

长三角城市群碳达峰路径模拟研究

石常峰¹, 俞越¹, 姚潇², 庞庆华¹

(1. 河海大学经济与金融学院, 常州 213200; 2. 河海大学信息科学与工程学院, 常州 213200)

摘要: 城市群是构建国内大循环、促进区域协调发展的重要平台。城市群一体化深入发展的现实背景下,其内部空间网络特性决定了单一城市碳达峰路径不可避免地受到邻近城市影响。为此,本文以中国一体化程度较高的长三角城市群为研究对象,构建基于地理—经济复合维度的空间权重矩阵,应用空间计量模型考察该城市群碳排放空间关联效应,进一步构建空间嵌入式GA-LSTM模型以对长三角城市群碳达峰路径进行动态模拟。实证结果显示:①若考虑长三角城市群空间关联效应,部分城市碳达峰时点提前且多数城市峰值水平降低,表明空间关联效应能有效优化城市群碳排放空间格局,但其达峰后排放态势并未受到显著影响。②基准情景下,除苏州、亳州以外城市均能于2030年前顺利实现碳达峰,其中安徽省多数城市在2019年后保持碳排放稳中有降,江苏省及浙江省部分城市达峰后的碳排放下降态势相对缓慢,而上海、南通在早期实现达峰后其碳排放却呈缓慢增加的反弹趋势。③绿色情景下,长三角城市群整体碳排放于2019年后呈平稳下降趋势,有效逆转了基准情景下的惯性增长,并且其内部城市在碳达峰时点、峰值水平以及达峰后态势方面均呈显著改善趋势,有助于形成互为促进的区域减排合力。

关键词: 碳达峰; 路径模拟; 空间关联; GA-LSTM模型; 长三角城市群

DOI: 10.11821/dlxb202411013

1 引言

2020年9月习近平总书记提出的“双碳”目标不仅是中国积极参与全球环境治理的减排承诺,更是以低碳转型推动经济高质量发展的必然要求。《2030年前碳达峰行动方案》进一步提出中国各地区要梯次有序推进碳达峰。中国共产党的“二十大”报告亦指出要坚持先立后破,有计划分步骤实施碳达峰行动。作为城市发展到成熟阶段的空间承载主体,具备较高人口密度与经济密度的城市群不可避免地成为了中国碳排放的“重灾区”^[1],城市群率先实现绿色低碳转型对于推动全国“双碳”目标具有重要引领作用。此外,“双循环”新发展格局下城市群内部碳排放更是呈现出不可忽视的“连根共树”特征,碳达峰形势严峻且复杂^[2],亟需开展环境联保共治工作。然而,现实气候系统惯性使得减排政策生效普遍滞后^[3]。为稳妥有序推进中国“双碳”目标,对城市群碳排放演化态势与碳达峰路径开展前瞻性预测研究具有重要实践意义。

地理学第一定律指出,距离邻近事物之间的空间关联更加紧密^[4]。产业关联、商品流动、人口迁移等经济社会特性导致的要素集聚与扩散效应,在客观上使得区域碳排放呈

收稿日期: 2023-12-28; 修订日期: 2024-07-23

基金项目: 教育部人文社会科学研究基金项目(22YJAZH086) [Foundation: Ministry of Education Humanities and Social Sciences Research Fund Project, No.22YJAZH086]

作者简介: 石常峰(1985-), 男, 江苏扬州人, 博士, 副教授, 硕士生导师, 研究方向为资源环境管理。

E-mail: 20161953@hhu.edu.cn

通讯作者: 姚潇(1982-), 男, 甘肃金昌人, 博士, 副教授, 硕士生导师, 研究方向为地理信息系统。

E-mail: yaox@hhu.edu.cn

现纵横交错、纷繁复杂的空间关联^[5]。碳排放空间关联的研究方法大致可概括为以下3类：① 采用投入产出框架探究中国生产—消费活动引致的碳排放交互影响，揭示跨区域贸易下“发达国家消费与中国污染”^[6]“东部发达地区消费和西部欠发达地区污染”^[7]等国别或地区发展中的碳转移、碳泄漏问题，进而强调制定区域及产业协同减排政策的必要性；② 借助社会网络分析方法从网络结构、节点属性和关系等角度系统考察碳排放空间网络的结构特征与形成机制，相关结果表明中国区域碳排放存在着包括主收益、净收益、净溢出和经纪人四大板块在内的“俱乐部”式空间分布特征^[8]；③ 通过引入空间权重矩阵构建空间计量模型，从全局高度考察相邻地区间碳排放的互相影响，即碳排放空间溢出效应^[9]。空间计量模型可以更灵活地将诸多影响因素纳入考察范围，并从统计意义上检验各种因素对碳排放影响的显著性^[10]。例如王少剑等采用空间滞后模型，发现中国城市碳排放存在着明显的空间集聚特征与路径依赖特征，强调实施区域协同减排的重要性^[11]。

虽然碳排放空间溢出效应已经得到了普遍揭示^[12]，但现有碳达峰预测研究通常忽视了客观存在的区域间碳排放空间关联，多数研究分别采用传统回归模型^[13]、统计学模型^[14]、机器学习模型^[15]等进行区域碳排放预测。而基于投入产出模型、社会网络分析模型和空间计量模型的相关研究往往侧重于碳排放驱动因素与溢出效应的考察，难以直接应用于区域碳排放预测。实践方面，岳书敬基于LMDI分解模型考察了长三角城市群的碳排放驱动效应，并通过情景模拟发现其将在2025—2029年间实现整体碳达峰^[16]。而晏清等结合空间计量模型和EKC理论进行了长三角城市群碳达峰预测，发现如果充分考虑区域一体化的空间溢出效应，EKC曲线的拐点将从2039年提前到2023年，从而使得长三角城市群碳达峰提前实现^[17]。显然预测过程中关于城市碳排放相互孤立的隐含假设，既有悖于现实发展情况，又容易得到顾此失彼的减排结论^[18]。系统视角下考虑空间溢出效应的碳排放预测研究缺失，使得制定因地制宜而又协同高效的城市群减排方案缺少必要的决策支撑。

值得注意的是，神经网络方法因其适应性好、覆盖范围广、学习能力强等特点，在空间分析中被认为具备新的范式潜力^[19]。例如，卷积神经网络（CNN）已经成为一种适用于各领域中欧几里得数据的空间特征学习方法^[20]。在此基础上提出的图卷积神经网络（GCN）能够进一步实现对节点与节点之间相关关系的学习。邻接矩阵被用来表示GCN模型中的相关关系，这与空间计量模型中通过空间权重矩阵来表征对象间关联关系的思路高度一致^[21]。然而，区域碳排放数据不仅和空间位置、空间依赖有关，而且往往伴随着明显的时间依赖特征^[22]。这也是现有应用神经网络方法进行碳排放预测的相关文献中通常选择长短期记忆网络（LSTM）来开展研究的重要原因^[23]。但正如前文所述，现有预测模型侧重于个体碳排放的时间特征学习，忽视了空间特征在碳排放演变态势中的重要性^[24]。而针对空间特征学习的GCN等模型因其过于复杂的网络结构，在理论上并不适用于具备小样本特征的碳排放数据，因而同样难以满足碳排放预测问题的需要^[25]。鉴于当前区域碳排放研究在时间维度和空间维度“各自为政”的特点，能够兼顾学习复杂时空依赖关系的碳排放预测方法仍有待进一步研究。

综上所述，本文借鉴空间计量模型以及GCN模型对空间关联特征的代表思路^[26]，提出一种基于GA-LSTM架构的空间嵌入式优化神经网络预测模型，并以长三角城市群内部41个城市为对象开展了碳达峰预测模拟研究。相较于传统预测方法，该深度学习模型能够实现神经网络超参数的优化，处理相关数据非线性映射动态关系，提取城市群碳排放潜在时空依赖关系，从而提高城市群碳达峰预测精度，为进一步模拟多情景下城市群碳达峰路径奠定模型基础。本文基于系统角度开展考虑空间关联效应的城市群碳达峰预测

模拟研究,以期城市群碳排放系统治理工作的推进以及城市群碳达峰全局规划方案的完善提供决策参考。

2 研究方法与数据来源

2.1 研究区概况

根据2019年国务院颁布的《长江三角洲区域一体化发展规划纲要》,长三角地区规划范围扩展至上海市、江苏省、浙江省、安徽省全域。土地面积约35.8万km²(约占国土面积3.7%)的长三角城市群地处江海交界处,是中国乃至全球最重要的制造业集群、外贸产业集群之一。2021年长三角城市群GDP总值约27.61万亿元、年末人口达到2.36亿人、碳排放总量约18.88亿t,分别占全国的24.26%、16.74%、16.51%^①。2023年习近平总书记在深入推进长三角一体化发展座谈会上指出,长三角一体化发展战略提出并实施以来,区域协调发展取得重大突破。由此,本文以一体化发展典型的长三角城市群为研究区域,涵盖41个城市,数据样本期限为2000—2019年,并在考虑碳排放空间关联的基础上对41市2020—2035年的碳排放进行预测。

2.2 空间权重矩阵构建及空间自相关检验

区域一体化深入发展背景下,长三角城市群经济生产活动呈现紧密联动态势,传统地理距离权重矩阵难以充分反映城市群内部碳排放的交互影响^[27]。现有研究表明,区域碳排放在地理邻近和经济邻近下均存在着显著的空间关联性^[28]。因此,本文构建地理—经济加权距离权重矩阵(W_3)来全面表征长三角城市群碳排放邻近关系。

$$W_3 = \psi W_1 + (1 - \psi) W_2 \quad (1)$$

式中: W_1 为地理距离权重矩阵,其元素用城市间地理中心距离的倒数来表示; W_2 为经济距离权重矩阵,其元素用城市间人均GDP年均值差值的绝对值倒数来表示; ψ 的取值在0~1之间,其大小表示 W_3 对地理距离或经济距离的偏向性,本文 ψ 取值为0.5^[29]。本文选取Moran's I 检验长三角城市群碳排放的空间自相关性并刻画其空间集聚特征,计算公式为:

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\left(\sum_{i=1}^n \sum_{j=1}^n w_{ij} \right) \sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

式中: n 为城市数量; y_i 和 y_j 分别表示城市 i 和城市 j 的碳排放值; \bar{y} 表示所有城市碳排放观测值的平均水平; w_{ij} 为空间权重矩阵中的元素,反映城市之间的邻近关系。

