

不同网格尺度下珠三角城市群蓝绿灰空间 景观格局对夏季地表温度的影响*

郑楷灿, 廖威林

中山大学地理科学与规划学院, 广东 广州 510006

摘要: 蓝绿灰空间作为城市下垫面的核心构成要素, 其景观格局优化对缓解城市热风险具有重要作用。然而, 当前针对不同网格尺度下城市群蓝绿灰空间景观格局对地表温度的影响研究仍较为缺乏。因此, 本研究选取珠三角城市群作为研究区域, 基于 2022 年的土地覆盖数据和 MODIS 地表温度数据, 结合 XGBoost 模型、SHAP 方法和累积局部效应方法探究不同网格尺度下 (1、2、3 km) 蓝绿灰空间景观格局对夏季日间地表温度的影响。研究发现, 各尺度下灰色空间景观格局均为地表温度变化的首要驱动因素, 而蓝绿空间影响随尺度增大而增强。此外, 各特征的累积局部效应显示, 增加蓝绿空间占比、斑块密度和聚集度, 减少灰色空间占比、斑块密度和聚集度, 并合理调控各类空间的最大斑块规模和形状复杂度可有效降低地表温度, 但均需结合具体空间尺度确定最优景观配置。本研究可为城市景观空间布局优化提供科学依据, 助力城市群的可持续发展。

关键词: 蓝绿灰空间; 景观格局; 地表温度; 珠三角城市群; 网格尺度

中图分类号: K90 **文献标志码:** A **文章编号:** 2097-0137(XXXX)XX-0001-10

Impacts of landscape patterns of blue-green-gray spaces on summer land surface temperature across multiple grid scales in the Pearl River Delta urban agglomeration

Zheng Kaican, Liao Weilin

School of Geography and Planning, Sun Yat-sen University, Guangzhou 510006, China

Abstract: Blue-green-gray spaces are principal components of urban underlying surfaces, and optimizing their landscape patterns can significantly mitigate urban thermal risks. However, studies on the impacts of blue-green-gray space landscape patterns on land surface temperature (LST) across multiple grid scales in urban agglomerations remain limited. Therefore, this study selected the Pearl River Delta urban agglomeration as the study area and used land cover data and MODIS LST data for 2022 to investigate how landscape patterns of blue-green-gray spaces affect summer daytime LST across multiple grid scales (i.e., 1, 2, and 3 km) by combining the XGBoost model, SHAP method, and accumulated local effects (ALE) method. Results show that gray space landscape patterns are the primary drivers of LST variation across all scales, whereas the influence of blue and green spaces increases with grid size. In addition, the ALE results indicate that increasing the proportion, patch density, and aggregation of blue and green spaces, reducing the proportion, patch density and

* 收稿日期: 2026-04-28

录用日期: 2026-07-15

网络首发日期: XXXX-XX-XX

基金项目: 国家自然科学基金 (42271419)

作者简介: 郑楷灿 (2003 年生), 男; 研究方向: 城市气候; E-mail: zhengkc@mail2.sysu.edu.cn

通信作者: 廖威林 (1990 年生), 男; 研究方向: 城市气候、气候变化; E-mail: liaoweilin@mail.sysu.edu.cn

全文阅读



ZR20260113

aggregation of gray spaces, and reasonably regulating the largest patch size and shape complexity of various spaces can effectively reduce LST. However, the optimal landscape configuration must be determined according to specific spatial scales. The findings provide a scientific basis for optimizing urban landscape patterns and support the sustainable development of urban agglomerations.

