

基于机器学习和 LEAP 模型的智慧城市碳减排效应研究

曹雄智¹ 牟俊杰¹ 潘柏州¹ 肖超¹ 张宇杰^{1*}

1. 成都工业学院 土木工程系 四川宜宾 644000

DOI:10.12238/ems.v7i12.16416

[摘要] 为研究智慧城市试点政策对城市双碳减排的影响,本文采用多种机器学习回归模型进行数据驱动,对智慧城市的碳排放进行预测,并构建 LEAP 模型,引入政策因素,对智慧城市减排潜力进行量化分析。文章结合了 BP 神经网络、LSTM、SVM 与随机森林 4 种机器学习方法,对 2024 年—2035 年不同城市 4 种基准情景下的碳排放量趋势进行了预测;并设计技术扩散曲线构建 LEAP 模型,通过情景模拟定量评估智慧城市试点政策在交通和工业领域的减排潜力。结果表明:智慧城市试点政策有效缓解了部分城市碳排放的快速上升趋势,但全国整体碳排放依然呈稳步增长态势,这提示现行政策在执行力度、技术推广和政策协同上仍有较大优化空间。

[关键词] 智慧城市试点政策; 碳减排; 机器学习; LEAP 模型

为推动绿色低碳发展和应对全球气候变化,中国提出力争在 2030 年前实现碳达峰,2060 年前实现碳中和的“双碳”目标^[1-2]。智慧城市试点政策是中国为探索新型城市发展模式、推动信息技术与城市治理深度融合而开展的系统性改革试验^[3-4]。随着“双碳”目标的推进,智慧城市建设被视为实现城市低碳转型的关键路径,但试点政策对碳减排的实际影响及作用机制仍需系统验证。

对于政策作用效果的评估一般有 3 种方法:定量分析方法、定性分析方法和建立综合评估框架的方法^[5-7]。不同的评估方法对于政策作用效果的侧重点各不相同,因此选择一个适合的方法对于评估政策作用效果的准确性和实用性具有至关重要的作用。目前国内外学者对于智慧城市试点政策的碳减排效应研究较为全面,总结出了众多的研究方法,李欣睿^[8]采用构建动态空间 DID 模型,使用 SBM-GML 指数分解的方法对智慧城市试点政策的碳减排效应进行研究,结果表明智慧城市建设短期降低碳排放,而长期增加碳排放。刘潇^[9]采用构建多期 DID 模型与多种稳健性方法对智慧城市试点政策的碳减排效应进行研究,结果表明智慧城市建设碳减排效应具有正向的空间溢出效应。尹碧波与邝萍^[10]采用双重机器学习模型与广义随机森林相结合的方法对智慧城市试点政策的碳减排效应进行研究,结果表明智慧城市建设能显著降低碳排放。栾尊其^[11]采用空间双重差分模型(SDID)与空间三重差分模型(SDDD)的方法研究智慧城市建设对碳排放的影响,结果表明智慧城市建设显著降低碳排放,平均减排约 4.8%,其中领先型城市可减排 14.4%。从目前的研究成果来看,对于智慧城市试点政策的碳减排效应研究大多采用双重差分法(DID)、双重机器学习因果判断、广义随机森林等计量经济模型,因此对智慧城市试点政策的碳减排效应研究较为局限,有必要对其进行更深入的研究。

本文针对智慧城市试点政策的碳减排效应,采用定量分析与定性分析相结合的方式,首先构建碳排放量预测模型,运用多种机器学习方法预测出 2025 年—2035 年 4 种基准情景下城市的碳排放量,然后根据专家及行业标准对智慧城市碳减排的途径进行定性分析,确定最终参与智慧城市试点政策减排潜力量化分析的方向与指标,最后构建 LEAP 模型,引入智慧城市试点政策因素的影响,对 2025 年—2035 年 4 种基准情景下城市的预测碳排放量进行校准。

1 碳排放量预测

1.1 数据处理

本文主要从全国 293 个地级市入手进行数据调查,采用 Python, R, SPSS 以及 MATLAB 进行综合分析。为消除搜集数据中的主观因素影响,主要通过数据网站确保其来源的真实性,本文于以下权威数据网站进行数据调查:国家统计局、各省市统计局、CEIC 宏观经济数据库及中经网统计数据库。

1.2 基于 BP 神经网络回归模型的碳排放量预测模型构建

BP 神经网络(Back Propagation Neural Network, BP)是一种多层的前馈神经网络,其主要特点是信号的前向传播和误差的反向传播,该网络通过不断调整神经元之间的连接权重和偏置,使得网络的输出能够逼近真实的目标输出。

