i \tag{1}$$

考虑到企业实际能源数据的获取难度，选取电力、天然气、原油作为主要能源品种进行估计。参考《国民经济行业分类》（GB/T 4754—2017），将用能企业分为制造业、建筑业、批发和零售业等行业。

2.1.2　区域住宅用户碳排放计算

近年来，传统化石能源在住宅能源消费中的比重逐渐下降，液化石油气消费基本持平，而天然气和电力的使用量急剧增加。特别地，电力是住宅最主要的能源消费，其消费在住宅能源中的消费比重范围约为20%～30%[21]。因此，把住宅的主要能耗分为电力、液化石油气和天然气，其计算式为

$$C_{\mathrm{c}}=\sum_{i=1}^{3}e_i k_i \tag{2}$$

2.1.3　区域交通碳排放计算

城市区域交通能耗碳排计算采取“自下而上”的计算方法，即

$$C_{\mathrm{road}}=\sum_{i}\left(V_i\cdot D_i\cdot C_i\cdot \rho_i\cdot e_i\right) \tag{3}$$

目前，不同城市轨道交通网络错综复杂，且轨道交通的碳排放量与多个城市、区域的碳排放量之间存在耦合，尚没有方法明确其碳核算的边界。但轨道交通的碳排放量在城市碳排放量中的比重较小，将轨道交通碳排放量分摊至各区域碳排放量后的数值也较小，其相较于工业碳排放量与住宅碳排放量可忽略不计。因此，采用城市区域道路交通碳排放量表征该区域的交通碳排放总量。

2.2　城市区域未来碳排放预测

2.2.1　基于DTW的关联度分析

不同的产业结构、能源结构会导致区域的主要碳排放来源有所区别，分析区域内主要能源消费和产业结构可更好地估计该区域的碳排放总量，而各产业的碳排放量主要受该产业电力碳排放量的影响[15]。因此，可通过计算各行业与区域电力碳排放量的关联度来表征该行业与区域碳排放总量的关联度。

在本文中，用能行业i的碳排放量数据集合为$C_i=\left\{T_i(1),T_i(2),\cdots,T_i(n)\right\}$，其中，$T_i(j)$为第$i$个行业的第$j$类消费能源核算的碳排放量，$j=1,2,\cdots,n$；住宅的碳排放量数据集合为$C_{\mathrm{c}}=\left\{T_{\mathrm{c}}(1),T_{\mathrm{c}}(2),\cdots,T_{\mathrm{c}}(n)\right\}$。其中，$T_{\mathrm{c}}(j)$为区域住宅用户消费第$j$类能源核算的碳排放量，$j=1,2,\cdots,n$；区域交通碳排放量数据集合为$C_{\mathrm{road}}=\left\{T_{\mathrm{road}}(1),T_{\mathrm{road}}(2),\cdots,T_{\mathrm{road}}(n)\right\}$，其中，$T_{\mathrm{road}}(j)$为区域交通消费第$j$类能源核算的碳排放量，$j=1,2,\cdots,n$；区域电力碳排放量数据集合为$C_{\mathrm{z}}=\left\{T_{\mathrm{z}}(1),T_{\mathrm{z}}(2),\cdots,T_{\mathrm{z}}(n)\right\}$，其中，$T_{\mathrm{z}}(j)$为区域电力消费第$j$类能源核算的碳排放量，$j=1,2,\cdots,n$。

通过计算两组数据集合的欧氏距离，构成距离矩阵。制造业与区域碳排放量间的距离矩阵$\boldsymbol{D}_{\mathrm{Si}}$中的元素$d_{kj}$的计算式为

$$d_{kj}=\sqrt{\left(C_i(k)-C_{\mathrm{z}}(j)\right)^2} \tag{4}$$

式中，$C_i(k)$和$C_{\mathrm{z}}(j)$分别为第i个行业碳排放量数据集合中第k个数据和区域碳排放量数据集合中第j个数据。

采用动态时间规整方法，在距离矩阵$\boldsymbol{D}_{\mathrm{Si}}$中搜索一条最优弯曲路径，使该路径上经过的各元素之和最小[22]，以此量化相似特征，其计算式为

$$D_{\mathrm{DTW}}(T_t,T_{it})=\min\left(\sum_{r=1}^{L}d\left(\omega_r(m,n)\right)\right) \tag{5}$$

