

# 基于LUR-XGBoost模型的杭州土地利用景观格局对PM<sub>2.5</sub>的影响及时空模拟

## Impact of Land Use Landscape Pattern on PM<sub>2.5</sub> and Spatio-Temporal Simulation Based on LUR-XGBoost Model in Hangzhou

侯玉婷<sup>1</sup> 柴瑜逸<sup>1</sup> 王灵玲<sup>2</sup> 章银柯<sup>3</sup> 邵竟男<sup>1</sup> 邵 锋<sup>1\*</sup>  
HOU Yuting<sup>1</sup> CHAI Yuyi<sup>1</sup> WANG Lingling<sup>2</sup> ZHANG Yinke<sup>3</sup> SHAO Jingnan<sup>1</sup> SHAO Feng<sup>1\*</sup>

(1.浙江农林大学风景园林与建筑学院, 杭州 311300; 2.杭州市富阳区林业水利局, 杭州 311400; 3.杭州植物园, 杭州 310013)

(1. College of Landscape Architecture, Zhejiang A&F University, Hangzhou, Zhejiang, China, 311300; 2. Bureau of Forestry & Water Resoure in Hangzhou Fuyang District, Hangzhou, Zhejiang, China, 311400; 3. Hangzhou Botanical Garden, Hangzhou, Zhejiang, China, 310013)

文章编号: 1000-0283(2026)03-0094-11

DOI: 10.12193/j.laing.20250312003

中图分类号: TU986

文献标志码: A

收稿日期: 2025-03-12

修回日期: 2025-09-03

### 摘 要

环境细颗粒物(PM<sub>2.5</sub>)已被列为全球第六大死亡和残疾风险因素。为精准防治PM<sub>2.5</sub>污染,需要以足够的分辨率捕捉PM<sub>2.5</sub>时空变化,开发基于有限数量监测站点的建模模拟方法。以2014—2023年杭州核心区7个国控站点监测的PM<sub>2.5</sub>浓度为响应变量,城市土地利用景观格局为解释变量,结合土地利用回归(Land Use Regression, LUR)模型、极限梯度提升(XGBoost)算法和斯皮尔曼相关性分析构建模型,采用数据分割、10倍交叉验证和外部数据验证法检验性能,探讨解释变量对PM<sub>2.5</sub>的影响机制,分析PM<sub>2.5</sub>污染的时空变异性。结果表明,混合模型表现性能更优, $R^2$ 和调整 $R^2$ 都在0.90以上,交叉验证的MSE值、RMSE值和MAE值分别为1.32  $\mu\text{g}/\text{m}^3$ 、1.15  $\mu\text{g}/\text{m}^3$ 和1.08  $\mu\text{g}/\text{m}^3$ 。500 m缓冲区内林地斑块形状复杂度和1 000 m不透水面平均斑块面积与PM<sub>2.5</sub>显著相关;林地、耕地和不透水面用地对PM<sub>2.5</sub>的预测能力分别为44%、33%和23%;年均浓度整体呈波动下降趋势和西北高、西南低、由南向北递增的空间分布格局;体现了“冬高夏低”的“U”形季节变化特征,低值区位于西湖区、拱墅区局地,高值区位于拱墅区、滨江区境内。

### 关键词

PM<sub>2.5</sub>; 土地利用景观格局; LUR-XGBoost模型; 时空模拟; 杭州

### Abstract

Ambient fine particulate matter (PM<sub>2.5</sub>) has been ranked as the sixth most important risk factor for death and disability globally. To accurately prevent and control PM<sub>2.5</sub> pollution, high-resolution spatiotemporal characterization of PM<sub>2.5</sub> variations is imperative, prompting the development of modeling approaches based on limited monitoring stations. This study used PM<sub>2.5</sub> concentration (2014—2023) from seven state—controlled stations in Hangzhou's core area as the response variable, with urban land—use landscape patterns as explanatory variables. A Land Use Regression (LUR) model, the Extreme Gradient Boosting (XGBoost) algorithm, and Spearman correlation analysis were employed to develop the model, while data splitting, 10-fold cross-validation, and external data validation were used to evaluate its stability. This framework was designed to investigate the mechanistic impacts of explanatory variables on PM<sub>2.5</sub> and analyze the spatiotemporal heterogeneity of PM<sub>2.5</sub> pollution. The validation results showed that the hybrid model performed well, with  $R^2$  and adjusted  $R^2$  above 0.90; the cross-validated MSE, RMSE, and MAE were 1.32  $\mu\text{g}/\text{m}^3$ , 1.15  $\mu\text{g}/\text{m}^3$ , and 1.08  $\mu\text{g}/\text{m}^3$ , respectively. The shape complexity of the forests patches within 500 m buffer and the 1000 m impervious surface average patch area are significantly correlated with PM<sub>2.5</sub>; predictive capacity rankings were: woodland (44%) > cropland (33%) > impervious surfaces (23%); the annual average concentration showed an overall fluctuating downward trend as well as a spatial distribution pattern of high in the northwest, low in the southwest, and increasing from the south to the north; reflecting the “U”—shaped seasonal change characteristic of “high in winter and low in summer”, the low value area was located in localized areas of Xihu and Gongshu districts, and the high value area was located in localized areas of Gongshu and Binjiang districts.

### Keywords

PM<sub>2.5</sub>; land use landscape pattern; LUR-XGBoost model; spatial-temporal simulation; Hangzhou

侯玉婷

2000年生/女/安徽芜湖人/在读硕士研究生/  
研究方向为风景园林规划与设计

柴瑜逸

2004年生/女/浙江衢州人/研究方向为园林  
植物应用

邵 锋

1979年生/男/江苏盐城人/博士/教授、博士  
生导师/研究方向为风景园林规划与设计

### 基金项目:

国家级大学生创新创业训练计划项目“基于机器学习的杭州主城区绿地景观格局对PM<sub>2.5</sub>浓度影响研究”(编号: 202410341052); 国家重点研发计划课题“城市社区水热过程调控与三维景观优化配置技术”(编号: 2022YFF1303102)

\*通信作者 (Author for correspondence)

E-mail: shaofeng@zafu.edu.cn

中国自改革开放以来,城市化率从1978年的18%增加到2009年的47%,预计在2030年达到70%,中国城市人口总数将超过10亿<sup>[1-2]</sup>。高度城市化极大地改变了地球的陆地表面,大面积的道路、建筑物和其他人工景观取代了原有的自然景观,导致空气质量衰退以及严重的城市居民健康风险。细颗粒物(PM<sub>2.5</sub>,即空气动力学直径 $\leq 2.5 \mu\text{m}$ 的颗粒物)和臭氧是目前制约国内环境空气质量改善的主要大气污染物,不仅影响大气能见度和气候变化,也对人体呼吸系统、神经系统等造成危害<sup>[3]</sup>。《空气质量持续改善行动计划》指出,2025年全国地级及以上城市PM<sub>2.5</sub>浓度要比2020年下降10%,对新时期城市PM<sub>2.5</sub>精细化监测提出了更高要求。由于大气监测站主要分布在农村和郊区等城市以外地区,已建立的观测网无法捕捉到大气层。PM<sub>2.5</sub>化学组成多样,背后涉及多种来源和复杂成因,工业生产、煤炭和扬尘是其主要来源<sup>[4]</sup>。而土地是上述排放源的空间载体,人们逐渐认识到PM<sub>2.5</sub>污染大多是由区域土地利用变化引起的<sup>[5-6]</sup>。快速城市化地区的人为活动与生态环境交互频繁,区域土地利用覆被相应发生着剧烈变化。研究显示,林地景观斑块较为密集、不连续,耕地斑块破碎化程度较高时会加重PM<sub>2.5</sub>污染;建设用地对PM<sub>2.5</sub>的影响存在环境库兹涅茨曲线现象,即环境污染程度随着经济增长呈现先升后降的变化趋势<sup>[7-8]</sup>。与人们普遍认为的土地类型对PM<sub>2.5</sub>的影响程度可能不同。对高密度城区而言,大规模改动城市土地格局是不切实际的,小幅度优化景观斑块的形状、密度、破碎度等更可行。因此,大量研究基于土地利用与大气的关联,设计复杂模型估算地面PM<sub>2.5</sub>浓度。有关土地空间降解空气污染的模式和具体尺度,还需进一步研究。