BP 神经网络的过程主要分为两个阶段,第一阶段是信号的前向传播,从输入层经过隐含层,最后到达输出层;第二阶段是误差的反向传播,从输出层到隐含层,最后到输入层,依次调节隐含层到输出层的权重和偏置,输入层到隐含层的权重和偏置。

隐含层的输出量设为 F_j , 输出层的输出量设为 O_k , 系统的激励函数设为 G , 学习速率设为 β , 则其三个层之间有如下数学关系:

$$F_j = G\left(\sum_{i=1}^m w_{ij} * x_i + a_j\right) \quad (1.1)$$

$$O_k = \sum_{j=1}^1 F_j * w_{kj} + b_k \quad (1.2)$$

式中: w_{ij} 表示从输入层到隐藏层的权重, 即输入层 x_i 与隐藏神经元 F_j 之间的连接强度; a_j 表示隐藏层第 j 个神经元的偏置; b_k 表示输出层第 k 个神经元的偏置。系统期望的输出量设为 T_k , 则系统的误差 E 可由实际输出值和期望目标值的方差表示, 具体关系表达式如下:

$$E = \frac{1}{2} * \sum_{k=1}^n (T_k - O_k)^2 \quad (1.3)$$

并令 $e_k = T_k - O_k$, 利用梯度下降原理, 则系统权值和偏置的更新公式如下:

$$w_{ij} = w_{ij} + \beta * F_j * (1 - F_j) * x_i * \sum_{k=1}^n w_{kj} * e_k \quad (1.4)$$

$$w_{jk} = w_{jk} + \beta * F_j * e_k \quad (1.5)$$

$$a_j = a_j + \beta * F_j * (1 - F_j) * x_i * \sum_{k=1}^n w_{jk} * e_k \quad (1.6)$$

$$b_k = b_k + \beta * e_k \quad (1.7)$$

最后, 重复上述计算步骤, 直至达到误差要求或达到最大计算次数。

1.3 基于长短期记忆网络回归模型的碳排放量预测模型构建

长短期记忆网络 (Long Short-Term Memory, LSTM) 是一种特殊的循环神经网络, 旨在解决传统 RNN 在处理长序列数据时的梯度消失和梯度爆炸问题。LSTM 通过引入细胞状态和门控机制, 有效地捕捉长距离依赖关系, 广泛应用于自然语言处理、时间序列预测和语音识别等领域。LSTM 回归模型构建一般分为 4 个步骤: 数据划分、前向传播、滑动预测、参数优化。基于 LSTM 回归模型的碳排放量预测模型原理具体如下:

第一步, 将 2002 年—2022 年的数据按 7: 3 的比例划分为训练集与验证集, 设输入特征维度为 n , LSTM 隐藏层神经元数量为 m , 则输入需转换为三维张量 $X_{input} \in R^{N \times n \times 1}$, 其中 $N=21-n$ 为样本数, 最后一维“1”表示碳排放量这个单变量。

第二步, 设在窗口的第 t 年的碳排放量为 x_t , 隐藏状态为 h_t , 细胞状态为 c_t , 则 LSTM 门控公式可以表示为:

$$\begin{cases} f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \\ \tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \\ c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\ o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t = o_t \odot \tanh(c_t) \end{cases} \quad (1.8)$$

式中: f_t 表示预测的第 t 年的碳排放量, W_f 表示遗忘门权重矩阵, b_f 表示遗忘门偏置, σ 表示 sigmoid 激活函数, \tilde{c}_t 表示候选细胞状态, i_t 表示输入门控制, \tanh 为双曲正切函数, \odot 表示元素-wise 乘法, o_t 表示输出值, W_o 表示输出层权重矩阵, b_o 表示输出层偏置。

第三步, 对下一年的碳排放量进行预测, 具体公式如下:

$$\hat{y} = W_o * h_n + b_o \quad (1.9)$$

式中, \hat{y} 表示预测的碳排放量。

第四步, 求出损失函数并对参数进行优化, 具体公式如下:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - Y_i)^2 \quad (1.10)$$