式中，$D_{\mathrm{DTW}}(T_t,T_{it})$为$T_t$和$T_{it}$之间的归一化距离计算值；$T_t$为该行业$t$时刻的碳排放总量归一化数据；$T_{it}$为该行业$t$时刻第$i$种能源的消费量归一化数据；$\omega_r(m,n)$为距离矩阵中弯曲路径中第$r$个元素的坐标；$L$为弯曲路径中所有元素的个数，该值应满足$\max(m,n)\leqslant L\leqslant mn-1$；$d\left(\omega_r(m,n)\right)$为距离矩阵中坐标$(m,n)$的局部距离。

依据式(5)，计算各行业与区域的电力碳排放量的相似度，并建立各行业电力碳排放量与区域电力碳排放量的DTW相似度数据集。

为筛选区域重点电力消费行业，提出上下四分位数箱线图法，利用各行业电力碳排放量与区域电力碳排放量在DTW集的上、下四分位值，确定关联度强弱的阈值[23]。上、下四分位数随时序数据波动程度而变化。该方法可提升样本关联辨识的泛化能力，即

$$L_{\mathrm{dtw}}=L_{\mathrm{d}}+3L_{\mathrm{q}}=L_{\mathrm{u}}+3(L_{\mathrm{d}}-L_{\mathrm{u}}) \tag{6}$$

式中，L_{dtw}为阈值；L_{u}和L_{d}分别为DTW值里的上四分位数和下四分位数；L_{q}为下四分位数与上四分位数之差。

通过上下四分位数箱线图法选取对区域碳排放量影响较大的行业，将行业历史断面能耗数据作为区域碳排放量预测模型的训练集。

2.2.2　基于LSTM的城市区域碳排放量预测

LSTM网络对长序列数据处理能力较强，选取历史断面重点行业用能数据与区域碳排放量数据作为样本，通过训练可得到行业用能数据与区域碳排放之间的映射模型。

LSTM网络结构由输入层、隐含层和输出层构成，其内部结构如图2所示。在图2中，$\boldsymbol{C}_{t-1}$为$t-1$

时刻的记忆单元状态向量；$\boldsymbol{h}_{t-1}$为$t-1$时刻的隐状态向量，影响当前时刻的信息处理与输出；$\boldsymbol{x}_t$为t时刻的输入信息向量，即t时刻的用能数据；$\boldsymbol{f}_t$为t时刻的遗忘门向量，控制当前记忆单元有多少信息会被丢弃；$\boldsymbol{i}_t$为输入门，决定$\boldsymbol{x}_t$有多少会被写入到记忆单元中，由sigmoid激活函数处理的输入数据；$\boldsymbol{g}_t$为候选记忆单元，生成当前时刻可能的记忆更新数据；$\boldsymbol{o}_t$为输出门，控制多少当前的记忆状态$\boldsymbol{C}_t$会影响到当前的输出$\boldsymbol{h}_t$；$\boldsymbol{h}_t$为当前时刻的隐状态输出；sig为Sigmoid函数；$\boldsymbol{C}_{t-1}$、$\boldsymbol{h}_{t-1}$、$\boldsymbol{x}_t$这些输入信息将送去遗忘门和记忆门处理，选择$\boldsymbol{C}_{t-1}$中被遗忘的信息，筛选$\boldsymbol{h}_{t-1}$、$\boldsymbol{x}_t$中应保留的信息。

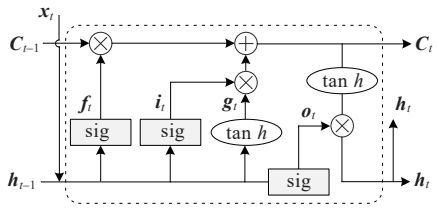

图2 LSTM内部结构示意

Figure 2 LSTM internal structure

设LSTM各单元在第t时间段的遗忘门为$\boldsymbol{f}_t$，记忆门分别为$\boldsymbol{i}_t$和$\boldsymbol{g}_t$，输出门为$\boldsymbol{o}_t$，隐层状态向量为$\boldsymbol{h}_t$，则在第t时间段各门的更新情况为