2.3 基于STIRPAT框架的空间面板模型

基于STIRPAT框架^[30],本文构建了长三角城市群碳排放影响因素指标体系以研究其对城市碳排放的影响方向与程度:

$$\ln \text{CO}_{2it} = \alpha_0 + \alpha_1 \ln \text{pop}_{it} + \alpha_2 \ln \text{pgdp}_{it} + \alpha_3 \ln \text{ur}_{it} + \alpha_4 \ln \text{open}_{it} + \alpha_5 \ln \text{ci}_{it} + \alpha_6 \ln \text{is}_{it} + \ln \varepsilon_{it} \quad (3)$$

式中: i 表示所对应的样本城市; t 表示年份; CO_2 表示碳排放总量; α 代表一组待估参数; pop 表示人口规模,用常住人口(万人)来衡量; pgdp 表示经济发展水平,用人均GDP(万元)来衡量; ur 表示城镇化率,用城镇居民人数占常住人口总数的比重来衡量(%); open 表示对外开放程度,用外商直接投资(FDI)除以当地GDP(万美元/万元)来衡量;

① 长三角地区和中国GDP、年末人口数据来自《中国统计年鉴》,碳排放数据来自CEADs数据库。

ci 表示减排技术水平,用碳排放总量除以实际GDP(t/万元)来衡量; is 表示产业结构,用第二产业产值占GDP比重(%)来衡量。

若忽视城市间经由商品贸易、技术扩散、人口流动等因素而形成的碳排放空间关联性,将不可避免地得到有偏差的结论,因此有必要引入空间面板模型:

$$\begin{cases} Y_{it} = \rho \sum_j w_{ij} Y_{jt} + \beta X_{it} + \sum_j w_{ij} X_{jt} \gamma + \varphi_{it} \\ \varphi_{it} = \lambda \sum_j w_{ij} \varphi_{jt} + \varepsilon_{it} \end{cases} \quad (4)$$

式中: Y 为被解释变量; X 表示STIRPAT框架下的一组解释变量; φ 表示空间自相关误差项; ε 是服从正态分布的扰动项; ρ 表示空间自回归系数; β 表示相应解释变量的系数; γ 表示空间滞后解释变量的系数; λ 表示误差项的空间自相关系数。考虑模型(4)的如下特殊形式:若 $\lambda = 0$,则为空间杜宾模型(SDM);若 $\lambda = 0$ 且 $\gamma = 0$,则为空间滞后模型(SAR);若 $\rho = 0$ 且 $\gamma = 0$,则为空间误差模型(SEM)。

2.4 空间嵌入式GA-LSTM模型

通过嵌入空间关联关系增强预测模型的做法已经得到了一些前沿性探索^[31]。能够统筹考虑时间、空间以及时空关联的时空复合预测框架显著提升了模型的拟合性能,而且使得模拟结果更为符合客观实际。然而此类倚重图模型处理的深度学习方法通常对数据样本的质量和数量有着较高要求^[32-33],尚未针对年度碳排放数据等小样本数据集构建出适配的预测架构。也有研究基于嵌入空间关系的思路,对基于灰色理论的预测模型进行优化,尝试在考虑空间关系的情况下对小样本数据进行预测^[18]。在碳排放预测领域,高维信息数据集的处理往往会加剧模型的复杂性,且深度学习模型固有的低可解释性问题也被进一步放大^[34]。因此在有效处理高维信息的同时,如何避免模型过度复杂且进一步提升预测结果的可解释性,已成为时空预测框架在碳排放预测领域中亟待解决的重要课题。

针对碳排放数据集的小样本、时序性分布特点,有研究提出以LSTM作为预测模型的核心架构,并运用遗传算法(GA)对其超参数进行优化的GA-LSTM框架^[15]。该框架能够准确捕捉单个空间主体的时间序列特征,适用于区域年度碳排放数据预测问题,但完全忽视了空间主体之间的动态相互依赖性。因此,本文提出一种基于GA-LSTM框架的空间嵌入式优化神经网络预测模型,通过纳入空间权重矩阵对GA-LSTM框架的建模逻辑予以改进,使前者在模型迭代中作用于参数优化过程,将单一数据集的个体训练转变为考虑相互影响关系的群体训练。空间嵌入式深度学习模型结构(图1),通过嵌入地理—经济加权距离权重矩阵以映射邻近城市影响因素对当地碳排放产生的间接影响,进而利用深度学习模型强大运算能力予以量化,从而实现对空间关联下城市碳排放的精准预测。

通过空间权重矩阵生成城市群碳排放空间滞后项并将其嵌入预测模型,一方面能够将长三角城市群碳排放空间关联性予以量化,并使得模型预测精度得以提升;另一方面也克服了模型构建中需要就各城市设定不同模型参数的弊端,进而提升模型训练效率。而矩阵输入所产生的维度提升问题也能够较好地被GA予以克服。嵌入空间权重矩阵后的数据处理过程如下:

$$X = \begin{pmatrix} x_1^1 & x_2^1 & \cdots & x_n^1 \\ x_1^2 & x_2^2 & \cdots & x_n^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^m & x_2^m & \cdots & x_n^m \end{pmatrix} = \{X_1, X_2, \cdots, X_n\} \quad (5)$$

$$Data_spatial = X \times W^T = \begin{pmatrix} d_1^1 & d_2^1 & \cdots & d_n^1 \\ d_1^2 & d_2^2 & \cdots & d_n^2 \\ \vdots & \vdots & \ddots & \vdots \\ d_1^m & d_2^m & \cdots & d_n^m \end{pmatrix} = \{D_1, D_2, \cdots, D_n\} \quad (6)$$

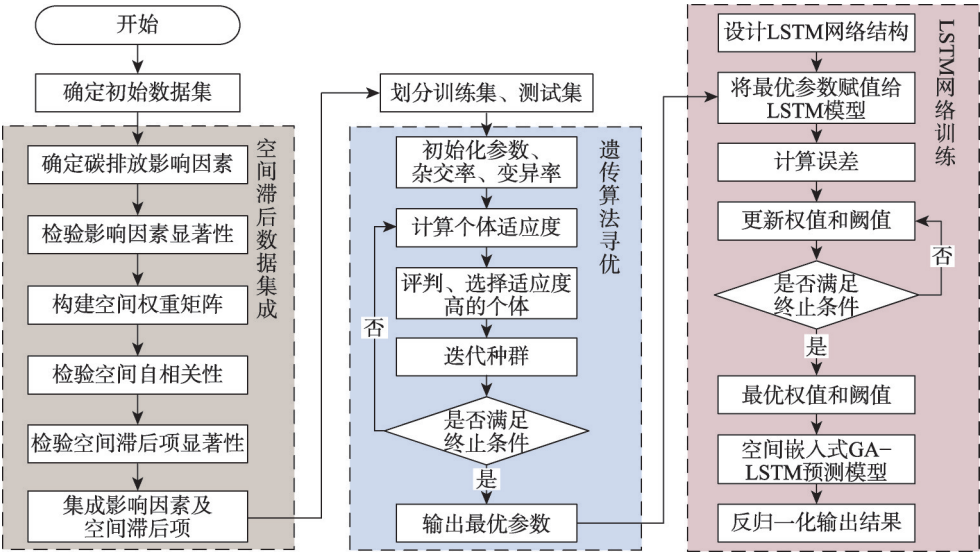


图1 空间嵌入式GA-LSTM模型流程图

Fig. 1 Flowchart of spatially embedded GA-LSTM model

式中： X 为长三角城市群第 t 年的碳排放影响因素矩阵； W 为所构建的空间权重矩阵； $Data_spatial$ 表示长三角城市群第 t 年的影响因素空间滞后项矩阵； m 表示影响因素数量。嵌入空间权重矩阵的LSTM模型结构如图2所示，给定长三角城市群第 t 年的影响因素集 X 作为模型第 t 年的初始输入，通过空间加权项 W 的加权输出定义为 $Data_spatial$ ，以矩阵格式集成初始输入与空间滞后项作为深度学习模型的训练集。

作为一种通过模拟自然进化过程搜索最优解的方法，GA具有大范围全局搜索的能力，可以进行多值比较且鲁棒性较强^[35]。因此采用GA优化LSTM模型超参数，其过程为：

$$(\varepsilon, \theta) = GA(X, X \times W^T) \tag{7}$$

利用经过GA-LSTM模型进行城市碳排放量的预测，则 t 年的碳排放预测值 \hat{y}_t 为：

$$\hat{y}_t = LSTM(X, X \times W^T, \varepsilon, \theta, bias) = LSTM(X, X \times W^T, GA(X, X \times W^T), bias) \tag{8}$$

式中： $bias$ 为偏移值。

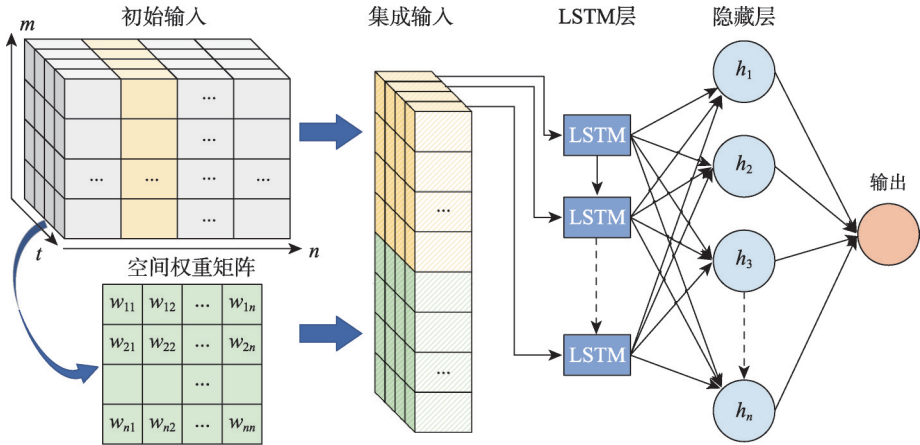


图2 空间嵌入式LSTM模型结构

Fig. 2 Structure of spatially embedded LSTM model

模型使用均方误差作为损失函数:

$$L = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n} \quad (9)$$

式中: y_t 和 \hat{y}_t 分别为第 t 年碳排放的真实值和预测值。

相较于传统的空间回归模型, 本文采用的模型架构在参数估计方面展现出明显的差异: 前者通常采用线性估计方法^[36], 而神经网络则倾向于使用非线性估计。尽管如此, 这两种方法都充分考虑了空间权重矩阵及其所表征的空间滞后效应对参数拟合的影响, 即每个空间单元聚合其相邻单元的自变量值以学习空间滞后效应, 使其参与到每一次参数迭代过程。沿用空间计量模型的架构, 通过将空间权重矩阵嵌入LSTM模型以在其前向传播过程中纳入潜在空间滞后效应。这种方法利用LSTM模型在处理时序数据方面的优势, 使得城市碳排放的空间滞后效应在时序深度学习框架内得到有效模拟和利用^[34]。此外, 将空间权重矩阵而非GCN模块集成到时序深度学习框架的设置逻辑, 避免了参数的复杂化和高维化问题。这使得模型能够有效地进行时空复合框架下的城市碳排放预测。