国内外大量研究证明土地利用回归(Land Use Regression, LUR)模型是预测污染物(NO<sub>2</sub>、SO<sub>2</sub>、PM<sub>10</sub>、PM<sub>2.5</sub>等)空间分布的有效方法<sup>[9]</sup>。LUR模型利用了目标要素与变量之间的相关关系,通过详细的土地利用分布图得出较为精细的结果<sup>[10-13]</sup>。固定结构的传统统计模型易忽略解释变量之间的相互作用或解释变量与PM<sub>2.5</sub>之间的非线性关系。近年来随机森林、深度神经网络等机器学习凭借其优越的数据挖掘能力和出色的模型性能,越来越多地被用于PM<sub>2.5</sub>预测。谢等<sup>[14]</sup>构建基于地理加权回归梯度与提升决策树(GWR-GBDT)的混合模型,实现PM<sub>2.5</sub>高时空分辨率模拟,有效表征城市微环境污染差异。Wong等<sup>[15]</sup>对比传统LUR模型与结合多种机器学习算法的混合LUR模型,预测中国台湾PM<sub>2.5</sub>浓度变化,发现结合Kriging-LUR和XGBoost的模型更能准确地估计PM<sub>2.5</sub>浓度。有学者利用MODIS AOD产品精确估算地面PM<sub>2.5</sub>,构建RF-XGBoost模型,结果表明其决定系数 $R^2$ 为0.93<sup>[16]</sup>。于梦婷<sup>[17]</sup>基于改进后LUR模型确定对PM<sub>2.5</sub>值影响最大的土地利用/转换类型。本研究结合了LUR识别最具影响力排放因子的优势,及XGBoost估计非线性趋势的可预测性,展开PM<sub>2.5</sub>污染模拟与治理。

杭州是中国东南部交通枢纽、长三角地区中心城市。其PM<sub>2.5</sub>浓度尚未达到发达国家环境空气质量水平,且污染下降趋势减缓,雾霾事件时常发生。既有空气污染研究年限有待延长,PM<sub>2.5</sub>模型精度需要提高。本研究针对杭州市核心区不同类型土地功能混杂、气候适应性不强、影响居民健康等问题,及新一轮国土空间规划目标要求,探究土地利用景观格局与PM<sub>2.5</sub>的耦合关系,以期达到以下研究目标:(1)以PM<sub>2.5</sub>实测数据为响应变量,土地利用景观格局为解释变量,构建

LUR-XGBoost混合模型,检验模型拟合性能;(2)筛选显著影响PM<sub>2.5</sub>的环境变量,根据相关性分析结果科学规划土地利用景观格局;(3)生成杭州地区1 km分辨率的PM<sub>2.5</sub>分布地图,便于重点改造高污染地区土地布局。为未来区域空气污染物预测提供借鉴,助力地方监管机构因地制宜地开发建设。

## 1 研究区概况

杭州(29° 11'—30° 34' N, 118° 20'—120° 37' E)为首批国家历史文化名城、浙江省会,地处长三角南翼。属亚热带季风气候,四季分明,雨量充沛。依据《杭州市国土空间总体规划(2021—2035)》,全市总面积16 850 km<sup>2</sup>,下辖西湖、拱墅、上城、滨江、钱塘、富阳、萧山、余杭、临平和临安10个市辖区,桐庐、淳安两个县和建德一个县级市。2023年末杭州常住人口1 252.2万人,人均公园绿地面积为14.96 m<sup>2</sup>/人,森林覆盖率达67.06%。市区环境空气优良天数为308 d,优良率为84.4%。PM<sub>2.5</sub>年均浓度为30.6  $\mu\text{g}/\text{m}^3$ ,在全省11个设区城市中排名第10<sup>[18]</sup>。杭州市区三面环山,地势自西南向东北倾斜,夏季盛行西南风,冬季盛行西北风,不利于大气污染物向外扩散<sup>[19]</sup>。风景名胜设施用地等特殊用地,距离国家环境空气质量一级标准(年均15  $\mu\text{g}/\text{m}^3$ )差距较大。本研究以最新国土空间规划划定的核心区(西湖区、拱墅区、上城区、滨江区)为研究范围,建有7个空气质量国控站点实时监测污染物。近些年首要空气污染物仍为PM<sub>2.5</sub>,严重影响居民身心健康。核心区作为杭州建设最完善、设施最齐全的高密度城区,人类活动丰富密集,导致PM<sub>2.5</sub>污染源多样;大型水体、山峰等特殊风貌分布在区域内,PM<sub>2.5</sub>空间演变复杂。

## 2 材料和方法

### 2.1 数据来源及预处理

#### 2.1.1 响应变量

PM<sub>2.5</sub>数据源于青悦网站 (<https://data.epmap.org/page/index>) 提供的2014年3月1日—2024年2月29日核心区7个国控站点(表1)小时浓度监测数据,单位为μg/m<sup>3</sup>。为便于书写和保证研究年代的完整性,后文将时间简写为2014—2023年。依据《环境空气质量标准(GB 3095-2012)》,西溪站点(2014—2015年、2018—2019年)、云栖站点(2018—2019年)与和睦小学站点(2014—2015年)数据无效;由于站点建设和仪器维护等原因,消防大队站点缺失2021年以前数据,共保留512 712组有效数据。因研究仅限于核心区范围,城区之间气候环境几乎无差别,为避免出现气象条件对PM<sub>2.5</sub>影响不够显著的分析结果,未将气象纳入考虑范围,以便在假定气象条件相对一致的前提下突出土地利用景观格局对细颗粒物的消解能力<sup>[20]</sup>。

#### 2.1.2 解释变量

使用源自Landsat图像的中国30 m年度土地覆盖数据集(CLCD) (<http://doi.org/10.5281/zenodo.4417809>),获取2014—2023年土地数

据。格式为TIFF栅格文件,地理坐标系统一设为GCS-WGS-1984。核心区可提取出“耕地”“林地”“草地”“水体”“荒地”“不透水面”和“湿地”7种土地覆盖类别。考虑到研究区以不透水面、林地和耕地为优势景观类型,水体不易改动,其余类型占比较少,分析土地类型与PM<sub>2.5</sub>污染的相关性应基于一定的土地规模,故选取不透水面、林地和耕地为目标类型。根据《环境空气质量监测规范》,空气环境质量评价点代表范围为半径0.5~40 km的区域<sup>[21]</sup>。考虑到单个站点代表范围和避免缓冲区重合,以监测站点为圆心建立半径为500 m、1 000 m、1 500 m的缓冲区,分析土地利用景观格局与PM<sub>2.5</sub>浓度的耦合关系(图1)。景观格局指数是量化土地利用景观格局的指标,能够反映景观的组成和配置特征<sup>[22-23]</sup>。基于前人对指数的选取方法,依据能够实际反映景观模式配置、降低指数间冗余度等原则,在Fragstats 4.2中选择类型层级的景观形状指数(Landscape Shape Index, LSI)、最大斑块占比(Larger Patch Index, LPI)、景观分离度(DMISION)、景观层级的平均斑块面积(AREA\_MN)和斑块密度指数(Patch Density, PD)5类指数,采用8邻域规则计算方式(表2),反映研究区整体土地利用景观格局特征。

## 2.2 建模方法

### 2.2.1 LUR模型变量筛选

LUR模型通常包含一个因变量和多个自变量,计算见公式(1)。

$$Y = \partial_0 + \partial_1 X_1 + \partial_2 X_2 + \dots + \partial_n X_n + \varepsilon \quad (1)$$

式中,  $Y$ 为因变量,表示监测点PM<sub>2.5</sub>浓度(μg/m<sup>3</sup>);  $X_1, X_2, \dots, X_n$ 为自变量,代表与PM<sub>2.5</sub>浓度相关的地理变量;  $\partial_0$ 是截距;  $\partial_1, \partial_2, \dots, \partial_n$ 为待定系数;  $\varepsilon$ 为随机误差。

根据初步经验,对自变量影响PM<sub>2.5</sub>的正负性做出先验假设<sup>[24]</sup>。应用斯皮尔曼相关性分析(Spearman - Rank analysis)评估潜在预测变量与PM<sub>2.5</sub>之间的相关性,用 $\rho$ 值表示。 $\rho$ 值在-1~1之间,正值表示正相关,负值表示负相关,0表示不相关。进行逐步变量选择监督程序,只有符合预定义关系标准的变量才会被纳入进一步的模型构建过程。如果变量的 $\rho < 0.1$ ,则选择变量并输入模型;若在模型构建的任何步骤中,变量的 $\rho > 0.1$ ,则删除。为避免同一类别变量之间共线的可能性和保证模型参数的可解释性。应用方差膨胀因子(VIF)测试全部变量的共线性,满足VIF < 5说明变量间不存在多重共线性<sup>[25]</sup>。验证结果出来后,参照前人的构建方法,剔除与PM<sub>2.5</sub>的

表1 杭州核心区国控站点详情  
Tab. 1 Details information of state-controlled monitoring sites in Hangzhou core area