式中: θ 表示所有需要优化的参数。

循环上述步骤, 直至验证集损失不再下降或达到最大训练次数。

1.4 基于支持向量机回归模型的碳排放量预测模型构建

支持向量机 (Support Vector Machine, SVM) 是一种监督学习算法, 主要用于分类任务 (也可扩展到回归和异常检测), 其核心目标是在特征空间中找到一个最优超平面, 将不同类别的样本分隔开, 且使间隔最大化。SVM 回归模型构建一般分为 4 个步骤: 构建基本线性函数、求出损失函数与目标函数、转化为对偶函数、计算偏置。基于 SVM 回归模型的碳排放量预测模型原理具体如下:

第一步, 构建基本线性函数, 设 X_i 为滑动窗口数, 则具体公式如下:

$$f(X) = w^T X + b \quad (1.11)$$

式中: $f(X)$ 表示预测值, w 表示权重变量, b 表示偏置。

第二步, 引入松弛变量处理误差, 求出损失函数与目标函数, 具体公式如下:

$$\begin{aligned} & \min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \\ & s.t. \begin{cases} Y_i - (w^T X_i + b) \leq \epsilon + \xi_i \\ (w^T X_i + b) - Y_i \leq \epsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0 (i=1, 2, \dots, N) \end{cases} \end{aligned} \quad (1.12)$$

式中: ϵ 表示不敏感损失函数, C 表示惩罚系数, ξ_i, ξ_i^* 表示松弛变量。

第三步，通过拉格朗日乘法将原始问题转化为对偶问题，引入核函数 $K(X_i, X) = \phi(X_i)^T \phi(X_j)$ (ϕ 为高维映射函数)，得到最终预测函数为：

$$f(X) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(X_i, X) + b \quad (1.13)$$

式中： α_i ， α_i^* 表示拉格朗日乘子。

第四步，通过支持向量计算偏置，具体公式如下：

$$b = Y_i - \epsilon - \sum_{j=1}^N (\alpha_j - \alpha_j^*) K(X_j, X_i) \quad (1.14)$$

1.5 基于随机森林回归模型的碳排放量预测模型构建

随机森林 (Random Forest, RF) 是一种基于集成学习的算法，它通过构建多个决策树并将它们的预测结果进行集成来进行回归任务。在随机森林中，每棵决策树都是独立并在随机选择的子样本上进行训练的，这样可以有效地减少过拟合的风险，随机森林通过将多个决策树的预测结果进行平均或加权平均，从而得到最终的回归结果。随机森林回归模型一般分为 3 个步骤：数据采样、训练树模型、集成预测。基于随机森林回归模型的碳排放量预测模型原理具体如下：

给定数据集 $\{C_t\}_{t=2002}^{2022}$ ，其中 t 表示年份， C_t 表示第 t 年的碳排放量。采用时间序列分割的数据分割策略，训练集为前 80% 的样本，测试集为后 20% 的样本。第一步，采用 bootstrap 方法进行数据采样，先从训练集 D 中有放回地抽取 n 个样本，则对于第 b 棵树的样本 D_b ，可以用下列公式表示：

$$D_b = \{(x_{i1}, y_{i1}), (x_{i2}, y_{i2}), \dots, (x_{in}, y_{in})\} \quad (1.15)$$

然后确定袋外样本第 b 棵树的 OOB 样本为：

$$D_{OOB}^{(b)} = \{(x_i, y_i) : (x_i, y_i) \in D \text{ 且 } (x_i, y_i) \notin D_b\} \quad (1.16)$$

第二步，首先进行随机森林构建，具体公式如下：

$$RF = \{T_1, T_2, \dots, T_B\} \quad (1.17)$$

式中：每棵树 T_b 均使用 bootstrap 样本 D_b 和随机特征选择策略训练。然后对新样本进行随机森林预测，设新样本为 x_{new} ，将新样本输入每棵树，在每棵树中，从根节点开始，根据分裂条件递归向下，到达叶子节点时，输出该节点的预测值 $T_b(x_{new})$ ，最后对所有树的预测结果求平均值，具体公式如下：

$$\hat{y}_{RF}(x_{new}) = \frac{1}{B} \sum_{b=1}^B T_b(x_{new}) \quad (1.18)$$

循环上述过程，直至分裂数达到最大分裂数或样本数小于最小分裂样本数。

1.6 研究结果与分析

分别采用基于 BP 神经网络、LSTM、支持向量机 (SVM)、随机森林 (RF) 构建的碳排放量预测模型对 293 个地级市 2023 年—2035 年的碳排放量进行预测，并对 4 种机器学习回归模型进行模型评价，将上述 4 种机器学习回归模型对于测试集和训练集的均方根误差 (RMSE) 进行对比分析 (见图)，可以看出 4 种机器学习回归模型对于测试集预测的均方根误差 (RMSE) 均较大，且 LSTM 回归模型 > BP 回归模型 > RF 回归模型 > SVM 回归模型，4 种机器学习模型对于训练集预测的均方根误差均出现显著下降，最终结果 SVM 回归模型 < BP 回归模型 < RF 回归模型 < LSTM 回归模型。从预测结果对比图中 (见图 1) 也可以得知 SVM 回归模型的预测结果更接近真实值。