2.5 数据来源及处理

中国城市尺度能源消耗数据缺失、统计标准不一使得城市碳排放数据难以直接测算^[32]。本文使用中国碳核算数据库 (CEADs) 提供的2000—2019年城市碳排放数据开展研究。该数据来源于研究团队发表的系列成果^[37], 具有立足中国实际、口径统一、连续且科学等优势。为进一步保证数据准确性, 本文使用欧盟委员会、联合研究中心 (JRC)、国际能源署 (IEA) 合作开发的全球大气研究排放数据库 (EDGAR) 作验证对比^[38]。该数据库提供了分辨率为 $0.1^\circ \times 0.1^\circ$ 的全球碳排放格点数据, 因此首先将格点数据转化为栅格数据, 然后通过分区域汇总得到长三角城市群的碳排放数据。如图3所示, 后缀为“C”“E”分别表示基于CEADs和EDGAR得到的长三角城市群代表性城市的碳排放核算数据。2019年5个城市的碳排放量合计占长三角地区当年碳排放总量的37.6%, 在城市群碳排放空间格局中占据关键地位。可以看出两种碳排放数据来源之间的误差均控制在一定范围内, 并且呈现出较为一致的历史演变趋势, 有效保障了数据的可靠性。

社会经济数据主要来源于2001—2020年《中国城市统计年鉴》、各城市统计年鉴以及社会统计公报, 个别年份的相关数据缺失采用插值法进行补齐。为消除价格因素影响, 将GDP等经济指标均调整至2000年的不变价。本文主要依据《长三角一体化发展规划“十四五”实施方案》以及各城市的“十四五”规划等指导性政策文件对影响因素进行情




图3 两种数据源的城市碳排放趋势对比

Fig. 3 Comparison of city carbon emission trends from two data sources

景参数设定，以结合预测模型模拟各城市未来的碳达峰路径。情景参数设定还在一定程度上考虑了国家整体规划的指导作用，例如人口增速参考了《中国劳动与人口绿皮书》《全国人口发展规划（2016—2030年）》进行设定，碳排放强度增速参考《2023年能源工作指导意见》《中华人民共和国国民经济和社会发展第十四个五年规划和2035年远景目标纲要》进行设定。以上海市为例，最终所设立的情景如表1所示。

表 1 上海市情景变量参数设定(%)
Tab. 1 Scenario variables setting for Shanghai

情景变量	2020—2025 年	2026—2030 年	2031—2035 年
人口增长率	0.50	0.30	-0.04
城镇化增长率	0.50	0.30	0.20
人均GDP增长率	2.90	2.30	1.90
对外开放增长率	1.50	1.30	1.00
产业结构变动率	-1.00	-0.90	-0.75
碳排放强度变动率	-0.60	-0.70	-0.73

3 结果分析

3.1 长三角城市群碳排放空间关联性检验

全局莫兰指数首先被用来检验长三角城市群碳排放的集聚关联效应。如表2所示，地理—经济加权距离矩阵设定下，研究期限内碳排放总量的Moran's *I*均至少在10%水平上显著为正，且绝大多数年份碳排放总量的Moran's *I*均在1%水平上显著为正，初步表明2000—2019年间长三角城市群碳排放放在地理经济加权距离下存在着显著的正向空间集聚效应，单个城市碳排放会受到周边城市碳排放变动的影响。

在考虑碳排放空间关联性的基础上，空间面板模型被用来检验碳排放的关键影响因素及空间滞后效应。在地理经济加权距离矩阵的设定下，LM检验、稳健的LM检验与LR检验的结果表明（表3），SDM为最优模型架构，且不会退化为SAR或SEM。Hausman检验结果进一步表明随机效应模型估计效果要优于固定效应模型，因此最终选用考虑随机效应的SDM进行实证研究，回归结果如表4所示。

表 2 2000—2019 年长三角城市群碳排放的空间自相关检验

Tab. 2 Spatial autocorrelation test of carbon emissions in the Yangtze River Delta urban agglomeration, 2000-2019

年份	Moran's <i>I</i>	<i>p</i> 值	年份	Moran's <i>I</i>	<i>p</i> 值
2000	0.017**	0.016	2010	0.032***	0.006
2001	0.027***	0.006	2011	0.031***	0.009
2002	0.026***	0.007	2012	0.032***	0.008
2003	0.031***	0.003	2013	0.028**	0.013
2004	0.043***	0.001	2014	0.027**	0.014
2005	0.049***	0.001	2015	0.019**	0.031
2006	0.046***	0.001	2016	0.020**	0.030
2007	0.045***	0.001	2017	0.013*	0.057
2008	0.037***	0.003	2018	0.029**	0.012
2009	0.035***	0.004	2019	0.028**	0.013

注：***、**、*分别表示在1%、5%、10%的水平上显著，下同。

表 3 空间面板模型检验

Tab. 3 Verification of spatial panel models

	LM-lag	Robust LM-lag	LM-error	Robust LM-error	LR-lag	LR-error
χ^2	243.952***	64.648***	669.312***	490.007***	318.290***	28.870***
<i>p</i> 值	0.000	0.000	0.000	0.000	0.000	0.000

表 4 回归模型估计结果
Tab. 4 Estimated results of regression model

变量	估计系数	直接效应	间接效应
$\ln pop$	0.936***	0.945***	-0.232
$\ln pgdp$	0.511***	0.571***	0.344*
$\ln ci$	0.925***	0.920***	1.616
$\ln open$	0.036***	0.033**	1.565
$\ln is$	0.144	0.184*	-0.115*
$\ln ur$	0.616***	0.506 **	-3.420
$W \times \ln CO_2(\rho)$	0.726***		
R^2	0.977		

(1) 长三角城市群碳排放空间滞后项的系数显著为正，当地碳排放对相邻城市碳排放的弹性系数约为0.73%，这表明长三角城市群碳排放存在相互促进的内部作用。从碳排放空间关联的角度，这反映出单边的减排努力容易被整个区域的碳排放增加所抵消，因此须采取系统减排策略以解决区域碳排放问题、抵制“搭便车”行为。

(2) 人口总量对于长三角城市群碳排放有着显著的正向影响。人口总量增加会直接促进消费规模扩大，进而引致生产规模扩大和能源消耗增长。化石能源占主体的能源结构下，人口总量增长最终会导致城市群碳排放总量增加。以城镇化率表征的人口结构同样有着显著的正向影响。产生大量消费需求的城镇人口集聚效应促进了地区碳排放增长，而提高资源利用效率以降低碳排放的人口规模效应却未能发挥应有之效。长三角城市群是中国重要的人口净流入地区，因此亟需优化公共服务等资源利用效率来激发人口规模效应，进而推动地区降碳。

(3) 经济增长与对外开放程度对长三角城市群碳排放均存在显著的正向影响，但经济增长对碳排放的拉动效应要大于城市对外开放程度提高。一方面，这说明长三角城市群的经济发展与碳排放尚未完全实现“脱钩”，经济增长的碳成本仍然较大；另一方面，外商直接投资多数集中于碳密集的第二产业，这也成为碳排放增长的重要因素。在发达国家“污染转移”的全球产业链空间格局下，长三角城市群有必要优化产业结构，实现从粗放式发展向绿色集约发展的转变。

(4) 以碳排放强度表征的减排技术对长三角城市群碳排放有着显著的正向作用。这表明通过缩短技术进步周期等方式加速减排技术突破，进而降低碳排放强度以有效推动长三角地区减排目标的早日实现。产业结构对长三角城市群碳排放存在并不显著的正向效应。虽然长三角城市群第三产业比重总体上逐渐扩大，但第二产业的绝对规模仍然处于稳定增长趋势进而产生更多化石能源的消耗。因此在关注产业转型的同时，也应该针对相关产业部门实施差异化减排战略，以绿色低碳生产技术的进步促进产业碳减排。

(5) 根据Lesage等的理论^[39]，本文进一步将各影响因素对长三角城市群碳排放的影响分解为直接效应和间接效应（表4）。其中直接效应与上文系数估计方向、显著性均保持一致，这也有效验证了回归结果的稳健性。经济发展水平的间接效应表明，经济增长对当地和周边城市碳排放都具备显著的正向影响。原因在于经济增长带来的消费生产扩张不仅体现在当地，也可能通过贸易往来加剧周边城市的生产碳排放。产业结构对碳排放的直接效应为正，间接效应却为负。这表明第二产业比重降低会减少当地碳排放，却可能通过高耗能产业转移等方式提升周边城市碳排放^[40]。为避免这种“碳泄露”现象，长三角城市群在其内部产业转移过程中也需要注重扩大减排技术的转移应用，以低碳技术的高效扩散促进地区绿色协同发展。

3.2 长三角城市群碳达峰预测分析

3.2.1 模型预测效果评估 BP神经网络模型、LSTM模型、GA-LSTM模型以及空间嵌入式GA-LSTM模型被用来对长三角城市群碳排放数据集进行训练测试，并进行拟合实验比较（75%的数据用于训练，25%的数据用于测试）（表5）。相较于BP神经网络模型和LSTM模型，GA-LSTM模型在MAE、MAPE和RMSE上表现更好，并且 R^2 更接近于1。表明不考虑碳排放空间关联的GA-LSTM模型对于城市群碳排放数据已具备更为优越的训练与拟合性能，在捕捉和映射碳排放变化特征方面具有较强的稳定性与精确性。而空间嵌入式GA-LSTM模型预测结果的各项指标，尤其是拟合精度，相较于GA-LSTM模型又有进一步提升，并且矩阵数据输入下潜在的维度过高问题也通过GA寻优得到了有效规避。这说明嵌入空间关联的预测逻辑提升了模型预测精度，能够更好地预测空间关联下长三角城市群碳达峰态势。此外，预测结果中各项指标并未出现所谓“非常见的优异”，且交叉验证的相关结果表明模型并不存在过拟合问题。