监测站点 Monitoring site	站点代码 Site code	位置 Location	E/°	N/°	土地利用现状一级类 Land use status I	土地利用现状二级类 Land use status II
滨江	1223A	滨江区	120.2072	30.2111	公共管理与公共服务用地	机关团体用地
西溪	1224A	西湖区	120.0633	30.2747	特殊用地	风景名胜设施用地
卧龙桥	1227A	西湖区	120.1269	30.2456	特殊用地	风景名胜设施用地
浙江农大	1228A	上城区	120.1903	30.2692	公共管理与公共服务用地	教育用地
和睦小学	1230A	拱墅区	120.1197	30.3119	公共管理与公共服务用地	教育用地
云栖	1233A	西湖区	120.0883	30.1808	特殊用地	风景名胜设施用地
消防大队	3656A	拱墅区	120.1556	30.2864	住宅用地	城镇住宅用地

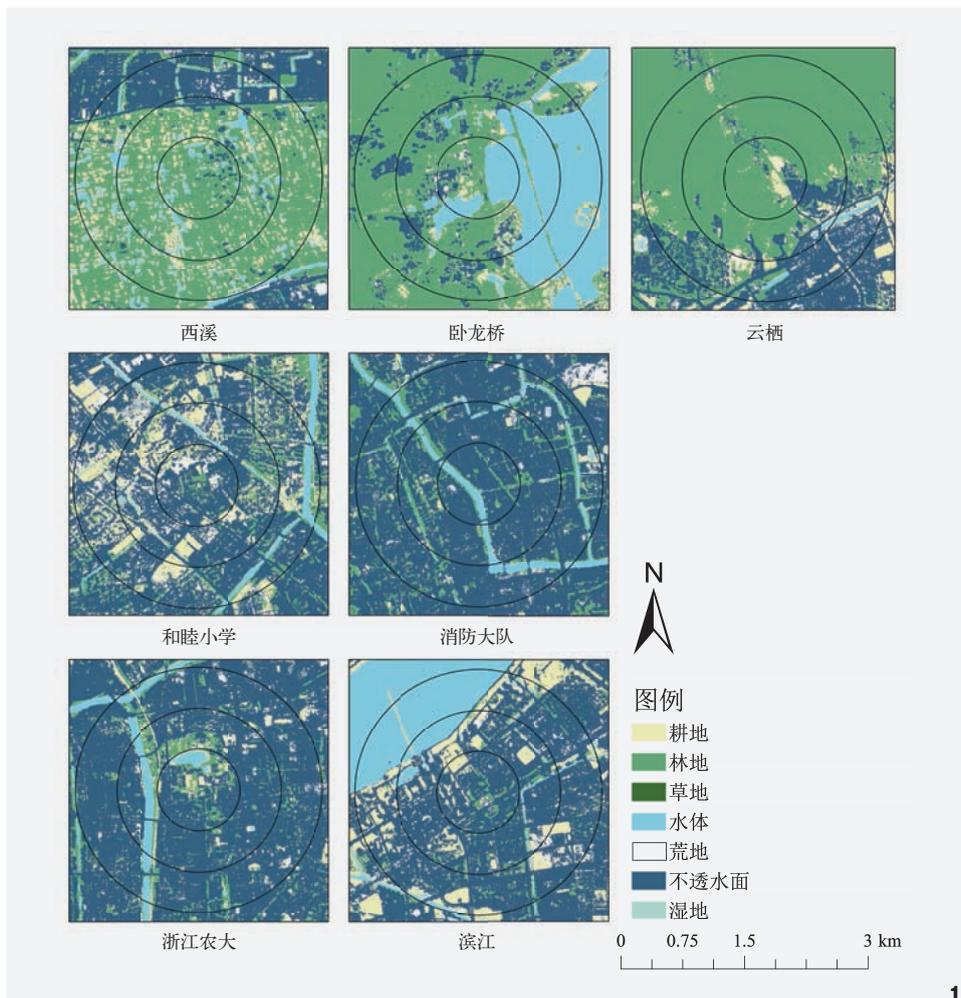


图1 杭州核心区土地类型覆盖图  
Fig. 1 Land cover map of Hangzhou core area

正负相关性同先验假定不一致的变量<sup>[20]</sup>。筛选出每个子类中对PM<sub>2.5</sub>影响力最大的因子(如500 m范围内林地-LSI), 剔除同类因子中与其显著相关( $r > 0.6$ )的子变量(如1 000 m范围内林地-LSI)。符合上述全部验证的预测变量用来建立最终的LUR模型。表3描述了需被检验的自变量样本重要信息, 与因变量均以年度为时间单位进行相关性检验。

### 2.2.2 XGBoost算法的参数设定

极端梯度提升(Extreme Gradient Boosting,

XGBoost)在梯度提升决策树(GBDT)方法的基础上做了改进, 利用多棵决策树构建而成。两种方法都采用梯度下降函数以最小化误差, 且XGBoost利用损失函数的泰勒展开精确评估模型误差, 从而找到最合适的目标函数<sup>[15]</sup>。XGBoost可通过三种方法(正则化目标、收缩和列子采样)有效防止过度拟合, 实现更准确地预测, 优点在于增加了训练过程, 且建模时间更短<sup>[16]</sup>。为获得用于估算地面PM<sub>2.5</sub>浓度的最佳模型, 利用先前筛选到的变量对模型进行初步拟合, 并计算各变量的特征重要

度。构建模型过程中, 参数的选择和优化至关重要<sup>[27]</sup>。本研究对该模型的学习率(eta)取值为0.5, 伽马参数取值为0.2。使用204棵决策树, 树的最大生长深度是2, 表现最佳的是第4次迭代。其他参数采用默认值, 最后选取性能最优的参数进行建模。

### 2.2.3 模型性能评估

由于某些自变量之间可能相关性过高, 为了获得泛化能力更好的模型, 通过比较模型的判定系数( $R^2$ )、均方误差(Mean Squared Error, MSE)、均方根误差(Root Mean Square Error, RMSE)和平均绝对误差(Mean Absolute Error, MAE), 检验模型性能。 $R^2$ 和调整 $R^2$ 用于评估预测能力, 值越接近1, 表示预测值越接近实际测量值。MSE、RMSE和MAE用于确认预测模型的残差, 残差越低, 模型准确率越高。每个评估指标计算见公式(2)~(5)。

$$R^2 = 1 - \frac{S_{\text{res}}}{S_{\text{tot}}} \quad (2)$$

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

$$M_{\text{SE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

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

其中, $R$ 为RMSE值, $M_{\text{SE}}$ 为MSE值, $M_{\text{AE}}$ 为MAE值, $S_{\text{res}}$ 表示回归数据与均值之间的误差, $S_{\text{tot}}$ 表示实际数据与均值之间的误差, $\hat{y}_i$ 表示估计值, $y_i$ 表示真实值, 其中“均值”指的是真实值均值。为进一步验证所建模型的信度和效度, 对模型过拟合问题进行数据拆分、10倍交叉验证和外部数据验证。将2014—2021年原始数据的80%拆分出来用于模型训练, 剩余20%用于模型测试<sup>[28]</sup>。利用XGBoost算法内置函数KFold进行10倍交叉验证, 随机选取90%的数据建立模型, 另10%的数据用于测试, 重复10次, 直至拆分后的每一份数据都

表2 景观格局指数计算方法  
Tab. 2 Calculation methods for landscape pattern index

景观格局指数 Landscape pattern index	计算公式 Formula	描述 Descriptive	生态学意义 Ecological significance	单位 Unit	阈值范围 Threshold range
LSI	$L_{SI} = \frac{0.25 E}{\sqrt{A}}$	$L_{SI}$ 为 LSI 值, 计算整个景观内所有斑块的形状特点	体现景观斑块边缘的复杂程度	—	[1, +∞)
LPI	$L_{PI} = \frac{\max(a_{ij})}{A} \times 100\%$	$L_{PI}$ 为 LPI 值, 计算最大斑块占景观面积的比例	识别某一类型下占优势水平的斑块	%	(0, 100]
DIVISION	$D = \left[ 1 - \sum_{j=1}^N \left( \frac{a_{ij}}{A} \right)^2 \right]$	$D$ 为 DIVISION 值, 计算各个斑块的分离程度	值越大, 表示同一类型景观斑块越分离	—	[0, 1)
AREA_MN	$A_{MN} = \frac{\sum_{j=1}^n a_{ij}}{N}$	$A_{MN}$ 为 AREA_MN 值, 计算单一类型斑块的平均面积	值越小, 表明单一类型景观斑块越破碎	hm <sup>2</sup>	(0, ∞)
PD	$P = \frac{N}{A}$	$P$ 为 PD 值, 计算每公顷范围内的斑块数	表征某种斑块在景观中的密度, 值越大, 斑块密度越高	100/hm <sup>2</sup>	(0, 1]

注: 公式中 $E$ 为总边缘长度(m);  $A$ 为景观总面积(m<sup>2</sup>);  $a_{ij}$ 为第 $i$ 类景观中第 $j$ 个斑块的面积(m<sup>2</sup>);  $N$ 为一种景观类型中斑块的总数,  $N$ 越大景观破碎度越大。