$$\begin{cases}\boldsymbol{f}_t=\mathrm{sig}\left(\boldsymbol{W}_{\mathrm{f}}\cdot\left[\boldsymbol{h}_{t-1},\boldsymbol{x}_t\right]+\boldsymbol{b}_{\mathrm{f}}\right)\\ \boldsymbol{i}_t=\mathrm{sig}\left(\boldsymbol{W}_{\mathrm{i}}\cdot\left[\boldsymbol{h}_{t-1},\boldsymbol{x}_t\right]+\boldsymbol{b}_{\mathrm{i}}\right)\\ \boldsymbol{g}_t=\tanh\left(\boldsymbol{W}_{\mathrm{g}}\cdot\left[\boldsymbol{h}_{t-1},\boldsymbol{x}_t\right]+\boldsymbol{b}_{\mathrm{g}}\right)\\ \boldsymbol{o}_t=\mathrm{sig}\left(\boldsymbol{W}_{\mathrm{o}}\cdot\left[\boldsymbol{h}_{t-1},\boldsymbol{x}_t\right]+\boldsymbol{b}_{\mathrm{o}}\right)\end{cases}\tag{7}$$

式中，$\boldsymbol{b}_{\mathrm{f}}$为遗忘门偏置向量；$\boldsymbol{b}_{\mathrm{i}}$为输入门偏置向量；$\boldsymbol{b}_{\mathrm{g}}$为记忆门偏置向量；$\boldsymbol{b}_{\mathrm{o}}$为输出门偏置向量；$\boldsymbol{W}_{\mathrm{f}}$、$\boldsymbol{W}_{\mathrm{i}}$、$\boldsymbol{W}_{\mathrm{g}}$、$\boldsymbol{W}_{\mathrm{o}}$分别为输入序列$\boldsymbol{h}_{t-1}$、$\boldsymbol{x}_t$在遗忘门$\boldsymbol{f}_t$、记忆门$\boldsymbol{i}_t$和$\boldsymbol{g}_t$、输出门$\boldsymbol{o}_t$下的权重矩阵。

经过遗忘门和记忆门处理后，通过输出门将$\boldsymbol{C}_t$、$\boldsymbol{h}_{t-1}$、$\boldsymbol{x}_t$的信息处理后，生成输出信号

$$\boldsymbol{h}_t=\boldsymbol{o}_t\odot\tanh\left(\boldsymbol{f}_t\odot\boldsymbol{C}_{t-1}+\boldsymbol{i}_t\odot\boldsymbol{g}_t\right)\tag{8}$$

2.3 基于扩展的STIRPAT碳排分析模型构建

STIRPAT模型是在人口-人均消费水平-技术水平影响(impact of population affluence technology，IPAT)等式的基础上提出的，其具有随机性且可拓展。基于IPAT等式构建的STIRPAT模型为

$$I=\alpha P^b B^c T^d e\tag{9}$$

式中，α为比例系数；I为环境负荷；P为人口规模；B为经济水平；T为技术水平；e为随机误差项；b、c、d分别为P、B、T的指数项。

为研究城市区域的碳排放量的影响因素，本文对STIRPAT模型进行扩展，利用区域碳排放量表征环境负荷I、人口密度表征人口规模P[24]、人均区域生产总值表征经济水平B；将技术水平T分解为强关联行业能源消费结构G(强关联行业能源消费在所属区域能源消费中的比重)和区域强关联行业能源强度E(强关联行业能源消耗与区域生产总值的比值)。扩展后的STIRPAT模型为

$$\ln I=\ln a+b\ln P+c\ln B+d\ln G+k\ln E+\varepsilon\tag{10}$$

为避免各变量回归过程中存在多重共线性问题，采用岭回归多元线性回归模型[25-26]。

3 实证分析

3.1 城市区域碳排放量的计算

以中国东部地区某城市新区为实证对象，采集其2017—2022年的用能企业、住宅和交通的能源消费数据。该新区的用能企业能源数据来源于企业调研，区域能源数据来源于当地的政府统计年鉴。采集该新区每月132家不同行业用能企业的能源数据、每年该新区的住宅、交通能源消费数据。为保证所有数据在时间长度上的一致性，对每月的用能企业数据进行累加，合并为以1 a为时间单位的数据。通过所提的碳排放计算模型，分别计算新区用能企业、住宅和交通的碳排放量。

采用IPCC发布的《国家温室气体清单指南》中的碳排放计算方法，计算该新区原煤、天然气、汽油、柴油、液化石油气、石油焦油、电力共7种能源的碳排放量。2017—2021年，该新区企业、住宅、交通及其碳排放总量的计算结果如图3所示。