表 5 不同模型的预测性能评估

Tab. 5 Performance evaluation of different predictive models				
模型	R^2	MSE	RMSE	MAE
BP神经网络	0.75	105.60	10.28	6.45
LSTM模型	0.78	74.17	6.93	5.36
GA-LSTM模型	0.88	47.97	6.49	4.55
空间嵌入式GA-LSTM模型	0.96	42.06	6.14	4.13

前文空间计量模型的分析结果已明确经济发展水平和产业结构是形成城市群碳排放空间外溢性的关键所在。因此，本文进一步通过改变模型输入值的消融实验来评估是否存在简化空间嵌入式GA-LSTM模型复杂程度的可行性与必要性。

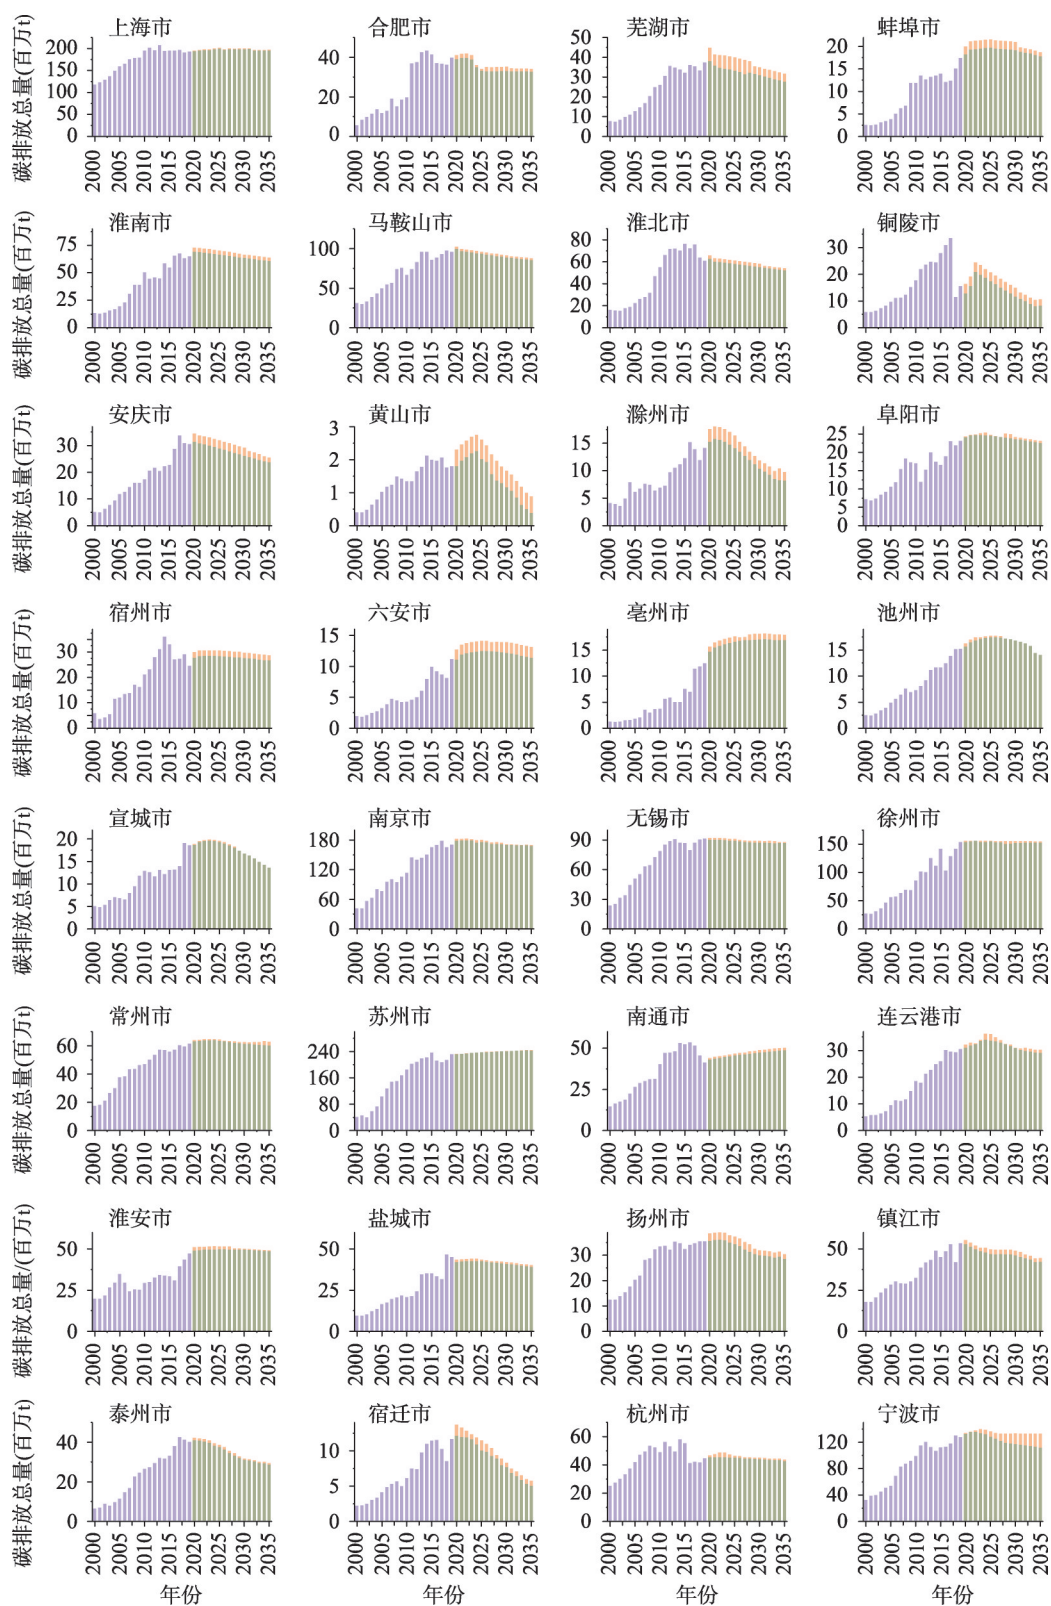
如表6所示，增加全部影响因素空间滞后项作为输入的空间嵌入式GA-LSTM模型在误差指标上表现更好。但与仅增加经济水平、产业结构两个影响因素空间滞后项作为输入的空间嵌入式GA-LSTM模型相比，模型实际性能提升幅度相对较小。这从数据层面验证了空间回归分析结果的科学性，有效表明经济发展水平和产业结构的空间滞后项已经能够在很大程度上解释长三角城市群碳排放的空间外溢效应。

表 6 基于空间嵌入式GA-LSTM模型的消融实验指标

Tab. 6 Metrics for ablation experiments based on spatially embedded GA-LSTM model				
模型	R^2	MSE	RMSE	MAE
空间嵌入式GA-LSTM模型(仅考虑显著空间滞后项)	0.96	42.06	6.14	4.13
空间嵌入式GA-LSTM模型(考虑全部空间滞后项)	0.97	42.03	5.57	3.84

基于空间嵌入式GA-LSTM模型的构建原理，纳入更多输入数据必然可以提高模型的精度，但可能会增加模型的复杂度与不稳定性。因此，根据消融实验的结果，仅考虑显著空间滞后项的空间嵌入式GA-LSTM模型设定更为合理。该简化设定可以有效保持模型拟合精度，同时显著提高模型的稳定性，使得模型更加实用和可靠^[41]。

3.2.2 空间嵌入式预测与传统预测的对比分析 为揭示空间关联效应对长三角城市群碳排放演化态势的影响，在基准情景下分别使用GA-LSTM模型和空间嵌入式GA-LSTM模型对长三角城市群碳排放进行预测。如图4所示，碳排放空间关联效应的存在显著降低了绝大多数城市2020—2035年间的碳排放规模，这对长三角城市群加快实现2060年的碳中和目标意义重大。这种空间关联效应产生的减排效果在安徽城市中表现得更为突出，而对



续图4




图4 基于空间嵌入式GA-LSTM模型与GA-LSTM模型预测结果对比

Fig. 4 Comparison of prediction results based on spatially embedded GA-LSTM model and GA-LSTM model

上海市以及大多数江苏省城市、浙江省城市的影响程度相对较低。这可能是由于安徽城市在长三角城市群碳排放空间网络中偏向于向其他板块发出碳排放关系的“净溢出”板块^[42]。达峰时间方面,空间关联效应对城市群碳排放态势的影响使得13个城市碳达峰时点发生改变。其中,安庆、无锡、宁波等10个城市提前实现了碳达峰,而徐州、常州、淮安3个江苏省城市的碳达峰时点在空间关联效应下被延后,但其相应的峰值水平仍得到显著降低。例如相较于未考虑空间关联效应的碳峰值,淮安在空间关联效应下的碳峰值水平下降了约3.5%。

通过对41个城市的预测结果进行汇总,可以发现基准情景下预测结果均显示长三角城市群在2022年左右可以实现碳达峰,其整体碳排放在2019—2022年间小幅惯性上升,在2022年之后呈现碳排放平稳下降的演化趋势,即长三角城市群整体。但GA-LSTM模型和空间嵌入式GA-LSTM模型揭示的长三角城市群整体碳峰值水平存在显著差异,空间关联效应的存在使得长三角城市群整体碳峰值水平下降了约3.8%。这与前述空间回归分析揭示的长三角城市群碳排放呈现正向溢出效应的结论相吻合,表明空间关联效应有助于增强长三角城市群碳排放的下降趋势,加速形成城市碳排放“低—低”空间聚集格局。

3.2.3 空间嵌入式预测的城市间对比分析

为明晰基准情景下长三角城市群能否顺利实现2030年前碳达峰,以及达峰后碳排放稳中有降的减排目标,本文首先从行政区划层面对长三角城市群2000—2035年的碳排放态势进行分析(图5)。从碳排放总量来看,长三角地区的省市间存在显著差异。上海市、江苏省苏州市和南京市、浙江省宁波市处于较高碳排放水平。从省内分异来看,江苏省内各市碳排放水平跨度较大,而浙江和安徽省内各市碳排放水平整体较低。

从碳达峰态势来看,长三角城市群整体碳排放在2022年后保持稳中有降态势,虽然未出现较大波动,但其碳排放下降速度实为缓慢。如图5所示,尽管上海市早在2013年就已经实现碳达峰,但其碳排放总量于2014—2035年间缓慢波动上升,未能有效逆转碳达