表3 影响PM<sub>2.5</sub>浓度的自变量描述性统计表  
Tab. 3 Descriptive statistics table for independent variables affecting PM<sub>2.5</sub> concentration

PM <sub>2.5</sub> 影响因子 PM <sub>2.5</sub> impact factor	变量名称 Variable name	缓冲区/m Buffer	时间分辨率 Time resolution	空间分辨率/m Spatial resolution
土地利用景观格局指数	不透水面-LSI	500; 1 000; 1 500	2014—2023 年	30
	不透水面-LPI			
	不透水面-DIVISION			
	不透水面-AREA_MN			
	不透水面-PD			
	林地-LSI			
	林地-LPI			
	林地-DIVISION			
	林地-AREA_MN			
	林地-PD			
	耕地-LSI			
	耕地-LPI			
	耕地-DIVISION			
	耕地-AREA_MN			
耕地-PD				

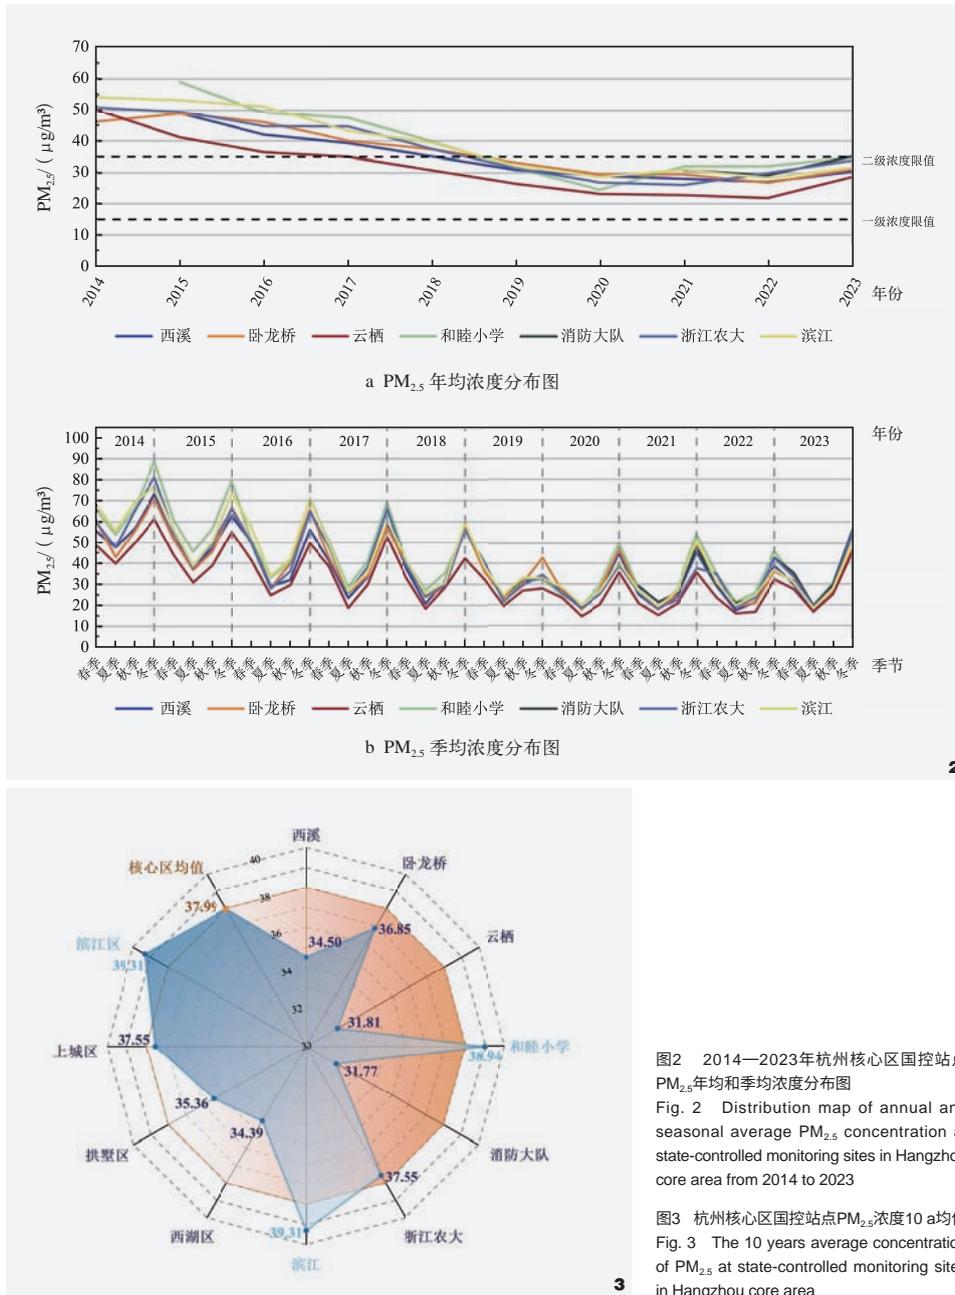
经过测试<sup>[29]</sup>。未用于模型开发的2022—2023年作为独立验证数据集, 以确保测试无偏差。

### 2.3 PM<sub>2.5</sub> 浓度变化模拟图绘制

使用性能最佳的机器学习模型绘制PM<sub>2.5</sub>

浓度梯度图。采用Arcgis10.8对杭州核心区进行1 km×1 km网格化处理, 生成690个预测点, 并使用训练好的PM<sub>2.5</sub>-LUR-XGBoost模型进行回归映射。在网格质心处提取与该位置相关的独立变量, 代入预测模型, 得到该区域PM<sub>2.5</sub>

浓度<sup>[12]</sup>。采用可视化功能克里金(Kriging)空间插值法绘制核心区年均和季均PM<sub>2.5</sub>浓度空间分布模拟图, 高精度展示污染物在时间上和空间上的异质性和聚集性。SPSS 28.0、Origin 2024和R 4.4.1用于数据统计分析和模型构建。



二级标准 (35 μg/m<sup>3</sup>) 7.94%。图2-b显示, 季均浓度在7月达到最低值 13.84 μg/m<sup>3</sup>, 随后波动上升; 1月达到最高值 63.82 μg/m<sup>3</sup>后下降, 随季节更替波动幅度较大。与年变化转好趋势不同, 在大量减排措施下, 冬季浓度仍保持较高水平, 季均值为 53.46 μg/m<sup>3</sup>, 超出年均值 40.72%。各站点每年季均浓度都符合春冬高、夏秋低的“U”形走势。

### 3.1.2 PM<sub>2.5</sub> 浓度空间分析

由图3可知, 各站点浓度在核心区平均水平 1.32% ~ 6.22% 上下浮动, 浓度最高在滨江站, 最低在消防大队站。消防大队站缺失数据可能影响计算结果, 且该站靠近京杭大运河, 大型水体上方湿度较大, 可滞留颗粒物<sup>[31]</sup>; 而滨江站依托高新开发区, 周边工业发展和大气污染企业增长较快。西湖区、拱墅区、上城区和滨江区浓度依次升高。西湖区作为旅游胜地, 实施严格的交通管控措施, 减少机动车使用, 且景区内有大面积天然水域和植被覆盖, 使得污染情况较轻。

### 3.2 LUR-XGBoost 模型性能评价

图4展示了两种模型训练集和测试集的拟合能力差异。在PM<sub>2.5</sub>浓度高和低情景下, 估计值分别容易低于和高于观测值, 表明在极端情况下模拟精度会下降, 可能与极端情况下训练数据集较少, 导致模型学习不足有关, 这与其他学者研究一致<sup>[32]</sup>。在LUR模型测试集中, 与观测值相比, 预测值曲线回归斜率和截距为 5.31 和 -190.49。而LUR-XGBoost模型测试集回归斜率相对较低 (1.18), 截距较大 (-9.07), 其回归曲线更接近于最佳拟合线, 说明泛化能力更强。传统模型训练集和测试集的R<sup>2</sup>值都弱于新模型, MSE值、RMSE值、MAE值都比后者高了数倍, 表

## 3 结果分析

### 3.1 PM<sub>2.5</sub> 浓度描述性统计

#### 3.1.1 PM<sub>2.5</sub> 浓度时间分析

由PM<sub>2.5</sub>小时浓度, 计算日均值、季均值和年均值, 得到年均和季均浓度变化趋势。按春季3—5月、夏季6—8月、秋季9—11月、

冬季12—翌年2月划分四季<sup>[30]</sup>。从图2-a能得出, 2014—2020年间PM<sub>2.5</sub>浓度持续下降, 2021—2023年间浓度反弹。年均浓度由2014年的60.81 μg/m<sup>3</sup>下降到2023年的32.22 μg/m<sup>3</sup>, 年平均递减率为2.86 μg/m<sup>3</sup>。2023年PM<sub>2.5</sub>平均浓度是32.22 μg/m<sup>3</sup>, 低于国家环境空气质量