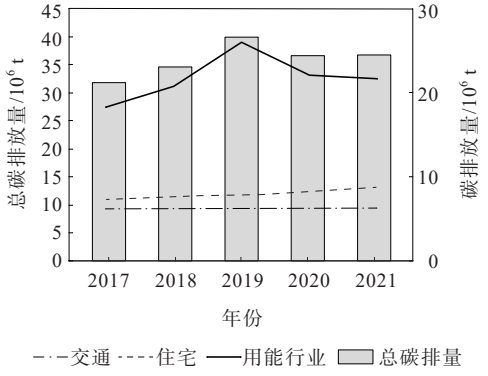

图3 新区企业、住宅、交通及其碳排放总量计算结果

Figure 3 Calculation results of total carbon emissions of enterprises, residential buildings, and transportation in this new district

从图 3 中可以看出，该新区 2017—2021 年的碳排放总量先缓慢增长，在 2019 年达到峰值，在 2020 年急剧下降，在 2021 年又开始回升。这主要是由于该新区为所在城市最大的现代产业集聚区，制造业、钢铁、石化等产业较为发达，能源消耗量大。这些用能企业的碳排放量占新区碳排放总量的 58%，住宅、交通碳排放量则分别占新区碳排放总量的 20%、17%。2020 年，新型冠状病毒感染疫情使得该地用能企业产能下降、能源消耗降低，导致该地的碳排放量出现短暂的下降。

该新区用能企业碳排放量占其碳排放总量的比重较大。为分析该地各行业对区域碳排放量的影响，本文按国家标准《国民经济行业分类》(GB/T 4754—2017)分行业划分各用能企业，并统计该新区 2018—2021 年各行业电力碳排放量，结果见表 1。

表 1　该新区 2018—2021 年的各行业电力碳排放量

Table 1　Electricity-related carbon emissions of various industries in this new district from 2018 to 2021

行业	碳排放量/(10^6 t)			
	2018 年	2019 年	2020 年	2021 年
制造业	5.136 7	6.325 9	5.275 9	5.437 7
房地产业	1.166 4	2.071 9	1.296 3	1.328 1
电力、热力供应业	0.651 1	0.743 1	0.965 9	0.992 6
批发与零售业	8.172 1	9.776 6	9.035 4	8.334 1
建筑业	3.465 4	3.767 3	3.275 9	3.437 3

由表 1 可知，该地制造业、批发与零售业的碳排放量分别占用能企业碳排放总量的 14%、22%，电力、热力供应业、房地产业等行业的碳排放量在用能企业碳排放总量中的占比较低。采用上下四分位数箱线图法，筛选该新区碳排放总量与当地各行业的电力碳排放量的关联度，结果如图 4 所示。

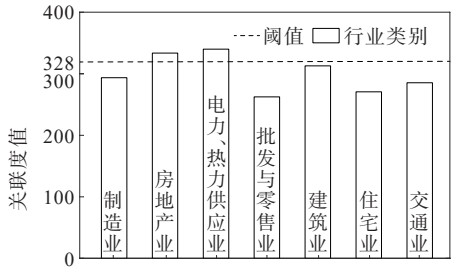

图 4　该新区碳排放总量与当地各行业的电力碳排放量的关联度

Figure 4　Correlation between total carbon emissions of this new district and electricity-related carbon emissions of local various industries

从图 4 中可以看出，该地的制造业、批发与零售、建筑业、住宅和交通与该新区碳排放量强关联。因此，选取这些行业和该新区 2017—2019 年碳排放量数据为训练集、2019—2022 年数据为测试集，采用 LSTM 模型，得到这些强关联行业、住宅、交通碳排放量数据与该新区碳排放总量的映射，该新区碳排放量预测如图 5 所示。

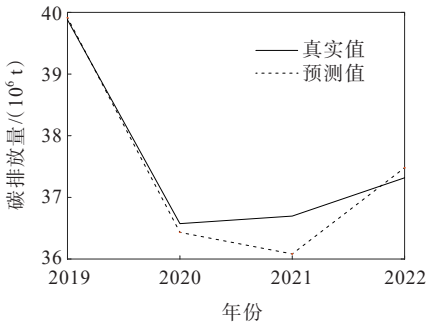

图 5　该新区碳排放量预测

Figure 5　Carbon emission projections for this new district

在本文所提预测模型中，测试集的预测值与真实值的平均相对误差仅为 0.458%，这验证了该方法的有效性与可行性。

3.2　该新区碳排放量影响因素分析

查询该新区 2017—2022 年的人均国内生产总值(gross domestic product，GDP)与人口数据，计算强关联行业的能源消费结构和能源强度等相关变量。各变量均通过了最小二乘法的共线性诊断，各变量之间不存在共线性问题。