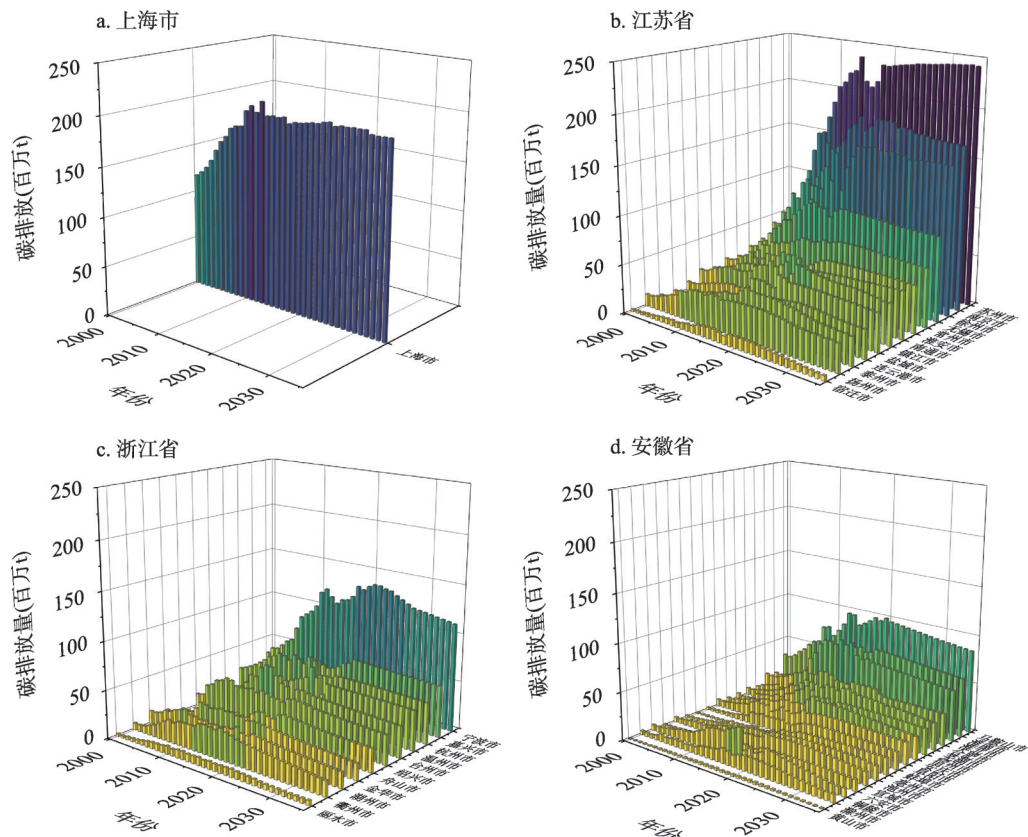


图5 长三角城市群碳排放历史演化与预测结果

Fig. 5 Historical evolution and prediction results of carbon emissions in the Yangtze River Delta urban agglomeration

峰后的反弹趋势。而经历2016—2019年碳排放骤降阶段从而实现碳达峰的南通市同样未能保持碳排放稳定下降，其碳排放总量于2019年之后持续上升且到2035年仍未出现转折趋势。江苏和浙江省的多数城市，如南京、徐州和宁波等在实现碳达峰后的碳排放下降趋势普遍较为缓慢。这表明长三角地区经济较为发达的城市在实现碳达峰后缺乏长效的减排机制保障，经济发展与碳排放的脱钩程度停滞不前，致使未来碳中和目标实现面临重大挑战。相比之下，安徽省各城市碳排放下降趋势更为显著，如合肥、淮南和淮北在2020年碳排放骤降后仍稳定下降。该现象一方面可能得益于“双碳”目标下安徽省城市从粗放式发展向绿色低碳发展进行快速转变；另一方面表明区域一体化发展下安徽省城市成为上海市、江苏省以及浙江省先进减排技术空间溢出效应的主要受益者。尽管这一过程很大程度上加速了安徽各城市的碳达峰进程，但达峰后的经济增长是否能与碳排放有效脱钩有待进一步考察。

从达峰时间来看，长三角城市群内部的多数城市均在2025年前实现了碳达峰，且达峰时间与其排放态势都呈现着区域“集聚”特征（图6a）。其中东部沿海地区城市的达峰时间相对较早，这也与他们早期进行产业转型的步调相一致。然而预测结果显示苏州市截至2034年才有望实现碳达峰，这或许是由于苏州近年来人口大量涌入以及产业多元化发展。人口增长与第二产业规模扩大的双重诱因导致了苏州市碳排放总量持续上升，从而未能顺利在2030年前实现碳达峰。长三角城市群西北地区的部分城市碳达峰时间相对较晚。对这些经济相对欠发达城市而言，发展与减排矛盾下减排压力重大，因此其碳达峰

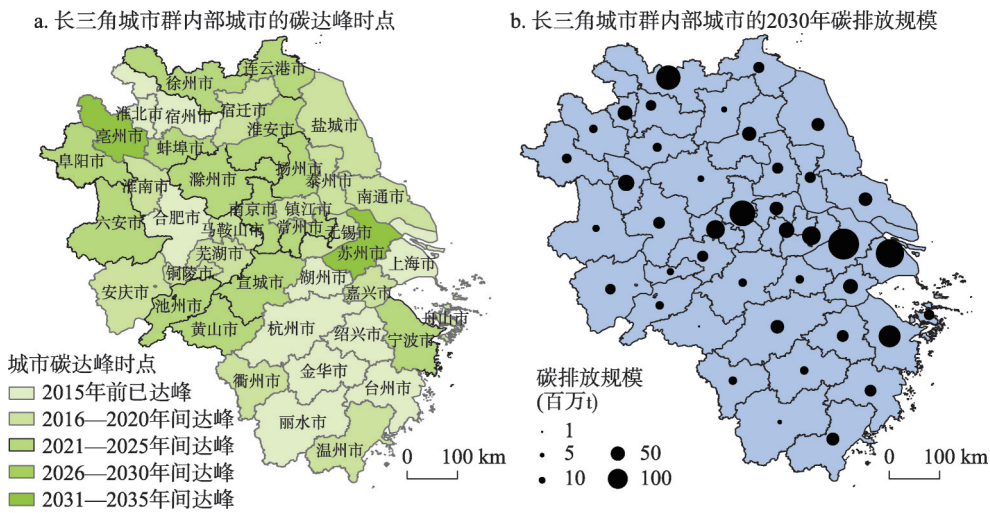


图6 长三角城市群碳达峰时间和碳排放空间分布特征

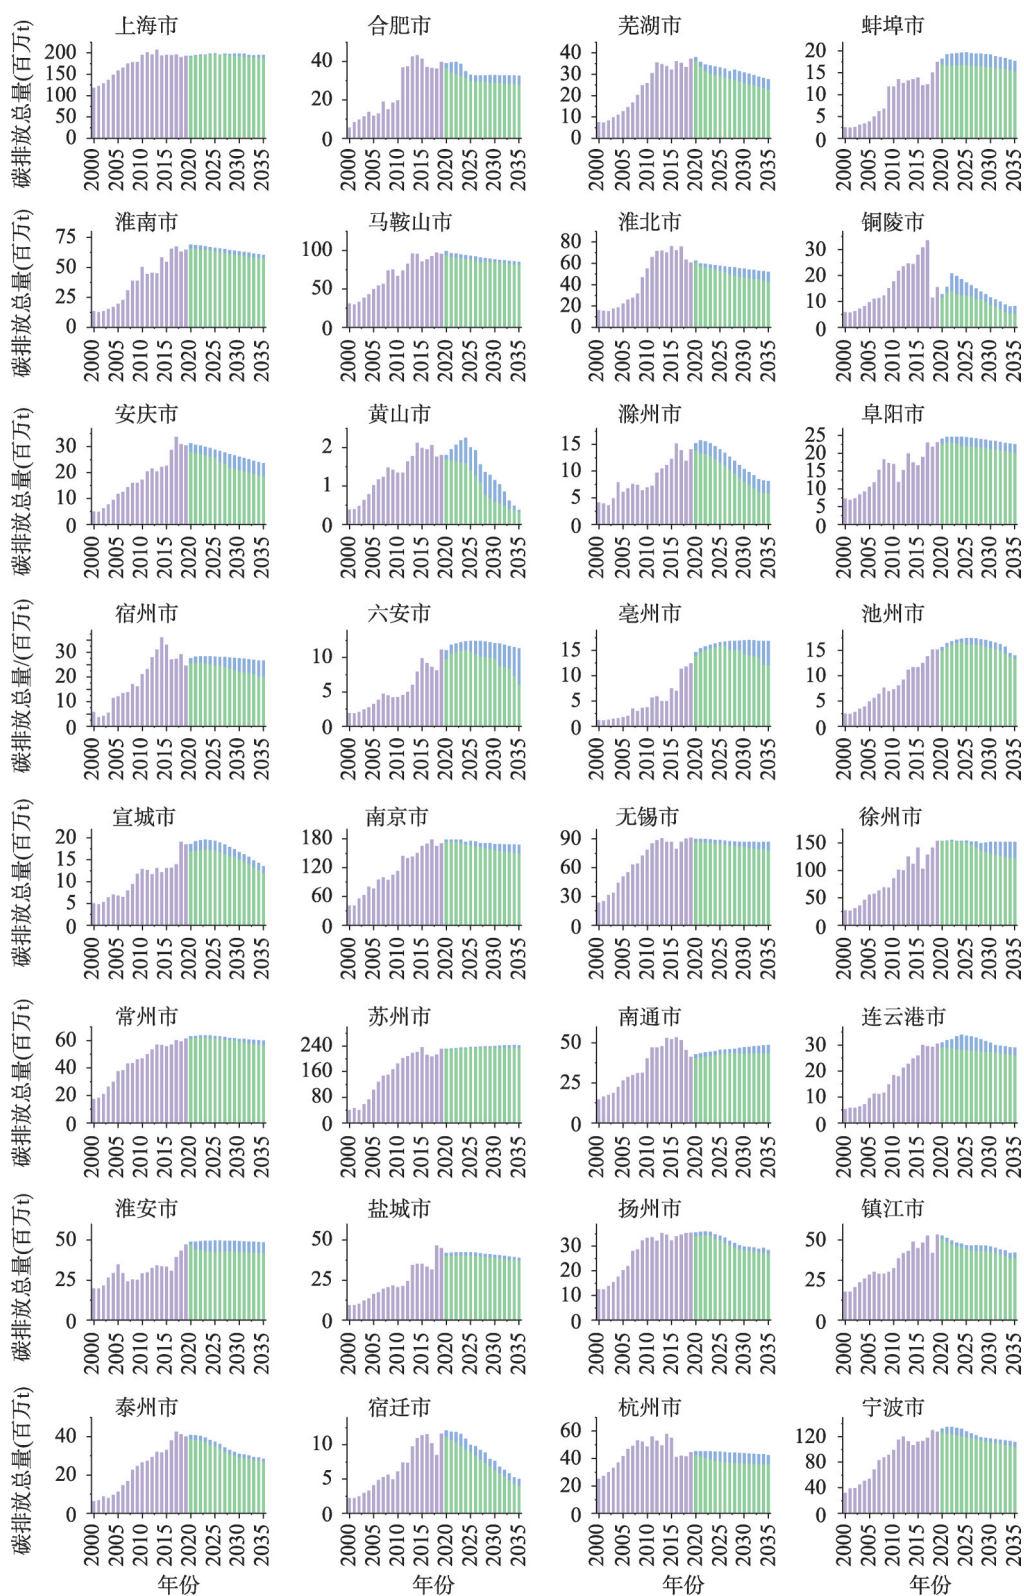
Fig. 6 Peaking time and spatial distribution of carbon emissions in the Yangtze River Delta urban agglomeration