明后者残差更低，拟合值更贴近真实值。在10倍交叉验证中(表4)，加入XGBoost算法后， $R^2$ 和调整 $R^2$ 分别提高了0.28和0.29，达到0.96、0.97。混合模型调整 $R^2$ 与原始模型差距很小，因此判断不存在过拟合问题。其MSE值、RMSE值和MAE值分别降低了19.47  $\mu\text{g}/\text{m}^3$ 、3.41  $\mu\text{g}/\text{m}^3$ 、2.35  $\mu\text{g}/\text{m}^3$ ，残差数值普遍偏低，充分验证了模型预测能力的进步。在外部数据验证环节(表5)，混合模型的 $R^2$ 和调整 $R^2$ 提高了0.30 ~ 0.34，MSE值、RMSE值和MAE值分别降低26.21 ~ 23.97  $\mu\text{g}/\text{m}^3$ 、2.97 ~ 3.03  $\mu\text{g}/\text{m}^3$ 和0.36 ~ 2.21  $\mu\text{g}/\text{m}^3$ 。树形结构模型比多元线性回归模型产生更好的估计值，各个变量对 $\text{PM}_{2.5}$ 的影响呈现非常复杂的非线性特征。LUR-XGBoost模型对 $\text{PM}_{2.5}$ 的解释能力都达到了90%以上，表现性能稳定，在高精度、高分辨率模拟方面具有突出优势。

### 3.3 $\text{PM}_{2.5}$ 影响因子及尺度效应分析

不同地理区域中驱动 $\text{PM}_{2.5}$ 浓度变化的解释变量具有空间异质性。因此，需通过标准化相关性检验定量评估自变量与 $\text{PM}_{2.5}$ 的统计学关联，提取与其明显相关的变量。目标变量的 $t$ 值、 $p$ 值、 $R^2$ 值和VIF值均列于表6中，所有变量的VIF值均 $<5$ ，认为不存在多重共线性。这些变量为后续可视化分析提供了重要的参考依据。图5是通过检验的变量与 $\text{PM}_{2.5}$ 的Spearman相关系数矩阵图，缓冲区距离大小对相关性有一定程度影响，体现划分不同等级缓冲区的必要性。500 m-林地-LSI和1 000 m-不透水面-AREA\_MN对 $\text{PM}_{2.5}$ 有极强的影响力，相关系数分别为0.92和-0.89。所有变量中，林地类参数占比达50%，且1 000 m尺度变量普遍具有更高的决定系数。在XGBoost模型中得到各变量对 $\text{PM}_{2.5}$ 的贡献能力排名，按照特征分数重新排序，以降序

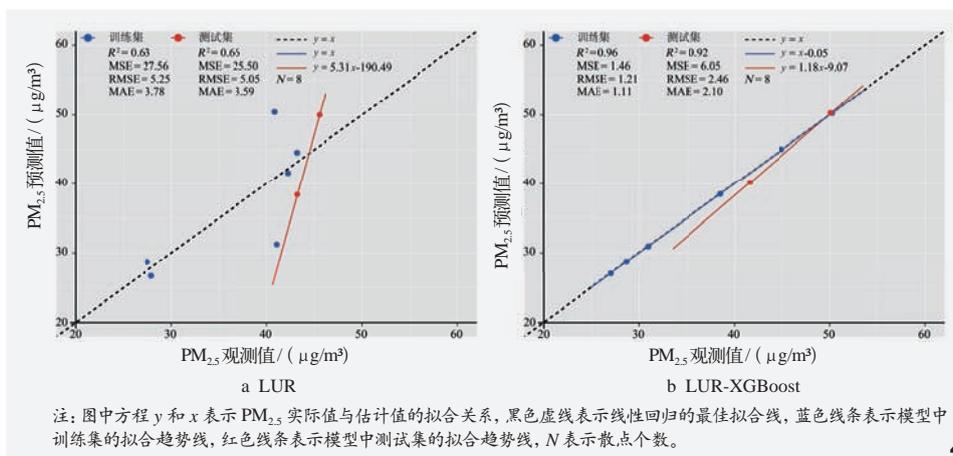


图4 使用LUR和LUR-XGBoost方法得到的 $\text{PM}_{2.5}$ 观测值与预测值的密度散点图

Fig. 4 Density scatter plot of observed versus predicted  $\text{PM}_{2.5}$  values obtained using LUR and LUR-XGBoost methodologies

表4 LUR模型与LUR-XGBoost模型的10倍交叉验证结果

Tab. 4 The results of 10-fold cross validation for both the LUR model and the LUR-XGBoost model

10倍交叉验证 10-fold cross validation	指标 Norm	LUR模型 LUR model	LUR-XGBoost模型 LUR-XGBoost model
2014—2021年	$R^2$	0.68	0.96
	Adjusted $R^2$	0.68	0.97
	MSE	20.79	1.32
	RMSE	4.56	1.15
	MAE	3.43	1.08

表5 LUR模型与LUR-XGBoost模型的外部数据验证结果

Tab. 5 External data validation results of the LUR model and the LUR-XGBoost model

外部数据验证 External data validation	指标 Norm	LUR模型 LUR model	LUR-XGBoost模型 LUR-XGBoost model
2022年	$R^2$	0.61	0.91
	调整 $R^2$	0.61	0.91
	MSE	30.47	6.50
	RMSE	5.52	2.55
	MAE	3.89	1.68
2023年	$R^2$	0.59	0.93
	调整 $R^2$	0.59	0.93
	MSE	34.11	7.90
	RMSE	5.84	2.81
	MAE	4.12	3.76

呈现(图6)。所有变量都是显著的，因其都具有可接受的相对重要性( $>3\%$ )。500 m-耕地-LPI和500 m-林地-LPI在重要性排名

中处于高位，分别具有29%和17%的预测能力。林地、耕地和不透水面的预测能力分别为44%、33%和23%，林地在缓解空气污染方

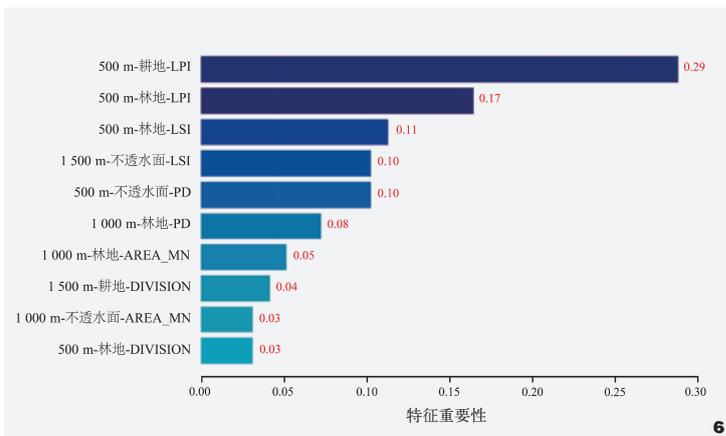
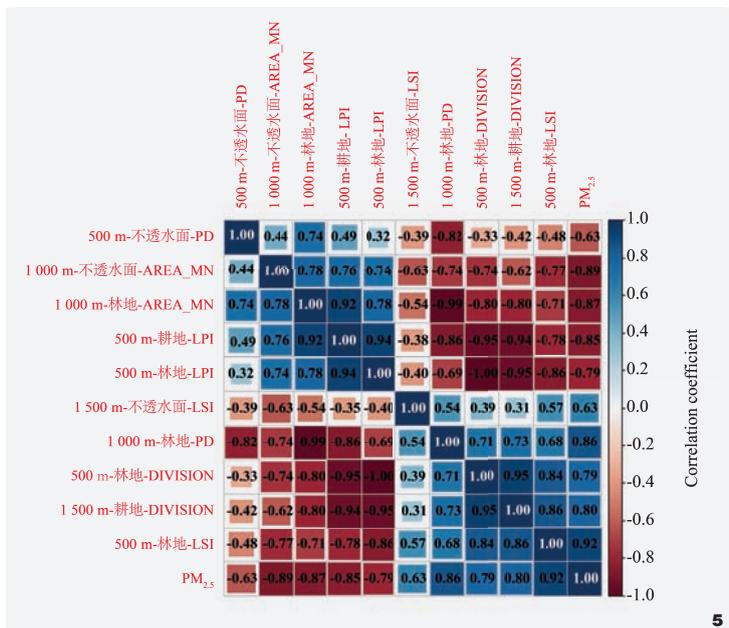