基于扩展的 STIRPAT 模型，采用岭回归方法对参数进行拟合。相关参数的岭回归过程如图 6 所示。在图 6 中，岭参数 k 的取值范围为[0，10]，步长为 1。从图 6 中可以看出，当 k=8 时，各变量回归系数区域稳定。因此，选取 k=8 时的岭回归估计系数为相关变量的相关系数。

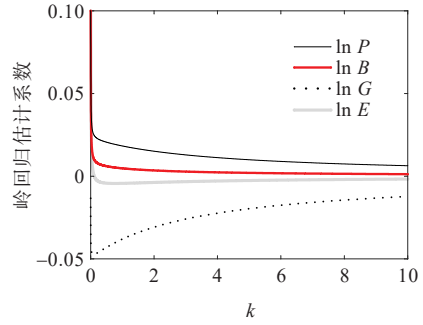

图 6　相关参数的岭回归过程

Figure 6　Ridge regression process for relevant parameters

由岭回归分析得到的STIRPAT模型为

$$\ln I = 0.049\,7\ln P + 0.052\,9\ln B - 0.038\,5\ln G + 0.058\,7\ln E + 2.838\,9 \quad (11)$$

对各变量进行显著性检验，发现所有变量均通过了显著性水平为5%的显著性检验，其拟合程度较好。

新区强关联行业的能源消费结构每增加1%，该区域的碳排放量将增加0.058 7%，对碳排放量影响最为显著。新区的人口数量、人均GDP和强关联行业能源强度每增加1%，碳排放量分别对应增加0.049 7%、0.052 9%、−0.038 5%。因此，该地碳排放量的影响因素主要有以下4个。

1）能源消费强度。能源消费强度对该新区碳排放量的影响程度最大。其原因是该新区经济对能源的批发零售、工业生产等第二产业发展的依赖程度较高，当地的能源消费需求也较高。

2）能源消费结构。能源消费结构对该新区碳排放量起了较小的抑制作用。其原因是新区当地的经济社会发展正在推进全面绿色转型，当地产业结构也正逐步发生改变。传统的高能耗制造业、建筑业的能源消费在该新区全社会能源消费中的比重正逐渐下降。

3）人均GDP。人均GDP对该新区碳排放量也存在着影响。其原因是该新区的产业结构对化石能源的依赖度较高，人均GDP的增长主要依靠第二产业的规模增长。因此，人均GDP的增长在一定程度上促进了碳排放量的增加。

4）人口。人口因素也在一定程度上增加了该新区的碳排放量。其原因是该新区所在城市是中国人口流入的大市，其经济发展水平、居民物质需求和生活水平、居民能源消费均较高，这些对碳排放量增长均有促进作用。

因此，为使该新区的碳排放总量得到有效控制，必须在促进当地经济的同时，促进节能减排，调整能源消费结构，降低高能耗行业在该地行业中的占比，大力发展低碳、低能耗的绿色经济。

4 结语

考虑到目前中国大多数城市的下属区域的碳排放量计算数据获取较为困难，本文提出考虑重点行业电力消费的城市区域碳排放量预测及其影响因素分析。以中国东部地区某城市新区为对象进行实证分析，得到以下主要结论：

1）计算该新区各行业与区域电力碳排放量的DTW值，发现制造业、批发与零售、建筑业、住宅和交通电力碳排放总量占新区电力碳排放总量比重约为87%，这些行业是新区主要碳排放源。

2）所提基于LSTM的区域碳排放量预测模型的平均相对误差仅为0.458%，这验证了所提预测模型的可行性。

3）通过STIRPAT模型分析可知，该地的能源消费强度、能源消费结构、人均GDP与人口均为该新区碳排放量的主要影响因素。为使新区的碳排放总量得到有效控制，促进当地经济发展的同时，促进节能减排，降低能源消费强度，调整能源消费结构，大力发展低碳、低能耗的绿色经济。

后续将挖掘不同区域的能源消费与碳排放量之间的耦合特性，分析电力数据、能源消费数据与碳排放总量之间的关系。

参考文献：

[1] 张智刚，康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报，2022，42(8)：2806-2819.
ZHANG Zhigang，KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE，2022，42(8)：2806-2819.