峰进程会相对缓慢。省域层面，浙江省、江苏省各市以及上海市在达峰时间上较为接近且呈现梯级变化、连片分布，而安徽省各市碳达峰时间存在着明显的差异。碳达峰时间的地理集聚与分异特征表明较为发达的江浙沪地区的减排进度在更大程度上保持相对一致。尽管长三角城市群已经扩容至三省一市全域，但安徽相对独立的碳达峰进程表明其亟需破除行政地域区隔等无形壁垒，深度融入长三角区域一体化发展，以加速自身绿色低碳转型进程。

从碳排放量来看，长三角城市群到2030年的排放特征依然呈现着“东多西少，北多南少”的特征，有着“南北差异缩小，中部居高不下”的变化趋势（图6b）。上海、苏州等中东部沿海城市的碳排放总量保持稳定。例如上海的碳排放总量高点出现在2013年的2.1亿t，随后稳定在1.95亿t上下，而苏州的碳排放总量在2019年之后则稳定在2.3亿~2.4亿t。尽管多数城市在2025年前便已实现了达峰目标，但是其排放量下降速度趋缓。相比之下，长三角北部城市的减排幅度相对较大，淮南、淮北、滁州等城市2030—2035年的碳排放总量较峰值水平约下降20%以上，与长三角城市群南部低排放城市的排放差异呈逐渐缩小趋势。长三角南部城市的碳排放相对保持较低水平且波动程度较低，例如安徽南部的黄山其碳排放规模逐渐下降至0.01亿t以下，浙江南部的丽水其碳排放规模逐渐下降至0.05亿t以下。

3.2.4 空间嵌入式预测的多情景对比分析 当前“双碳”目标已经成为中国经济发展的主基调之一。为呼应“双碳”目标下各城市减排工作加速推进的客观现状，特别构建绿色情景。参照基准情景参数设定以及“十四五”规划等指导性政策文件，本文为绿色情景设定了更低的经济增速、第二产业比重以及碳排放强度水平。在空间嵌入式GA-LSTM模型预测过程中，单个城市的绿色情景主要表现为当地经济增速放缓、产业结构高级化进程加快、绿色减排技术加速进步，以及邻近城市的经济增速放缓、产业结构高级化进程加快。基准情景和绿色情景下的碳排放预测结果如图7所示。

在绿色情景下，长三角城市群整体碳达峰于2019年实现，达峰时点相较于基准情景提前了3年，峰值水平相较于基准情景下降了2.6%。这表明空间关联效应叠加绿色情景会使得长三角城市群整体更早地步入碳排放下行通道，并且其减排幅度也会进一步提升。



续图7

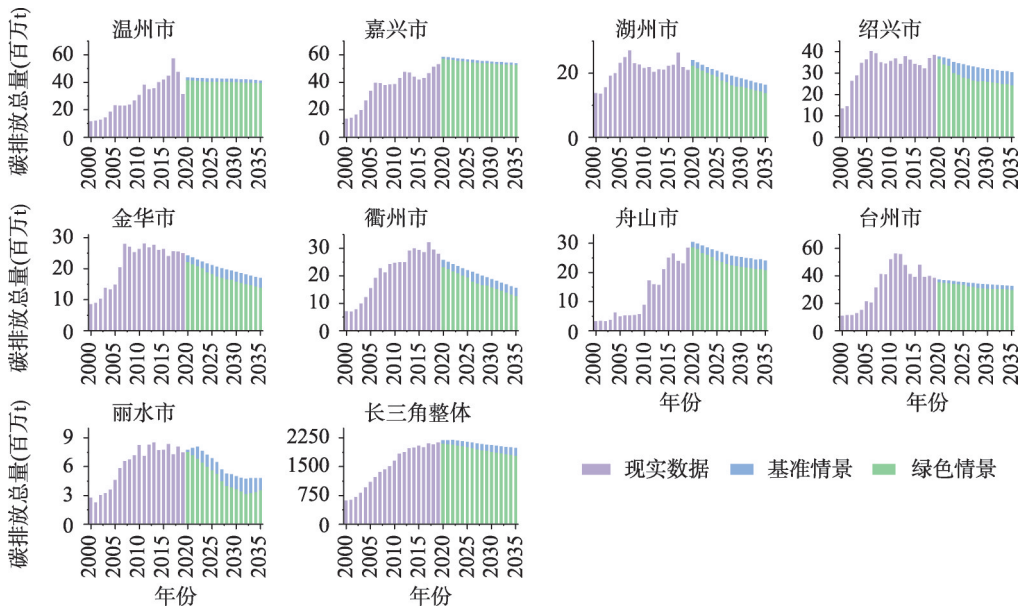


图7 基准情景与绿色情景下基于空间嵌入式GA-LSTM模型的预测结果对比
Fig. 7 Comparison of prediction results based on spatially embedded GA-LSTM model under baseline and green scenarios

达峰态势方面，相较于基准情景，绿色情景下绝大多数城市的碳排放演化态势呈现更为显著的下降趋势，这在达峰时间和峰值水平上均带来较大的改变。达峰时间方面，有22个城市的碳达峰时点在绿色情景下发生改变，并且均表现为达峰时点提前。除上海外，安徽省、江苏省、浙江省的整体碳达峰时点也均得以提前。绿色情景下的达峰时点变动存在空间异质性，安徽以及江苏的部分城市碳达峰时点受到影响较大，而上海以及浙江城市的碳达峰时点受到影响则相对较弱。峰值水平方面，绿色情景下所有城市实现碳达峰时的碳排放规模均有所下降，但减排作用同样存在空间异质性。以基准情景下的峰值水平情况为参照，绿色情景下安徽整体的碳排放降低了约9.5%，远高于江苏（3.9%）、浙江（5.3%）的整体减排效果。这可能是因为安徽绿色低碳技术水平较低，在绿色情景下能够同时受益于自身技术加速突破以及其他城市先进低碳技术传导的双重影响。

总体来说，绿色情景下长三角城市群存在着碳减排加速现象。这也由前文碳排放空间滞后系数为正的结论得以印证：显著的碳排放正向空间关联意味着长三角城市群碳排放存在明显的空间集聚现象，并表现为“一荣俱荣，一损俱损”的空间演化特征，凸显了城市群开展协同减排工作的重要性。影响因素方面，前述空间回归分析的结果表明，邻近城市的经济增速放缓导致其“辐射效应”减弱，从而显著降低当地碳排放；邻近城市的产业结构升级（第二产业比重降低）引致城市群内部产业梯度转移，从而显著加剧产业承接城市的碳排放。本文的预测结果表明，绿色情景下城市碳排放受到邻近城市的经济发展“辐射效应”要大于产业空间转移的影响，从而产生显著的减排成效。

4 结论与讨论

4.1 结论

本文在揭示并检验地理—经济空间距离下长三角城市群碳排放存在显著空间关联性的基础上，应用空间计量模型考察了长三角城市群碳排放的关键影响因素及其空间溢出

效应,并进一步构建空间嵌入式GA-LSTM预测模型对长三角城市群进行碳达峰路径模拟。主要结论如下:

(1) 长三角城市群碳排放在地理—经济加权距离上呈现明显的“集群”特征。2000—2019年间,长三角城市群碳排放呈“中东部排放骤增,南北部稳中有进”的态势。此外,随着区域经济社会发展,长三角城市群碳排放的空间关联程度不断增强,中部高排放、北部次之、南部低排放的梯级分布特征愈发显著。以上海、南京、宁波等为代表的中国东部沿海发达城市成为长三角城市群碳排放的主要来源。

(2) 空间回归分析结果显示,经济发展、对外开放以及城镇化水平对碳排放具有显著的正向影响,成为长三角城市群碳排放增长的关键诱因,而减排技术发展则会显著降低城市群碳排放。直接效应与间接效应的分解结果表明,经济水平提高对城市及其周边的碳排放均存在显著的正向影响,这可能是由长三角区域一体化深化下的跨越区域界限的消费及生产活动所引致。以第二产业比重降低为主要特征的产业结构调整可以显著降低当地碳排放,但可能通过产业转移等方式引起周边城市碳排放增加。

(3) 空间嵌入式预测与传统预测的结果对比显示,碳排放空间关联效应的存在会显著抑制长三角城市群的碳排放规模,从而有效降低其内部各城市碳峰值水平。部分城市的碳达峰时点在考虑空间关联效应的情况下得以提前,但徐州、常州、淮安三个城市反而出现碳达峰时点延后。两种模型在基准情景下的预测结果均表明长三角城市群整体碳排放在2019—2022年间有惯性增长趋势,整体可于2022年左右实现碳达峰,此后碳排放呈现稳定下降趋势。此外,相较于达峰时间和峰值水平,碳排放空间关联效应未显著改变城市的达峰后态势,这表明空间关联效应很可能仅仅影响了碳排在空间内的转移分配,并未从根源上形成城市群系统减排的内生动力。

(4) 达峰时点与峰值水平层面,空间嵌入式预测结果表明基准情景和绿色情景下长三角城市群整体分别于2022年、2019年实现碳达峰,其碳排放峰值水平在21.31亿~21.87亿t之间。除苏州和亳州以外,其他城市在两种情景下均能在2030年之前实现碳达峰。部分东部沿海城市的碳达峰时间较早,如上海、南通分别于2010年、2016年就已经实现碳达峰。而长三角城市群西北地区的部分城市达峰时间相对较晚,如亳州、蚌埠、六安和池州等城市于2030年左右才能实现碳达峰。到2035年碳排放总量较大城市分别是苏州、上海、南京和宁波。省域尺度下,浙江、江苏、上海内部达峰时间相近的城市基本呈现连片分布,而安徽省各市达峰时间却存在着明显的差异。