图5 目标变量与PM<sub>2.5</sub>浓度的相关系数矩阵图

Fig. 5 Correlation coefficient matrix plot between the target variable and PM<sub>2.5</sub> concentration

图6 XGBoost模型中不同特征的重要性排名

Fig. 6 Importance ranking of different features in XGBoost models

面拥有更突出的能力。与该类型景观的地理位置、卫星图像成像时间和季节有直接关系。

### 3.4 PM<sub>2.5</sub>污染时空分布特征提取

图7显示了最佳模型得到的PM<sub>2.5</sub>年均浓度分布图，空间分辨率为1 km×1 km。从宏观时间尺度上来看，预测PM<sub>2.5</sub>总体浓度年平均值为42.03 μg/m<sup>3</sup>，高于观测值(37.99 μg/m<sup>3</sup>)。

因估计值是针对整个核心区计算的，观测值仅代表监测点附近有限范围。PM<sub>2.5</sub>模拟年均值同观测值一样，先降后升。新冠疫情防控期间(2019—2020年)的浓度较上一年分别改善了20%和12%，主要源于人为活动减少。近三年，杭州大部分地区全年PM<sub>2.5</sub>浓度低于国家二级标准(35 μg/m<sup>3</sup>)。整体呈明显的西北高、西南低、由南向北递增的趋势。结合

新推出的《杭州市大城北地区规划建设三年行动计划(2024—2026年)》分析，未来三年大城北地区是城市有机更新的主战场，可能成为PM<sub>2.5</sub>污染高热点区域。低值区主要分布在城市周边植被与水体较多的区域，如西湖风景名胜区和灵山景区附近。

计算研究区四季的10 a累计均值，有利于从宏观角度评估PM<sub>2.5</sub>浓度季节差异，建立长效应对机制(图8)。总体而言，最高值出现在冬季，夏季最低。冬季浓度最高时达到66.7 μg/m<sup>3</sup>，夏季低至15.5 μg/m<sup>3</sup>。季节变化较为明显，即“冬季>春季>秋季>夏季”。冬季供热采暖集中、降水少、空气流动性差，容易出现污染物堆积现象；夏季植物生长旺盛，叶面积总量处于全年最高期，植被消减颗粒物能力强。低浓度区始终位于西湖区西南部和拱墅区东南部，西湖风景名胜区和午潮山国家森林公园的高森林覆盖率、京杭大运河和上塘河的水体沉降作用都可能对其产生影响。拱墅区西部和滨江区中北部是高污

表6 目标变量筛选结果  
Tab. 6 The screening results of the target variables

变量名称 Variable name	t 值 t value	p 值 p value	R <sup>2</sup> 值 R <sup>2</sup> value	VIF 值 VIF value
500 m-不透水面-PD	-1.97	0.0961	0.39	1.65
500 m-林地-LPI	-3.17	0.0194	0.63	2.67
500 m-林地-LSI	5.76	0.0012	0.85	4.53
500 m-林地-DIVISION	3.13	0.0204	0.62	2.63
500 m-耕地-LPI	-3.88	0.0081	0.72	3.51
1 000 m-不透水面-AREA_MN	-4.71	0.0033	0.79	4.70
1 000 m-林地-PD	4.16	0.0059	0.74	3.89
1 000 m-林地-AREA_MN	-4.31	0.0050	0.76	4.10
1 500 m-不透水面-LSI	1.97	0.0967	0.39	1.65
1 500 m-耕地-DIVISION	3.28	0.0169	0.64	2.79

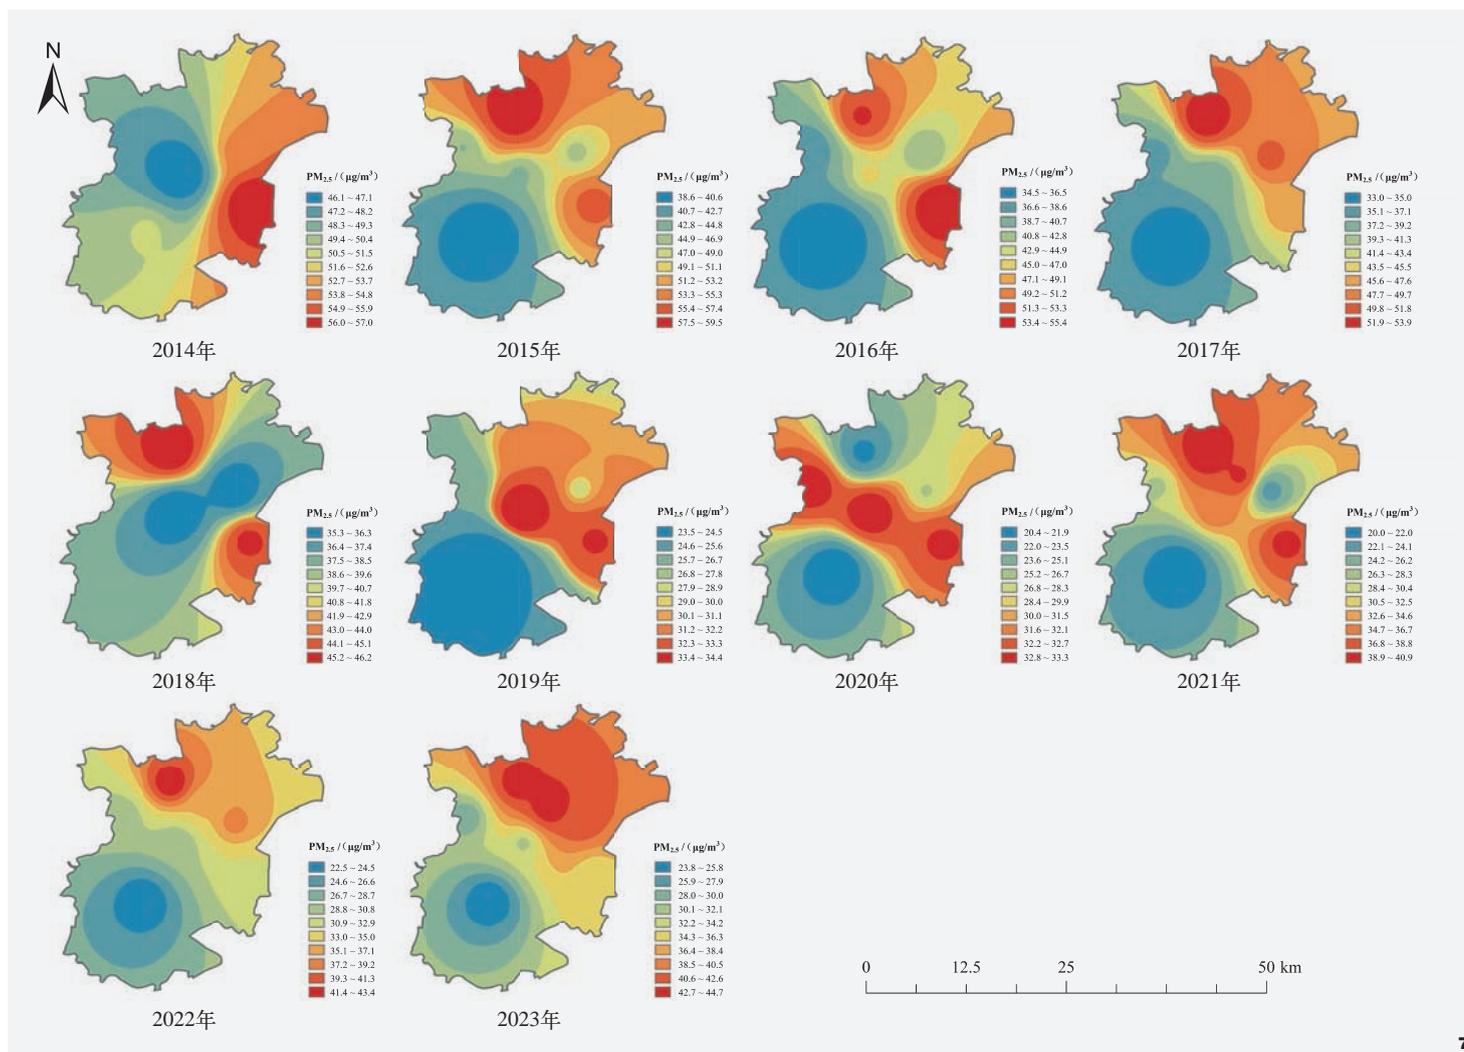


图7 2014—2023年杭州核心区年均PM<sub>2.5</sub>浓度分布模拟图  
Fig. 7 Simulation distribution map of annual average PM<sub>2.5</sub> concentration in Hangzhou core area from 2014 to 2023