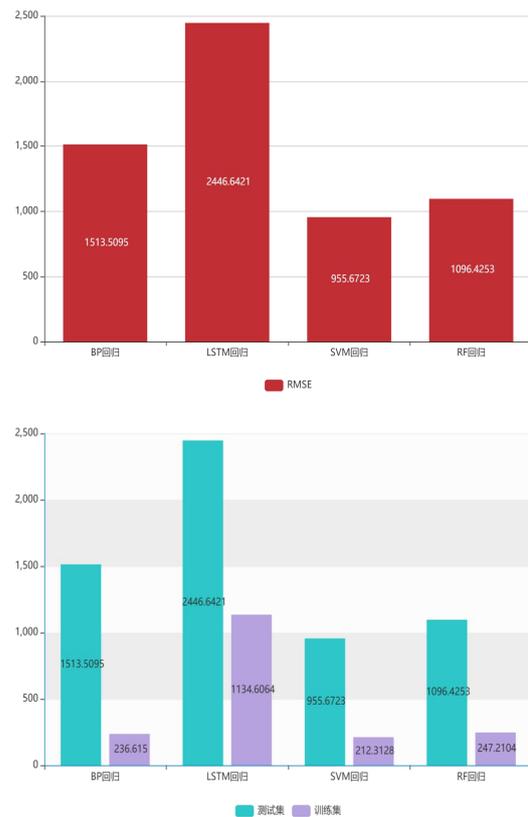


图 1 模型性能对比图

由此可得出，4 种机器学习回归模型中，LSTM 回归模型预测效果最差，SVM 回归模型预测效果最好，因此最终采用 SVM 回归模型的预测结果。然后从 293 个地级市中根据 4 种基准情景 (2012 年实行智慧城市试点政策、2013 年实行智慧城市试点政策、2015 年实行智慧城市试点政策、未实行智慧城市试点政策) 挑选出 4 个具有代表性的城市进行对比，挑选尽量按照不同地区、不同规模的原则进行，最终确定北京市、兰州市、呼和浩特市、商洛市 4 个基准情景代表城市，4 种基准情景下 SVM 回归模型预测结果如下图 2 所示：

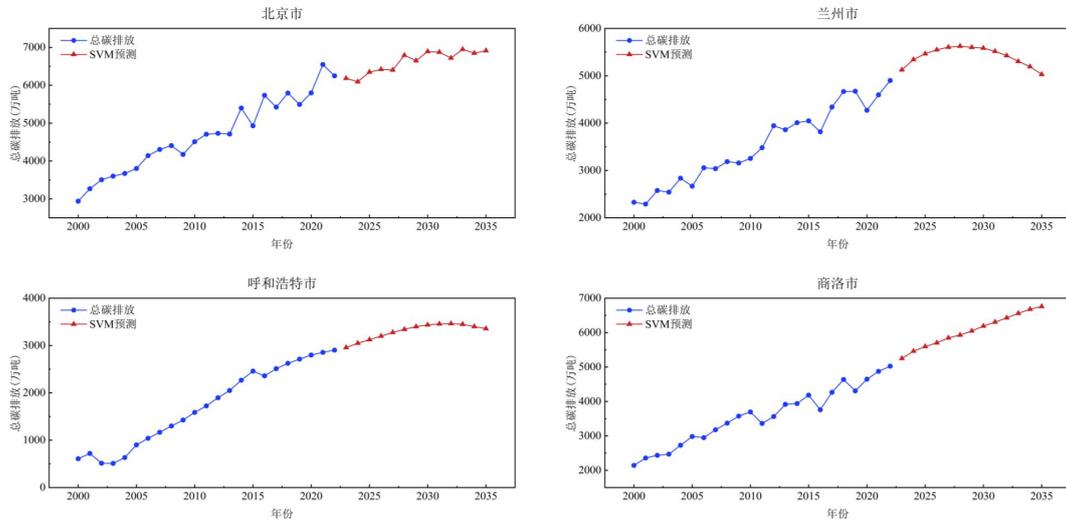


图 2 SVM 预测结果图

由原数据和 SVM 预测结果所示，从 2000 年—2022 年北京市碳排放量虽然有一定波动，但整体呈现稳步上升的趋势，从 2023 年以后北京市碳排放量虽然也会上升，但上升幅度将逐渐减小，逐渐实现碳达峰的目标。兰州市预计将在 2028 年实现碳达峰的目标，呼和浩特市预计将在 2032 年实现碳达峰的目标，商洛市碳排放量稳步上升，在 2035 年以后才能实现碳达峰。