(5) 达峰后排放态势层面,基准情景下长三角城市群整体碳排放在2020年后保持缓慢下降趋势。安徽多数城市如芜湖、马鞍山和滁州均在2019年后实现碳排放稳中有降。合肥在2023—2024年间的碳排放骤降帮助其稳定了达峰后态势,随后碳排放下降却较为缓慢。而南京、无锡等江苏城市以及杭州、宁波等浙江城市达峰后的碳排放下降态势同样相对缓慢。此外,上海、南通、苏州在2019年之前均出现了碳排放相对高点,上海和常州后续呈现碳排放缓慢增加的反弹趋势,而苏州的碳排放则稳定上涨并于2027年超过历史高位。绿色情景下,长三角城市群达峰后态势发生较大变化,总体呈现出更为显著的碳排放下行趋势,表明绿色转型叠加空间关联效应可以有效促进城市群整体减排。但值得注意的是碳排放规模较大的苏州在2034年才有望实现碳达峰,因而需要采取更为严格的减排措施。

4.2 讨论

(1) 在区域一体化深入发展背景下,处于优化提升领先地位的长三角城市群亟需落实系统治理观念,完善区域协同减排的顶层设计,以空间关联下经济集聚和产业转型的

显著空间溢出效应为重要切点,推动区域绿色低碳转型。首先,鉴于经济增长的显著正向空间溢出效应,长三角城市群应妥善处理经济集聚对当地和周边城市的辐射效应。其次,由于第二产业发展会显著增加城市碳排放并显著降低周边城市的碳排放,需要重视产业转移背后的碳转移现象,促进产业优化配置与低碳发展。此外,在考虑经济集聚与产业转移方向的基础上,可将系统化减排方案制定与差异化减排政策实施相结合,以促进长三角城市群各城市实现2030年碳达峰与2035年后碳排放稳中有降的减排目标,并平衡整体减排与局部减排之间的关系。

(2) 不仅要关注城市群碳达峰的时点与峰值水平,也要关注达峰后碳排放演变态势。对上海、南通等较早实现碳达峰的城市来说,达峰后稳中有降的碳排放态势需要更高效的减排手段来支撑,如扩大清洁能源消费比重并提升能源利用效率。长三角西北部城市的经济发展水平相对较低,需要平衡发展与减排之间的矛盾。因而这些地区产业结构优化的优先级相对较高,亟需探索以产业转型升级为抓手的绿色低碳创新发展模式。对长三角城市群整体而言,需要处理好短期目标和长期目标之间的关系,持续深入推进长三角城市群一体化进程,实现碳密集产业在区域的稳妥有序转型。此外,还可通过积极发展清洁能源与生产减排技术,并利用两者的扩散效应以降低整个长三角地区碳排放,进而实现区域协同减排目标。

(3) 需要以区域环境联保共治机制配合城市绿色转型行动,从而有效形成长三角城市群减排合力。碳排放空间关联效应能显著影响长三角城市群的达峰时点和峰值水平,但并未有效改善其达峰后排放态势。而空间关联效应叠加绿色情景进一步使得长三角城市群在达峰时点、峰值水平和达峰后态势方面均呈现显著改善趋势。因此,在推进长三角城市群整体与局部绿色转型的过程中,一是需要注重充分发挥空间关联效应的积极作用,尤其需要处理好经济发展的碳辐射效应和产业转移过程中“碳泄露”问题,以优化城市群碳排放空间格局;二是必须要以强有力的外生动力改变碳排放增长趋势,从源头着手转变经济发展方式,以碳排放“双控”行动倒逼产业结构、能源结构转型,并制定相应的政策体系即法律法规,从根本上实现对碳排放问题的有效治理。

(4) 本文提出一种基于GA-LSTM架构的空间嵌入式优化神经网络预测模型,并实证模拟了长三角城市群碳达峰路径,以期长三角城市群率先实现“双碳”目标提供决策依据。但研究仍存在一些不足:① 本文在深度学习预测模型中嵌入空间权重矩阵以处理碳排放空间溢出效应,但鉴于神经网络表征能力较强、可解释性较弱的黑盒子特征,本文选择结合空间回归分析与空间嵌入式预测的方式来实现对碳排放影响因素的有效分析,从而间接为预测结果提供经济学解释。② 受限于城市能源数据的统计标准不一、口径缺失,城市碳排放数据难以直接测算获得。本文基于CEADs提供的城市碳排放数据集开展预测研究,通过CEADs提供的基于夜间灯光数据反演的县级碳排放数据集对城市碳排放数据进行补齐与趋势校正,并使用EDGAR数据库作验证对比。因此,建议未来的研究能够进一步聚焦复杂系统观下如何以可解释机器学习方法量化影响因素对邻近城市碳排放的影响程度,并发展城市碳排放核算方法以提供更具时效性与准确性的基础数据^[43]。

关联数据信息: 本文关联实体数据集已在科学数据银行(Science Data Bank)出版,获取地址<https://www.scidb.cn/s/2Mfeuy>, DOI: 10.57760/sciencedb.17027.

参考文献(References)

- [1] Shao Shuai, Zhang Ke, Dou Jianmin. Effects of economic agglomeration on energy saving and emission reduction: Theory and empirical evidence from China. *Management World*, 2019, 35(1): 36-60, 226. [邵帅, 张可, 豆建民. 经济集

- 聚的节能减排效应: 理论与中国经验. 管理世界, 2019, 35(1): 36-60, 226.]
- [2] Sheng Kerong, Li Xiaorui, Sun Wei, et al. Examining the impacts of network position on urban carbon emissions efficiency in China. *Acta Geographica Sinica*, 2023, 78(11): 2864-2882. [盛科荣, 李晓瑞, 孙威, 等. 中国城市网络地位对碳排放效率的影响. 地理学报, 2023, 78(11): 2864-2882.]
- [3] Samset B H, Fuglestedt J S, Lund M T. Delayed emergence of a global temperature response after emission mitigation. *Nature Communications*, 2020, 11(1): 3261. DOI: 10.1038/s41467-020-17001-1.
- [4] Wang Zheng, Cheng Zhanhong. Spatiotemporal interaction characteristics and transition mechanism of carbon intensity in China's service industry under the targets of carbon peak and carbon neutrality. *Acta Geographica Sinica*, 2023, 78(1): 54-70. [王峥, 程占红. “双碳”目标下中国服务业碳强度时空交互特征及跃迁机制. 地理学报, 2023, 78(1): 54-70.]
- [5] Xiao Jing, Zeng Ping. Digital economy enabling regional low-carbon transitions: Intrinsic mechanisms and spatial spillovers. *Modern Economic Research*, 2023(7): 23-33. [肖静, 曾萍. 数字经济赋能地区低碳转型: 内在机制与空间溢出. 现代经济探讨, 2023(7): 23-33.]
- [6] Wang Q, Han X Y. Is decoupling embodied carbon emissions from economic output in Sino-US trade possible? *Technological Forecasting and Social Change*, 2021, 169: 120805. DOI: 10.1016/j.techfore.2021.120805.
- [7] Zhang H Y, Zhang W, Lu Y L, et al. Worsening carbon inequality embodied in trade within China. *Environmental Science & Technology*, 2023, 57(2): 863-873.
- [8] Shao Shuai, Xu Lili, Yang Lili. Structural characteristics and formation mechanism of carbon emission spatial association networks within China. *Systems Engineering: Theory & Practice*, 2023, 43(4): 958-983. [邵帅, 徐俐俐, 杨莉莉. 千里“碳缘”一线牵: 中国区域碳排放空间关联网络的结构特征与形成机制. 系统工程理论与实践, 2023, 43(4): 958-983.]
- [9] Xu Weixiang, Zhou Jianping, Liu Chengjun. The impact of digital economy on urban carbon emissions: Based on the analysis of spatial effects. *Geographical Research*, 2022, 41(1): 111-129. [徐维祥, 周建平, 刘程军. 数字经济发展对城市碳排放影响的空间效应. 地理研究, 2022, 41(1): 111-129.]
- [10] Wang Kai, Tang Xiaohui, Gan Chang, et al. Temporal-spatial evolution and influencing factors of carbon emission intensity of China's service industry. *China Population, Resources and Environment*, 2021, 31(8): 23-31. [王凯, 唐小惠, 甘畅, 等. 中国服务业碳排放强度时空格局及影响因素. 中国人口·资源与环境, 2021, 31(8): 23-31.]
- [11] Wang Shaojian, Su Yongxian, Zhao Yabo. Regional inequality, spatial spillover effects and influencing factors of China's city-level energy-related carbon emissions. *Acta Geographica Sinica*, 2018, 73(3): 414-428. [王少剑, 苏泳娴, 赵亚博. 中国城市能源消费碳排放的区域差异、空间溢出效应及影响因素. 地理学报, 2018, 73(3): 414-428.]
- [12] Cheng Yeqing, Wang Zheyue, Zhang Shouzhi, et al. Spatial econometric analysis of carbon emission intensity and its driving factors from energy consumption in China. *Acta Geographica Sinica*, 2013, 68(10): 1418-1431. [程叶青, 王哲野, 张守志, 等. 中国能源消费碳排放强度及其影响因素的空间计量. 地理学报, 2013, 68(10): 1418-1431.]
- [13] Gao Guoli, Wen Yang, Wang Li, et al. Study on carbon peak of urban clusters based on analysis of influencing factors of carbon emissions. *Business and Management Journal*, 2023, 45(2): 39-58. [高国力, 文扬, 王丽, 等. 基于碳排放影响因素的城市群碳达峰研究. 经济管理, 2023, 45(2): 39-58.]
- [14] Xu Bin, Chen Yufang, Shen Xiaobo. Clean energy development, carbon dioxide emission reduction and regional economic growth. *Economic Research Journal*, 2019, 54(7): 188-202. [徐斌, 陈宇芳, 沈小波. 清洁能源发展、二氧化碳减排与区域经济增长. 经济研究, 2019, 54(7): 188-202.]
- [15] Shi C F, Zhi J Q, Yao X, et al. How can China achieve the 2030 carbon peak goal: A crossover analysis based on low-carbon economics and deep learning. *Energy*, 2023, 269: 126776. DOI: 10.1016/j.energy.2023.126776.
- [16] Yue Shujing. Factorization and scenario projections of peak carbon reach in the Yangtze River Delta Urban Agglomeration. *Guizhou Social Sciences*, 2021(9): 115-124. [岳书敬. 长三角城市群碳达峰的因素分解与情景预测. 贵州社会科学, 2021(9): 115-124.]
- [17] Yan Qing, He Chaoqi, Guo Huanxiu. Empirical study on carbon peaking in Yangtze River Delta cities based on regional integration. *Forum of World Economics & Politics*, 2022(3): 150-172. [晏清, 贺超飞, 郭焕修. 基于区域一体化的长三角城市群碳达峰实证研究. 世界经济与政治论坛, 2022(3): 150-172.]
- [18] Wang H P, Zhang Z. Forecasting Chinese provincial carbon emissions using a novel grey prediction model considering spatial correlation. *Expert Systems with Applications*, 2022, 209: 118261. DOI: 10.1016/j.eswa.2022.118261.
- [19] Fischer M M. Computational neural networks: A new paradigm for spatial analysis. *Environment and Planning A: Economy and Space*, 1998, 30(10): 1873-1891.
- [20] Li Xun, Xu Weipan, Huang Yaofu, et al. Spatial distribution of rural building in China: Remote sensing interpretation and density analysis. *Acta Geographica Sinica*, 2022, 77(4): 835-851. [李邴, 许伟攀, 黄耀福, 等. 基于遥感解译的中国