染地带，可能是周围居民区和企业分布较多。

#### 4 讨论

模拟结果显示，机器学习模型各方面性能都要优于传统模型。杭州PM<sub>2.5</sub>-LUR-XGBoost模型交叉验证调整R<sup>2</sup> (0.97) 高于上海<sup>[33]</sup>和北京<sup>[34]</sup>LUR模型的0.877和0.81，被认为处于较高水平。与Wang等<sup>[35]</sup>关于机器学习提升LUR模型精度的研究结论吻合，但这是基于微观区域尺度而言，宏观尺度下的影响

机理研究还不够，研究还存在局限。相关性分析结果印证了土地利用变化对PM<sub>2.5</sub>作用机制十分复杂。不透水面平均斑块面积和林地景观形状指数与PM<sub>2.5</sub>关联性最强，因为面积较大的不透水面周边可能伴随绿地环绕，形成“污染隔离带”；林地边缘不规则不利于形成连续通风廊道，与李琳等<sup>[36]</sup>研究结果一致。PM<sub>2.5</sub>污染存在明显的时空分异特征，与刘冲、肖华斌、杨晓辉等<sup>[37-39]</sup>研究结论相近。不同监测点间浓度有差异，与站点所在区域

的工业活动、生产模式和城市下垫面等因素有关。由于数据来源限制，研究仅聚焦于土地格局对PM<sub>2.5</sub>浓度的作用，但实际上PM<sub>2.5</sub>受多方面影响，可能造成研究结果的片面性。本研究重点考虑核心区优势景观的类型水平和景观水平指数，补充了高密度城区缓解PM<sub>2.5</sub>污染的精细化土地规划策略：

(1) 不透水面梯度调控。增加国控站点500 m范围斑块密度和1 000 m平均斑块面积，降低1 500 m景观形状指数。在工业区和居住区

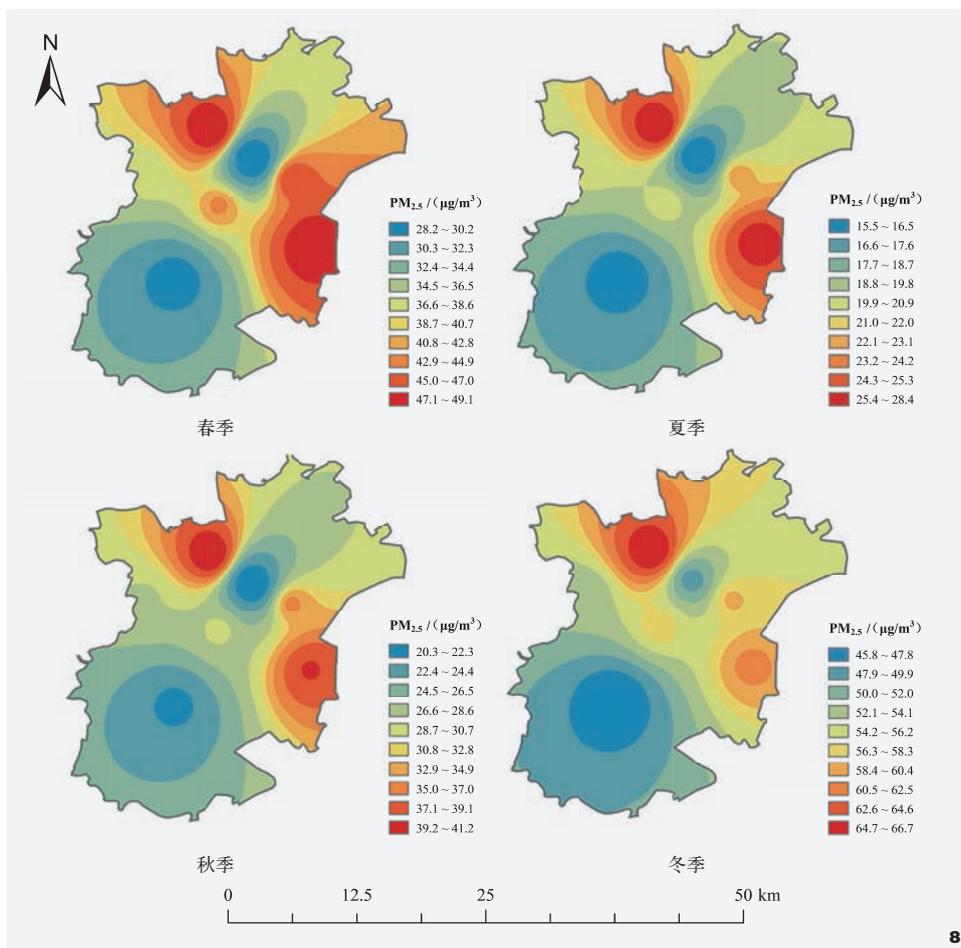


图8 2014—2023年杭州核心区累计季均PM<sub>2.5</sub>浓度分布模拟图  
Fig. 8 Simulation of cumulative quarterly average PM<sub>2.5</sub> concentration distribution in Hangzhou core area from 2014 to 2023

过渡带、非机动车道和城市交通干道之间搭建绿色屏障，如立体绿化墙、透水材料隔离带等，分割连片的不透水面。整合分散的休憩广场、服务设施，形成连续服务节点带，减少孤岛式开发。调整景观空间结构复杂性，让斑块边界贴近方形或圆形等规则形状。

(2) 林地形态连通整合。提升站点附近500 m最大斑块占比和1 000 m平均斑块面积，降低500 m景观分离度、景观形状指数和1 000 m斑块密度。结合城市更新契机，实施生态网络微改造，加强林地景观连接度。在城市建成区采取见缝插绿的措施，发挥绿

地集群效应。增强灰绿空间能量、物质交换过程，持续减缓PM<sub>2.5</sub>扩散。规划和睦小学林地景观时，可通过人工干预将自然边缘复杂的林地调整为规则几何形状。

(3) 耕地规模化聚集管理。扩大站点周边500 m最大斑块占比，缩小1 500 m景观分离度。集中规划现有耕地，推进土地休养生息、退耕还林还草。沿河种植兼具生态功能与观赏价值的耐湿或水生作物，辅以油菜花、向日葵等季节性经济作物，形成层次丰富的水岸农业景观。消防大队和浙江农大站点附近耕地呈点状、分散状分布，建议

集中规划，让小斑块、独立斑块聚拢成大斑块，既能提高最大斑块占比，也可降低景观分离度。

## 5 结论与展望

研究重点探讨了在改善大气环境的前提下，如何优化杭州不同类型土地景观空间布局。主要研究结果如下：(1) LUR-XGBoost模型表现性能显著优于传统模型。LUR-XGBoost模型回归曲线更贴近最佳拟合线，残差值较低，对PM<sub>2.5</sub>的解释能力都达到了90%以上，表现性能稳定。(2) 土地利用景观格局空间组合与PM<sub>2.5</sub>浓度有显著相关性。为有效减轻PM<sub>2.5</sub>浓度，应降低站点500 m范围林地景观形状复杂度，增加1 000 m不透水面平均斑块面积；林地、耕地和不透水面面对PM<sub>2.5</sub>的预防能力逐渐降低，在城市规划中应重点关注林地布局。(3) PM<sub>2.5</sub>模拟浓度呈现高分辨率的时空分布异质性。年均浓度总体上与实测值一致呈波动下降趋势，以及西北高、西南低、由南向北递增的格局；季节变化为冬高夏低、春秋两季居中，低值区普遍分布在西湖区和拱墅区局地，高值区集中在拱墅区和滨江区境内。

研究模型在城市空气污染物模拟实践中有着良好的应用前景，为长三角地区PM<sub>2.5</sub>分布高分辨率预测提供借鉴。未来可从以下角度继续丰富城市空气污染研究：将研究区域扩大至中国其他地区同类型城市，测试LUR-XGBoost模型在复杂地理条件下的适应能力；纳入气候、社会经济和政策等多元影响因素，构建多维数据库，提高大气环境质量；结合实地调研，找到景观空间中消解污染物能力的不足之处，结合城市更新和绿化管理背景，提出更科学的景观格局调整模式。