Key words: blue-green-gray space; landscape pattern; land surface temperature; the Pearl River Delta urban agglomeration; grid scale

快速城市化背景下,城市景观格局发生剧烈重构,对局地热环境造成显著影响(成雅田等, 2020)。蓝绿灰空间是城市景观的主要构成要素,其组分结构与空间格局对城市地表温度的变化具有关键调控作用(Xu et al., 2024; 王佳等, 2025)。具体而言,由河湖、湿地等水体构成的蓝色空间,林地、草地等植被覆盖的绿色空间(Cao et al., 2025),可通过水分蒸发、冠层遮阴、植被蒸散等多种生态过程降低地表温度(王刚等, 2018; Kumar et al., 2024);在蓝绿空间占比提升、热交换面积扩大的情况下,这种降温效应会随之明显增强(He et al., 2024)。然而,由道路、建筑等不透水面组成的灰色空间则具有太阳辐射吸收率高、储热能力强的特点(Lin et al., 2025),其持续扩张会促使城市地表温度进一步升高(Bao et al., 2025)。

相关研究表明,蓝绿灰空间景观格局对地表温度的影响存在明显的尺度效应(He et al., 2023; Qu et al., 2025; 沈中健等, 2025; Wu et al., 2025)。例如,绿色空间斑块密度对地表温度的影响会随着分析尺度的扩大呈增强趋势(沈中健等, 2025);而在较大尺度的统计单元内,灰色空间的面积占比会成为影响地表温度变化的核心驱动因子(Wu et al., 2025)。因此,只有在适宜的空间尺度和指标组合的基础上开展景观格局优化工作,才能充分发挥其对热环境的调控作用(He et al., 2023)。

当前,研究多以单个城市为对象开展空间景观格局分析,典型案例包括对济南(沈中健等, 2025)、武汉(He et al., 2023)等城市的相关研究。但在城市群范围内,对于不同空间尺度下,蓝绿灰空间景观格局对地表温度的影响的认识尚不充分。鉴于此,本研究选取了珠三角城市群为研究区域,计算3类空间在不同网格尺度内的景观指数,构建机器学习模型探究其对夏季日间地表温度的影响特征。

1 研究区域与数据

1.1 研究区域


珠三角城市群地处中国广东省中南部,全域面积约 54 000 km²,包括广州、深圳、珠海、佛山、中山、江门、东莞、惠州与肇庆9座城市(图1),是中国三大城市群之一。改革开放后,该区域城市化建设不断推进,灰色空间的快速扩张取代了大量的蓝绿空间,造成局地热环境发生显著变化(Wang et al., 2025),夏季日间地表温度持续上升(Zhang et al., 2024)。在此背景下,本研究选取珠三角城市群这一典型区域开展研究。

1.2 研究数据

本研究使用了土地覆盖、地表温度和高程3类数据。其中,土地覆盖数据来源于AGLC土地覆盖数据集(许晓聪等, 2021),该数据集将土地覆盖划分为10类,空间分辨率为30 m。本研究采用了2022年的土地覆盖数据,将湿地和水体合并为蓝色空间,林地、草地、灌木和苔原归为绿色空间,不透水面定义为灰色空间,耕地、裸地和永久冰雪纳入其他空间;4类空间在珠三角城市群内的具体分布情况见图1b。

相较于气象站观测获得的近地面2 m气温,地表温度可直接反映下垫面的热力特征,对景观格局变化更为敏感(Wu et al., 2025)。本研究使用的地表温度数据为MYD11A2,其由Aqua卫星搭载的MODIS传感器采集的影像反演得到,日间数据的采集时间约为地方时13:30,空间分辨率为1 km,时间分辨率为8 d。该产品通过多日合成的处理机制,有效削弱了因云覆盖、大气条件变化、传感器观测误差带来的随机波动,被广泛应用于城市热环境研究(Shao et al., 2023; Jiang et al., 2026)。

本研究选取了2022年夏季(6—8月)日间的地表温度数据,根据质量控制波段筛选出温度误差 ≤ 3 K的像元(质量较好),将单位转换为 $^{\circ}\text{C}$,并计算多日均值,以此来探究蓝绿灰空间景观格局对珠三角城市群夏季日间地表温度空间分布特征产生的影