[2] 邓杰，姜飞，王文烨，等. 考虑电热柔性负荷与氢能精细化建模的综合能源系统低碳运行[J]. 电网技术，2022，46(5)：1692-1704.
DENG Jie，JIANG Fei，WANG Wenye，et al. Low-carbon optimized operation of integrated energy system considering electric-heat flexible load and hydrogen energy refined modeling[J]. Power System Technology，2022，46(5)：1692-1704.

[3] 姜飞，林政阳，王文烨，等. 考虑最小平均包络熵负荷分解的最优Bagging集成超短期多元负荷预测[J]. 中国电机工程学报，2024，44(5)：1777-1789.
JIANG Fei，LIN Zhengyang，WANG Wenye，et al. Optimal bagging ensemble ultra short term multi-energy load forecasting considering least average envelope entropy load decomposition[J]. Proceedings of the CSEE，2024，44(5)：1777-1789.

[4] WEN L，CAO Y. Influencing factors analysis and forecasting of residential energy-related CO2 emissions utilizing optimized support vector machine[J]. Journal of Cleaner Production，2020，250：119492.

[5] 徐勇戈，宋伟雪. 基于FCS-SVM的建筑业碳排放预测

研究[J]. 生态经济, 2019, 35(11): 37-41.
XU Yongge, SONG Weixue. Carbon emission prediction of construction industry based on FCS-SVM[J]. Ecological Economy, 2019, 35(11): 37-41.

[6] 王利兵, 张赟, 郑炜, 等 . 化石能源非能利用需求和碳排放研究[J]. 全球能源互联网, 2023, 6(6): 577-587.
WANG Libing, ZHANG Yun, ZHENG Wei, et al. Research on demand and carbon emissions of non-energy use of fossil energy[J]. Journal of Global Energy Interconnection, 2023, 6(6): 577-587.

[7] OFOSU-ADARKWA J, XIE N M, JAVED S A. Forecasting CO2 emissions of China's cement industry using a hybrid Verhulst-GM(1, N) model and emissions' technical conversion[J]. Renewable and Sustainable Energy Reviews, 2020, 130: 109945.

[8] Seyed Mohsen Hosseini, Amirali Saifoddin, et al. Forecasting of CO2 emissions in Iran based on time series and regression analysis[J]. Energy Reports. 2019 (5): 619-631.

[9] 罗涌恒,姜飞,孙梦琪,等 . 基于前景理论和参考值变换的分布式能源站健康状态矢量动态评价[J]. 电网技术, 2023,47(11):4438-4453.
Luo Yongheng, Jiang Fei, Sun Mengqi, et al. Dynamic evaluation of health state vector of distributed energy stations based on prospect theory and reference value transformation [J]. Power System Technology, 2023, 47 (11):4438-4453.

[10] 张雯, 吴志彬, 徐玖平 . 基于 EMD-PSO-LSSVM 的碳排分解集成预测方法[J]. 控制与决策, 2022, 37(7): 1837-1846.
ZHANG Wen,WU Zhibin, XU Jiuping. A decomposition-integration forecasting method of carbon emission based on EMD-PSO-LSSVM[J]. Control and Decision, 2022, 37(7): 1837-1846.

[11] 闫姝雅, 杨国涛, 张淼 .“双控”和“双碳”目标下中国省域能源消费指标分配[J]. 统计与信息论坛, 2023, 38 (5): 118-128.
YAN Shuya, YANG Guotao, ZHANG Miao. China's provincial energy consumption quotas allocation based on the energy consumption double control, carbon peak and neutrality goals[J]. Journal of Statistics and Information, 2023, 38(5): 118-128.

[12] QADER M R, KHAN S, KAMAL M, et al. Forecasting carbon emissions due to electricity power generation in Bahrain[J]. Environmental Science and Pollution Research, 2022, 29(12): 17346-17357.

[13] JENA P R, MANAGI S, MAJHI B. Forecasting the CO2 emissions at the global level: a multilayer artificial neural network modelling[J]. Energies, 2021, 14(19): 6336.