- 农房空间分布特征分析. 地理学报, 2022, 77(4): 835-851.]
- [21] Vu V H, Nguyen D L, Nguyen T H, et al. Self-supervised air quality estimation with graph neural network assistance and attention enhancement. *Neural Computing and Applications*, 2024, 36(19): 11171-11193.
- [22] Amato F, Guignard F, Robert S, et al. A novel framework for spatio-temporal prediction of environmental data using deep learning. *Scientific Reports*, 2020, 10(1): 22243. DOI: 10.1038/s41598-020-79148-7.
- [23] Liu Zhao, Wang Zilin, Yuan Cijia. Impact of independent technological innovation on industrial carbon emissions and trend prediction from the perspective of structure. *China Population, Resources and Environment*, 2022, 32(7): 12-21. [刘朝, 王梓林, 原慈佳. 结构视域下自主技术创新对工业碳排放的影响及趋势预测. 中国人口·资源与环境, 2022, 32(7): 12-21.]
- [24] Luan Jianlin, Feng Yinwei, Li Haijiang, et al. Research on the spatiotemporal prediction of ship carbon emissions based on the deep learning model. *Science Research Management*, 2023, 44(3): 75-85. [栾建霖, 冯胤伟, 李海江, 等. 基于深度学习模型的船舶碳排放时空预测研究. 科研管理, 2023, 44(3): 75-85.]
- [25] Jin G Y, Liang Y X, Fang Y C, et al. Spatio-temporal graph neural networks for predictive learning in urban computing: A survey. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(10): 5388-5408.
- [26] Zhang Jiawei, Chen Xi, Wang Shouyang. New spatial weight matrix and its application in China's regional foreign trade. *Systems Engineering: Theory & Practice*, 2009, 29(11): 84-92. [张嘉为, 陈曦, 汪寿阳. 新的空间权重矩阵及其在中国省域对外贸易中的应用. 系统工程理论与实践, 2009, 29(11): 84-92.]
- [27] Guo Yi, Cao Xianzhong, Wei Wendong, et al. The impact of regional integration in the Yangtze River Delta on urban carbon emissions. *Geographical Research*, 2022, 41(1): 181-192. [郭艺, 曹贤忠, 魏文栋, 等. 长三角区域一体化对城市碳排放的影响研究. 地理研究, 2022, 41(1): 181-192.]
- [28] Wang Shaojian, Xie Zihan, Wang Zehong. The spatiotemporal pattern evolution and influencing factors of CO₂ emissions at the county level of China. *Acta Geographica Sinica*, 2021, 76(12): 3103-3118. [王少剑, 谢紫寒, 王泽宏. 中国县域碳排放的时空演变及影响因素. 地理学报, 2021, 76(12): 3103-3118.]
- [29] Shao Shuai, Li Xin, Cao Jianhua, et al. China's economic policy choices for governing smog pollution based on spatial spillover effects. *Economic Research Journal*, 2016, 51(9): 73-88. [邵帅, 李欣, 曹建华, 等. 中国雾霾污染治理的经济政策选择: 基于空间溢出效应的视角. 经济研究, 2016, 51(9): 73-88.]
- [30] Yu S W, Zhang Q, Hao J L, et al. Development of an extended STIRPAT model to assess the driving factors of household carbon dioxide emissions in China. *Journal of Environmental Management*, 2023, 325: 116502. DOI: 10.1016/j.jenvman.2022.116502.
- [31] Zhang S, Tong H H, Xu J J, et al. Graph convolutional networks: A comprehensive review. *Computational Social Networks*, 2019, 6(1): 11. DOI: 10.1186/s40649-019-0069-y.
- [32] Shao Z, Gao S N, Zhou K L, et al. A new multiregional carbon emissions forecasting model based on a multivariable information fusion mechanism and hybrid spatiotemporal graph convolution network. *Journal of Environmental Management*, 2024, 352: 119976. DOI: 10.1016/j.jenvman.2023.119976.
- [33] Liu H X, Han Q L, Sun H, et al. Spatiotemporal adaptive attention graph convolution network for city-level air quality prediction. *Scientific Reports*, 2023, 13(1): 13335. DOI: 10.1038/s41598-023-39286-0.
- [34] Zhu D, Liu Y, Yao X, et al. Spatial regression graph convolutional neural networks: A deep learning paradigm for spatial multivariate distributions. *GeoInformatica*, 2022, 26(4): 645-676.
- [35] Zhang Jinliang, Li Chao. Research on dynamic distribution vehicle route optimization under the influence of carbon emission. *Chinese Journal of Management Science*, 2022, 30(9): 184-194. [张金良, 李超. 碳排放影响下的动态配送车辆路径优化研究. 中国管理科学, 2022, 30(9): 184-194.]
- [36] Tian Yun, Yin Minhao. Does technological progress promote carbon emission reduction of agricultural energy? Test based on rebound effect and spatial spillover effect. *Reform*, 2021(12): 45-58. [田云, 尹恣昊. 技术进步促进了农业能源减排吗? 基于回弹效应与空间溢出效应的检验. 改革, 2021(12): 45-58.]
- [37] Zheng H R, Zhang Z K, Wei W D, et al. Regional determinants of China's consumption-based emissions in the economic transition. *Environmental Research Letters*, 2020, 15(7): 074001. DOI: 10.1088/1748-9326/ab794f.
- [38] European Commission. GHG Emissions of All World Countries. Luxembourg: Publications Office of the European Union, 2023.
- [39] LeSage J P, Pace R K. Introduction to Spatial Econometrics. New York: CRC Press, 2009.
- [40] Zhu Yongli, Ding Lijie. Spatial effects and influencing factors of carbon emission intensity in the Yangtze River Delta urban agglomeration: An industrial transfer-based perspective. *Resources Science*, 2022, 44(7): 1373-1387. [朱泳丽, 丁利杰. 长三角城市群碳排放强度的空间效应及影响因素: 基于产业转移视角. 资源科学, 2022, 44(7): 1373-1387.]

- [41] Liang X D, Li X Y. Carbon emission causal discovery and multi-step forecasting for global cities. *Cities*, 2024, 148: 104881. DOI: 10.1016/j.cities.2024.104881.
- [42] Yu Jie, Zhang Yong, Li Qingyao. Structural characteristics and evolutionary mechanism of spatial correlation network of carbon emissions in the Yangtze River Delta. *Journal of Natural Resources*, 2024, 39(2): 372-391. [俞洁, 张勇, 李清瑶. 长三角碳排放空间关联网络结构特征及演化机制. *自然资源学报*, 2024, 39(2): 372-391.]
- [43] Ma Li, Wang Jingxu, Zhang Didi, et al. Developing FF_{CO₂} emission inventory with high spatio-temporal resolution: Methodology and prospects. *Acta Geographica Sinica*, 2022, 77(3): 650-664. [马立, 王璟煦, 张迪迪, 等. 高时空分辨率 FF_{CO₂}排放清单的构建方法及研究展望. *地理学报*, 2022, 77(3): 650-664.]

Carbon peak prediction for Yangtze River Delta urban agglomeration based on spatially embedded GA-LSTM model

SHI Changfeng¹, YU Yue¹, YAO Xiao², PANG Qinghua¹

(1. School of Economics and Finance, Hohai University, Changzhou 213200, Jiangsu, China;

2. College of Information Science and Engineering, Hohai University, Changzhou 213200, Jiangsu, China)

Abstract: Urban agglomerations serve as crucial platforms for constructing substantial domestic circulation and fostering harmonious regional development in China. Given the evolution of the integrated development of urban agglomerations, the characteristics of their internal spatial networks inevitably lead to the carbon peak paths of individual cities being influenced by their proximate counterparts. Consequently, this study focused on the Yangtze River Delta urban agglomeration, which boasts a high degree of integration within China, constructed a spatial weight matrix based on composite geographic and economic dimensions, applied a spatial econometric model to analyze the spatial correlation of carbon emissions in this urban agglomeration, and further applied the spatially embedded Genetic Algorithm-Long Short-Term Memory (GA-LSTM) model to simulate dynamically the peak paths of carbon emissions in this urban agglomeration. The empirical results revealed several important findings: (1) Considering the spatial correlation effects of the urban agglomeration, the carbon peaks of several cities occur sooner than expected, and most cities experience a reduction in their peak level, indicating that the spatial correlation effect can effectively optimize the spatial pattern of carbon emissions. However, the post-peak emission dynamics of these cities are not significantly affected. (2) In the baseline scenarios, with the exception of Suzhou (Jiangsu) and Bozhou, all cities attain their carbon peak by 2030, with most cities in Anhui province maintaining a steady decrease in carbon emissions after 2019, some cities in Jiangsu and Zhejiang provinces experiencing a relatively slow decrease in carbon emissions after reaching the peak, and Shanghai and Nantong showing a rebound trend of slow increase in carbon emissions after reaching their peak at an early stage. (3) Under the green scenarios, the total carbon emissions from the Yangtze River Delta urban agglomeration follow a steady downward trend since 2019, effectively reversing the inertial growth under the baseline scenarios, and the cities within the urban agglomeration show significant improvement in the time to peak, peak level, and post-peak situation, which contributes to a synergistic emission reduction pattern.

Keywords: carbon peak; path simulation; spatial correlation; GA-LSTM model; Yangtze River Delta urban agglomeration