审图号为GS(2024)0650,底图边界无修改。

图1 研究区域与蓝绿灰空间分布情况

Fig. 1 Study area and spatial distribution of blue-green-gray spaces

响。高程数据使用ASTER GDEM V3产品,空间分辨率为30 m。

2 研究方法

已有关于地表温度的研究多选用3 km及以下网格尺度开展分析(He et al., 2023; He et al., 2024)。考虑到本研究用到的MODIS地表温度产品的空间分辨率为1 km,故本研究以1 km作为基准,设置了1 km×1 km、2 km×2 km、3 km×3 km 3种网格尺度。在此基础上,对每种尺度分别构建了线性回归模型,以及随机森林和XGBoost模型这2种机器学习模型,以此探究不同网格尺度下,蓝绿灰空间的景观格局对夏季日间地表温度产生的影响。

模型构建过程中,按照7:1:2的比例将样本划

分为训练集、验证集和测试集,借助均方根误差(RMSE)和决定系数(R^2)进行精度评价。模型的因变量为统计网格内的平均地表温度,自变量共计18项,包括像元中心坐标(x 和 y 坐标),统计网格内的高程均值,以及蓝色、绿色、灰色3类空间各自对应的5种景观指数(表1)。2种机器学习模型运用Optuna框架优化超参数,通过100次试验最小化RMSE。本研究采用SHAP方法和累积局部效应(ALE, accumulated local effects)方法对机器学习模型结果加以解释。

2.1 随机森林模型

随机森林模型由多个决策树模型构成,训练过程中,每个决策树模型只随机抽取部分数据进行学习,且在节点分裂时只随机选择部分特征进行判断

表1 景观指数
Table 1 Landscape indices

景观指数	公式	说明
斑块密度(PD)	$PD = \frac{N}{A}$	N 为斑块数量, A 为景观总面积,用于衡量景观的碎片化程度,较高的斑块密度通常表示景观更加破碎,单位为 km^{-2}
最大斑块占比(LPI)	$LPI = \frac{a_{\max}}{A}$	$a_{\max}$ 为最大斑块面积,用于衡量景观中最大斑块的主导性
景观形状指数(LSI)	$LSI = \frac{0.25E}{\sqrt{A}}$	E 为所有斑块的总边缘长度,用于衡量景观斑块的边界复杂度,高LSI值表示形状更复杂
斑块面积占比(PLAND)	$PLAND = \frac{a}{A}$	a 为斑块总面积,用于衡量特定类别在景观中的相对重要性
聚集度(AI)	$AI = \frac{g}{G}$	g 为同类斑块之间的边界总长度, G 为其在景观内可能的最大边界长度,用于衡量景观斑块的连通性,高AI值表示斑块更聚集

(Wang et al., 2022); 在回归任务中, 随机森林模型的最终预测结果为每个决策树模型预测值的均值。

2.2 XGBoost模型

随机森林模型会并行生成多棵决策树, XGBoost模型的运行方式与随机森林模型存在明显区别。作为梯度提升树模型, 其运行逻辑为通过逐棵迭代构建决策树, 每次新生成的决策树, 都用来弥补前面所有树预测结果中的偏差, 从而一步步降低模型误差(Fu et al., 2025)。和传统的梯度提升树模型相比, XGBoost模型新增了正则化处理步骤, 该步骤可以很好地减少模型出现过拟合。

2.3 SHAP方法

SHAP方法将博弈论中的Shapley值与机器学习相结合, 借助加性模型将预测值分解为基线预测值与每个特征SHAP值的总和。其中基线预测值为所有特征取平均时获得的预测值, 而每个特征的SHAP值依据其在所有特征组合中的边际贡献经加权求和得到, 公式如下:

$\phi_i =$

$$\sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(M - |S| - 1)!}{M!} [f(S \cup \{i\}) - f(S)],$$

其中 ϕ_i 为第 i 个特征的SHAP值, N 为全部特征组合, S 为不包含第 i 个特征的特征组合, $|S|$ 为特征组合中的特征数, M 为全部特征数, $f(S)$ 表示该特征组合的预测值, $f(S \cup \{i\})$ 表示在该特征组合上加入第 i 个特征后的预测值(Shao et al., 2023)。