2 减排潜力量化分析

2.1 指标选取

根据对城市碳排放量影响最大的因素考虑，本文将从交通减排、工业减排两个方面对智慧城市试点政策对各地级市的双碳减排效应进行衡量。

1. 交通减排

交通减排是影响城市碳排放总量的重要因素，因此本文选用交通减排作为衡量双碳减排效应的指标之一。交通减排含有很多要素，为了更准确地反映智慧城市交通减排策略对双碳减排的影响，引入电动汽车渗透率、共享出行比例、交通大脑调控强度三个变量，分别记为 traffic-1、traffic-2、traffic-3。

2. 工业减排

工业一直是能源消耗和二氧化碳排放的最主要来源，工业领域的碳达峰进度直接影响整体碳达峰的实现进度，因此本文将工业减排作为衡量双碳减排效应的第二个指标，引入工业光伏装机量、工业节能率两个变量，分别记为 industry-1、industry-2。

2.2 LEAP 模型构建

长期能源替代规划系统 (Long-range Energy Alternat

ives Planning System, LEAP) 是一个广泛使用的能源-环境模型工具，由斯德哥尔摩环境研究所开发，主要用于分析能源政策、气候变化缓解策略及可持续发展规划。LEAP 模型的构建主要分为三个步骤：需求树构建、技术扩散曲线构建、情景模拟执行参数校准。

第一步，在指标选取时已经构建，核心目标是双碳减排，通过拆解交通减排和工业减排两大关键领域，构建了多层次的减排路径及量化指标，最终指向碳排放量的优化。

第二步，根据上述需求建立技术扩散曲线，具体公式如下：

$$P(t) = \frac{K}{1 + e^{-r(t-t_0)}} \quad (1.19)$$

式中： K 表示技术最大渗透率， r 表示扩散速度， t_0 表示拐点年份，由各地级市需求树中目标交通减排量和目标工业减排量设定技术最大渗透率，扩散速度（即政策强度）均设为 0.2，拐点年份根据各地级市入选智慧城市试点政策年份而定。

第三步，对基准情景进行校准，设置关键校准参数如下表所示：

符号	变量名称	关键校准参数
traffic-1	电动汽车渗透率	一年上升 5%
traffic-2	共享出行比例	一年上升 2%
traffic-3	交通大脑调控强度系数	一年上升 1%
industry-1	工业光伏装机量	一年上升 5%
industry-2	工业节能率	一年上升 5%