注：文中图表均由作者绘制。

## 参考文献

- [1] ZHU Y G, IOANNIDIS J P A, LI H, et al. Understanding and Harnessing the Health Effects of Rapid Urbanization in China[J]. *Environmental Science & Technology*, 2011, 45(12): 5099-5104.
- [2] 中华人民共和国中央人民政府. 联合国报告预测2030年中国城镇化水平将达70%[EB/OL]. (2013-8-28)[2025-4-12]. [https://www.gov.cn/jrzq/2013-08/28/content\\_2475379.htm](https://www.gov.cn/jrzq/2013-08/28/content_2475379.htm).
- [3] LIN Z Y, FAN X L, CHEN G J, et al. Sources Appointment and Health Risks of PM<sub>2.5</sub>-bound Trace Elements in a Coastal City of Southeastern China[J]. *Journal of Environmental Sciences*, 2024, 138: 561-571.
- [4] 王占永, 蔡铭, 彭仲仁, 等. 基于移动观测的路边PM<sub>2.5</sub>和CO浓度的时空分布[J]. *中国环境科学*, 2017, 37(12): 4428-4434.
- [5] ANG-OLSON J, FISCHER M, DULLA R. Land Use as an Air Quality Control Measure: Review of Current Practice and Examination of Policy Options[J]. *Transportation Research Record: Journal of the Transportation Research Board*, 2000, 1738(1): 33-38.
- [6] MCCARTY J, KAZA N. Urban Form and Air Quality in the United States[J]. *Landscape and Urban Planning*, 2015, 139: 168-179.
- [7] XU W Y, JIN X B, LIU M M, et al. Analysis of Spatiotemporal Variation of PM<sub>2.5</sub> and Its Relationship to Land Use in China[J]. *Atmospheric Pollution Research*, 2021, 12(9): 101151.
- [8] GROSSMAN G M, KRUEGER A B. Environmental Impacts of a North American Free Trade Agreement [J]. *CEPR Discussion Papers*, 1992, 8(2): 223-250.
- [9] JERRETT M, ARAIN A, KANAROGLOU P, et al. A Review and Evaluation of Intraurban Air Pollution Exposure Models[J]. *Journal of Exposure Science & Environmental Epidemiology*, 2005, 15(2): 185-204.
- [10] HOEK G, BEELEN R, DE HOOGH K, et al. A Review of Land-use Regression Models to Assess Spatial Variation of Outdoor Air Pollution[J]. *Atmospheric Environment*, 2008, 42(33): 7561-7578.
- [11] HAN L, ZHAO J Y, GAO Y J, et al. Spatial Distribution Characteristics of PM<sub>2.5</sub> and PM<sub>10</sub> in Xi'an City Predicted by Land Use Regression Models[J]. *Sustainable Cities and Society*, 2020, 61: 102329.
- [12] SHI T, HU Y M, LIU M, et al. Land Use Regression Modelling of PM<sub>2.5</sub> Spatial Variations in Different Seasons in Urban Areas[J]. *Science of the Total Environment*, 2020, 743: 140744.
- [13] SHI S, WANG W D, LI X Y, et al. Optimizing Modeling Windows to Better Capture the Long-term Variation of PM<sub>2.5</sub> Concentrations in China During 2005-2019[J]. *Science of the Total Environment*, 2023, 854: 158624.
- [14] 谢晓苇, 李代超, 卢嘉奇, 等. 基于移动监测数据的不同城市场景下PM<sub>2.5</sub>浓度精细模拟与时空特征解析[J]. *地球信息科学学报*, 2022, 24(8): 1459-1474.
- [15] WONG P Y, LEE H Y, CHEN Y C, et al. Using a Land Use Regression Model with Machine Learning to Estimate Ground Level PM<sub>2.5</sub>[J]. *Environmental Pollution*, 2021, 277: 116846.
- [16] LIN L J, LIANG Y C, LIU L, et al. Estimating PM<sub>2.5</sub> Concentrations Using the Machine Learning RF-XGBoost Model in Guanzhong Urban Agglomeration, China[J]. *Remote Sensing*, 2022, 14(20): 5239.
- [17] 于梦婷. 基于改进LUR模型的PM<sub>2.5</sub>时空分布与土地利用关系的研究[D]. 大连: 大连理工大学, 2022.
- [18] 2023年12月浙江省城市环境空气质量月报. 浙江省生态环境厅[EB/OL]. (2024-01-17)[2025-5-13]. [http://sthjt.zj.gov.cn/art/2024/1/17/art\\_1453975\\_58950359.html](http://sthjt.zj.gov.cn/art/2024/1/17/art_1453975_58950359.html).
- [19] 金均, 吴建, 蔡菊珍, 等. 杭州市灰霾天气基本特征及成因分析[J]. *环境污染与防治*, 2010, 32(5): 61-63.
- [20] 王梦迪, 吉文丽, 李凯媛. 西安市PM<sub>10</sub>、PM<sub>2.5</sub>的时空特征及其与土地利用的关系[J]. *西北林学院学报*, 2021, 36(4): 249-256.
- [21] 国家环境保护总局. 环境空气质量自动监测技术规范: HJ/T 193-2005[S]. 北京: 中国环境科学出版社, 2005.
- [22] 莫素芬, 胡宝清, 赖国华, 等. 广东西江流域景观格局动态变化分析[J]. *广西科学院学报*, 2020, 36(2): 200-206.
- [23] 徐瑶琴. 南昌市景观格局演变及其生态网络构建研究[J]. *环境科学与管理*, 2023, 48(7): 148-153.
- [24] BEELEN R, HOEK G, VIENNEAU D, et al. Development of NO<sub>2</sub> and NO<sub>x</sub> Land Use Regression Models for Estimating Air Pollution Exposure in 36 Study Areas in Europe – the ESCAPE Project[J]. *Atmospheric Environment*, 2013, 72: 10-23.
- [25] ZHANG J J Y, SUN L, RAINHAM D, et al. Predicting Intraurban Airborne PM<sub>10</sub>-trace Elements in a Port City: Land Use Regression by Ordinary Least Squares and a Machine Learning Algorithm[J]. *Science of the Total Environment*, 2022, 806: 150149.
- [26] 赵雪, 侯丽丽, 王鑫龙, 等. 基于LUR模型的2019年北京地区PM<sub>2.5</sub>与PM<sub>10</sub>浓度空间分异模拟[J]. *环境科学学报*, 2020, 40(11): 4060-4069.
- [27] 谭洁, 危千骏, 廖朝阳, 等. 基于XGBoost-SHAP可解释机器学习模型的城市形态与地表温度的关系[J]. *应用生态学报*, 2025, 36(3): 659-670.
- [28] 刘倩, 王兆茹, 胥寒莉, 等. 基于粒子群优化XGBoost模型的PM<sub>2.5</sub>质量浓度反演[J]. *环境科学*, 2025, 46(8): 5023-5034.
- [29] FAN Y, SUN N N, LV S C, et al. Prediction of Developmental Toxic Effects of Fine Particulate Matter (PM<sub>2.5</sub>) Water-soluble Components via Machine Learning Through Observation of PM<sub>2.5</sub> from Diverse Urban Areas[J]. *Science of the Total Environment*, 2024, 946: 174027.
- [30] YANG H O, LENG Q M, XIAO Y F, et al. Investigating the Impact of Urban Landscape Composition and Configuration on PM<sub>2.5</sub> Concentration Under the LCZ Scheme: A Case Study in Nanchang, China[J]. *Sustainable Cities and Society*, 2022, 84: 104006.
- [31] ZHU D, ZHOU X F. Effect of Urban Water Bodies on Distribution Characteristics of Particulate Matters and NO<sub>2</sub>[J]. *Sustainable Cities and Society*, 2019, 50: 101679.
- [32] TIAN H, ZHAO Y Q, LUO M, et al. Estimating PM<sub>2.5</sub> from Multisource Data: A Comparison of Different Machine Learning Models in the Pearl River Delta of China[J]. *Urban Climate*, 2021, 35: 100740.
- [33] LIU C, HENDERSON B H, WANG D F, et al. A Land Use Regression Application into Assessing Spatial Variation of Intra-urban Fine Particulate Matter (PM<sub>2.5</sub>) and Nitrogen Dioxide (NO<sub>2</sub>) Concentrations in City of Shanghai, China[J]. *Science of the Total Environment*, 2016, 565: 607-615.
- [34] JI W, WANG Y, ZHUANG D F. Spatial Distribution Differences in PM<sub>2.5</sub> Concentration Between Heating and Non-heating Seasons in Beijing, China[J]. *Environmental Pollution*, 2019, 248: 574-583.
- [35] WANG A, XU J S, TU R, et al. Potential of Machine Learning for Prediction of Traffic Related Air Pollution[J]. *Transportation Research Part D: Transport and Environment*, 2020, 88: 102599.
- [36] 李琳, 张希光. 高精度综合景观格局的中国人口暴露风险评价[J]. *北京测绘*, 2024, 38(9): 1335-1340.
- [37] 刘冲. 杭州市2015-2019年PM<sub>2.5</sub>时空分布特征研究[D]. 成都: 成都理工大学, 2020.
- [38] 肖华斌, 许宇彤, 王子康, 等. 济南市大气PM<sub>10</sub>、PM<sub>2.5</sub>时空分布特征与城市街区形态关联分析[J]. *园林*, 2024, 41(3): 121-130.
- [39] 杨晓辉, 肖登攀, 栢会子, 等. 2013-2020年京津冀地区PM<sub>2.5</sub>浓度时空变化模拟及趋势分析[J]. *地理与地理信息科学*, 2022, 38(4): 58-67.