2.4 ALE方法

ALE方法是另一种解释机器学习模型结果的方法, 可得到单个特征对模型预测的影响。ALE方法将目标特征划分为多个区间, 在每个区间内计算特征值从左边界变化到右边界时对预测值的影响

(即局部效应), 随后将每个区间的局部效应累积, 再进行中心化处理, 即将累积效应曲线减去累积效应的样本加权均值, 得到最终的ALE曲线。

ALE曲线上某点的斜率表示该点处模型预测结果的平均变化率。斜率为正时, 表明该特征在该点处对预测值具有正向影响; 斜率为负时, 表明该特征在该点处对预测值具有负向影响; 斜率绝对值越大, 表明在该点处特征对预测值造成的影响越强。若某一段区间内包含的样本数量偏少, ALE方法得到的结果的不确定性会随之增大。与传统的部分依赖图相比, 本研究使用的ALE方法能有效避免特征之间因多重共线性导致的估计偏差, 该方法得到的解释结果可信度更高(Yang et al., 2024)。

3 结果与分析

3.1 模型精度验证

各网格尺度下不同模型的精度如表2所示, 3种模型对地表温度的预测精度均较高, RMSE均小于 1.6°C , R^2 均大于0.8, 其中XGBoost模型的预测精度最高。图2展示了XGBoost模型在测试集上的预测值与观测值的对比, 结果显示, 在3种网格尺度下, 散点均分布在1:1线附近, 表明模型预测值与观测值具有良好的一致性。因此, 本研究后续将基于XGBoost模型的输出结果进行深入分析。

3.2 特征重要性分析

根据SHAP方法得到的结果, 可分析不同网格尺度下各特征对地表温度变化的相对重要性(图3)。灰色空间的景观特征对地表温度的影响贡献占比最大, 在3种尺度下均超过40%。蓝绿空间景观特征的贡献占比会随着网格尺度的增大而增加, 其中蓝色空间的贡献占比从 $1\text{ km} \times 1\text{ km}$ 尺度下的

表2 不同网格尺度下各类模型的精度

Table 2 Accuracy of different models at different grid scales

模型	精度指标	网格尺度		
		1 km×1 km	2 km×2 km	3 km×3 km
线性回归	RMSE / $^{\circ}\text{C}$	1.597	1.251	1.093
	R^2	0.804	0.871	0.897
随机森林	RMSE / $^{\circ}\text{C}$	1.495	1.215	1.052
	R^2	0.828	0.879	0.905
XGBoost	RMSE / $^{\circ}\text{C}$	1.189	1.025	0.934
	R^2	0.891	0.914	0.925

积占比、最大斑块占比和聚集度的贡献度较高,且随着网格尺度增大而增加,进而使得蓝色空间景观特征贡献占比增加。

3.3 特征ALE分析

为进一步探究各特征对于地表温度的影响规律,本研究结合数据分布情况,对样本量充足的区间内的特征ALE曲线展开分析(图4~6)。整体上看,高程和位置信息对地表温度的影响在不同网格尺度下基本一致,地表温度会随着高程的升高而降低。面积占比与斑块密度这2类指标对地表温度的影响在各尺度下也较为稳定,其中蓝绿空间的这2类指标均与地表温度呈负相关;而灰色空间面积占比和斑块密度的增加,对地表温度有显著的增温效应。

最大斑块占比对地表温度的影响在不同景观类型间差异明显。在蓝色空间中,最大斑块占比提高主要产生降温效应;而在绿色空间中,最大斑块占比在较低阶段起到降温作用,但当占比超过临界阈值,则会出现增温效应。灰色空间中,最大斑块占比对地表温度的影响具有尺度依赖性,在1 km×1 km尺度下呈降温效应,而在另外2个尺度下则呈现“降温-升温-降温”的复杂影响特征。造成上述差异的原因可能在于最大斑块占比是相对指标,在小尺度网格下,高占比对应的灰色空间斑块实际规模可能小于大尺度网格下低占比对应的斑块实际规模。