[14] WANG Y, ZHAO T. Panel estimation for the impacts of residential characteristic factors on CO2 emissions from residential sector in China[J]. Atmospheric Pollution Research, 2018, 9(4): 595-606.

[15] 杜俊慧, 张克勇, 张雪姣 . 山西省碳排放影响因素分解及峰值预测[J]. 中北大学学报(自然科学版), 2018, 39 (3): 334-343.
DU Junhui, ZHANG Keyong, ZHANG Xuejiao. Study on influence factors of carbon emission and prediction of peak value in Shanxi Province[J]. Journal of North University of China (Natural Science Edition), 2018, 39 (3): 334-343.

[16] LI Y M, WANG Q. Exploring carbon emissions in China'sElectric power industry for low-CarbonDevelopment: drivers, decoupling analysisand policy implications[J]. Polish Journal of Environmental Studies, 2019, 28(5): 3353-3367.

[17] Manel Daldoul, Ahlem Dakhlaoui. Using the LMDI decomposition approach to analyze the influencing factors of carbonemissions in tunisian transportation sector [J] International Journal of Energy Economics and Policy.2018(7): 22-28.

[18] 周椿奇, 向月, 岑炳成, 等 . 清洁能源发展场景下电动汽车入网对区域碳排放的系统动力学建模与分析[J]. 电力科学与技术学报, 2021, 36(3): 36-45.
ZHOU Chunqi, XIANG Yue, CEN Bingcheng, et al. System dynamics modeling and analysis of regional carbon emission by electric vehicles development under the evolution of clean energy development[J]. Journal of Electric Power Science and Technology, 2021, 36(3): 36-45.

[19] 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.

[20] NIE H G, KEMP R. Index decomposition analysis of residential energy consumption in China: 2002–2010[J]. Applied Energy, 2014, 121: 10-19.

[21] 白一飞, 张伟荣, 刘加平, 等 . 基于环境库兹涅茨曲线的城市示范区域人均碳排放量预测方法研究[J]. 生态经济, 2022, 38(4): 35-42+84.
BAI Yifei, ZHANG Weirong, LIU Jiaping, et al. Study on forecasting method of per capita carbon emissions in urban demonstration area based on environmental kuznets curve[J]. Ecological Economy, 2022, 38(4): 35-42+84.

[22] 曲正伟, 张嘉曦, 王云静, 等. 考虑分布式电源不确定性的配电网改进仿射状态估计[J]. 电力系统自动化, 2021, 45(23): 104-112.
QU Zhengwei, ZHANG Jiaxi, WANG Yunjing, et al. Improved affine state estimation for distribution network considering uncertainty of distributed generator[J]. Automation of Electric Power Systems, 2021, 45(23): 104-112.

[23] 刘喆林, 王成山, 李鹏, 等. 多源量测数据融合的配电网状态估计及应用[J]. 中国电机工程学报, 2021, 41(8): 2605-2615.
LIU Zhelin, WANG Chengshan, LI Peng, et al. State estimation of distribution networks based on multi-source measurement data and its applications[J]. Proceedings of the CSEE, 2021, 41(8): 2605-2615.

[24] 沈豫, 黄夏楠, 刘林, 等. 基于格兰杰因果与ARDL模型的高能耗产业用电量预测[J]. 电力科学与技术学报, 2022, 37(6): 165-172.
SHEN Yu, HUANG Xianan, LIU Lin, et al. Research on forecasting electricity consumption of high-energy-consuming industries based on Granger causality and ARDL model[J]. Journal of Electric Power Science and Technology, 2022, 37(6): 165-172.

[25] 文明, 胡资斌, 龙乙林, 等. 考虑碳排放惩罚因子的综合能源系统优化规划[J]. 电力科学与技术学报, 2021, 36(3): 11-18.
WEN Ming, HU Zibin, LONG Yilin, et al. Optimal planning of integrated energy system considering carbon emission penalty factor[J]. Journal of Electric Power Science and Technology, 2021, 36(3): 11-18.

[26] 刘硕, 吴旭, 马速良, 等. 基于模型预测控制的光–氢–储耦合系统的功率优化分配方法研究[J]. 高压电器, 2024, 60(7): 23-33.
LIU Shuo, WU Xu, MA Suliang, et al. Research on power optimization allocation method for solar-hydrogen-storage coupled system based on model predictive control[J]. High Voltage Apparatus, 2024, 60(7): 23-33.