2.3 研究结果与分析

根据上述情景进行模拟，预测结果如图 3 所示：

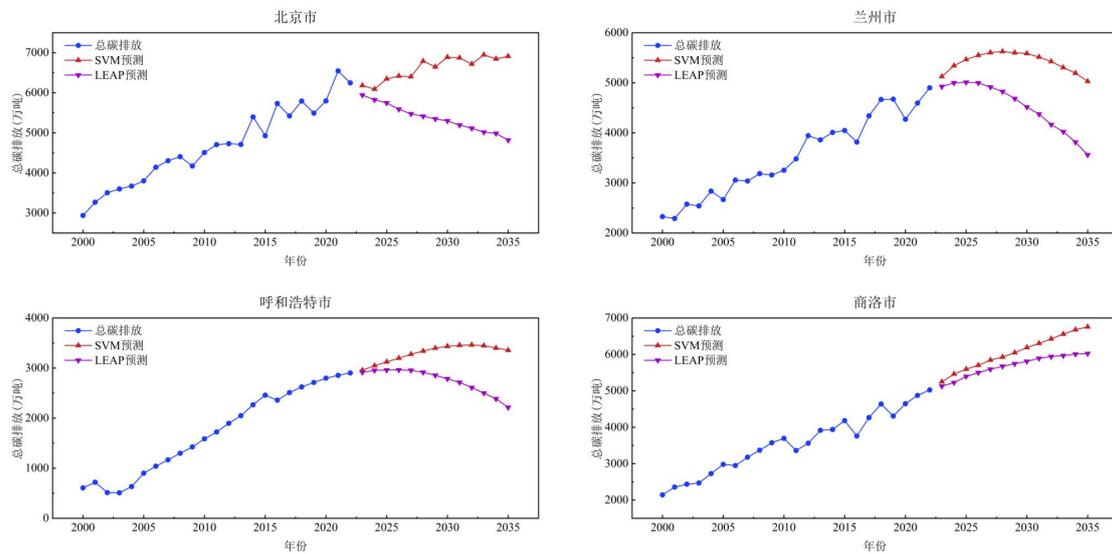


图3 LEAP 预测结果图

LEAP 模型情景模拟结果表明, 如果引入政策因素的影响, 北京市预计在 2024 年即可实现碳达峰, 与北京市公布的《北京市碳达峰实施方案》接近, 在 2024 年实现碳达峰后, 碳排放量稳步降低, 且随时间增加, 降低速率逐步加快。兰州市基准情景下 2028 年可实现碳达峰的目标, LEAP 情景模拟下预计将在 2025 年实现碳达峰。呼和浩特市基准情景下 2032 年才能实现碳达峰, 引入政策因素后, 在 2027 年即可实现碳达峰的目标。商洛市基准情景下碳排放直至 2035 年仍在上升, 如果实行智慧城市试点政策, 引入政策影响因素, 可以大大减慢碳排放上升速度, 有望在 2035 年前实现碳达峰。以上结果表明, 采用智慧城市试点政策的城市每年可实现大约 2%-5% 的减排增速, 智慧城市试点政策及相关政策可帮助城市更快实现碳达峰和碳中和的目标。

3 结论

本文以全国 293 个地级市 2002 年至 2022 年面板数据为基础, 探索性地将机器学习与 LEAP 模型结合, 研究智慧城市试点政策对城市的碳排放效应, 评估指标和预测结果都表明了模型的稳定性和优越性, 同时预测结果也表明智慧城市试点政策对城市双碳减排具有促进作用, 但仍然存在较大优化空间。结果强调了智慧城市在碳减排中的重要作用, 推动智慧城市建设能为城市节能减排提供一条新的路径。

[参考文献]

- [1] 庄贵阳. 我国实现“双碳”目标面临的挑战及对策[J]. 人民论坛, 2021, (18): 50-53.
- [2] 欧阳志远, 史作廷, 石敏俊, 等. “碳达峰碳中和”: 挑战与对策[J]. 河北经贸大学学报, 2021, 42 (05): 1-11.
- [3] 李智超. 政策试点推广的多重逻辑——基于我国智慧

城市试点的分析[J]. 公共管理学报, 2019, 16 (03): 145-156+175.

[4] 刘成杰, 胡钰苓, 李虹桥, 等. 中国智慧城市试点政策对城市发展质量的影响——基于韧性发展的视角[J]. 城市问题, 2021, (11): 79-89.

[5] 孙瑞英. 从定性、定量到内容分析法——图书、情报领域研究方法探讨[J]. 现代情报, 2005, (01): 2-6.

[6] 刘甲炎, 范子英. 中国房产税试点的效果评估: 基于合成控制法的研究[J]. 世界经济, 2013, 36 (11): 117-135.

[7] 白立敏, 修春亮, 冯兴华, 等. 中国城市韧性综合评估及其时空分异特征[J]. 世界地理研究, 2019, 28 (06): 77-87.

[8] 李欣睿. 智慧城市建设对碳排放的影响及作用机制[J]. 中国市场, 2024, (17): 5-8.

[9] 刘潇. 智慧城市试点政策的碳减排效应研究[D]. 浙江大学, 2023.

[10] 尹碧波, 邝萍. 智慧城市的碳减排效应研究: 基于双重机器学习的因果推断[J]. 统计与信息论坛, 2025, 40 (03): 73-86.

[11] 栾尊其. 智慧城市建设对碳排放的影响[D]. 济南大学, 2024.

基金项目: 基于 BIM+智能建造技术的工程应用研究——以宜宾市起步广场项目为例 (2024YB010)

第一作者简介: 曹雄智 (1996 年—), 男 (汉族), 助教, 硕士, 研究方向: 智能建造, 工程管理;

通信作者简介: 张宇杰 (1996 年—), 男 (汉族), 助教, 硕士, 研究方向: 人工智能, 邮箱: 936324168@qq.com.