在形状复杂度方面,蓝色空间形状复杂度的提升在各网格尺度上均产生增温效应。而在1 km×1 km和2 km×2 km尺度下,绿色空间和灰色空间的形状复杂度与地表温度主要呈负相关。在3 km×3 km尺度下,绿灰空间形状复杂度的ALE曲线波动明显,且ALE值极差较小,表明在大尺度网格中,该景观特征对地表温度影响较弱,曲线波动可能由弱影响状态下模型回归的不确定性所致(Apley et al., 2020)。

聚集度指标的温度效应具有明显的阈值特征。无论选用何种网格尺度,蓝绿空间聚集水平偏低时,对地表温度的影响都很微弱;而当其超过某一阈值后,便可发挥降温效应。灰色空间也有类似规律,当聚集水平处于较低区间时,不会给地表温度

带来明显改变;在其增加到一定程度后,1 km×1 km尺度下,对地表温度的影响呈波动性,在另外2种尺度下聚集度的增加则表现出增温效应。

基于上述分析结果,可从以下3个方面优化3类空间的景观格局,以降低珠三角城市群的地表温度。1)适度扩大蓝绿空间面积并控制灰色空间扩张,这与已有研究结论一致(沈中健等, 2025; Wu et al., 2025)。2)避免蓝绿空间大面积连片布局,适度提高其斑块密度,同时保证地块间具有较好的连通性;对于灰色空间,则不仅需要降低斑块密度,还要避免建成区高度聚集发展。3)需将3类空间的形状复杂度与单个斑块面积控制在合理范围,以充分发挥其温度调节功能。需要强调的是,上述3个方面的景观布局优化建议均需要充分考虑不同空间尺度下各类景观特征对地表温度带来的差异化影响,从而制定分层管控方案。

4 结 论

本研究在1 km×1 km、2 km×2 km和3 km×3 km 3种网格尺度下,选用模型表现最优的XGBoost模型,探究了蓝绿灰空间景观格局对珠三角城市群夏季日间地表温度的影响。发现在所有网格尺度上,灰色空间景观特征的贡献占比均居首位,其中面积占比对地表温度变化起主导作用。而随着统计网格尺度的增大,蓝绿空间景观特征对地表温度的贡献占比逐渐提升,在所有指标中,绿色空间聚集度对地表温度影响程度的增幅最为显著。进一步结合ALE方法计算结果,针对珠三角城市群的景观布局优化提出了相应建议,以缓解热环境风险。本研究得到的规律可为城市热环境治理提供切实可行的优化思路。

本研究仅考虑了二维景观形态对地表温度的影响,后续研究可将建筑结构指数、建筑平均体积等三维景观特征纳入分析框架,并考虑风速、湿度等气象要素的影响。此外,本研究主要围绕夏季日间地表温度进行分析,后续可进一步对比不同尺度下景观特征对地表温度影响的昼夜和季节差异;并基于逐日数据探究不同尺度景观格局对极端高温的影响。





图4 1 km×1 km尺度下各特征的累积局部效应曲线

Fig. 4 ALE curves for each feature at 1 km×1 km scale



蓝色阴影区域为95%置信水平对应的置信区间,灰色竖线表示数据分布。

图5 2 km×2 km尺度下各特征的累积局部效应曲线

Fig. 5 ALE curves for each feature at 2 km×2 km scale




图6 3 km×3 km尺度下各特征的累积局部效应曲线

Fig. 6 ALE curves for each feature at 3 km×3 km scale

参考文献:

- 成雅田, 吴昌广, 2020. 基于局地气候优化的城市蓝绿空间规划途径研究进展[J]. 应用生态学报, 31(11): 3935–3945.
- 沈中健, 王金岩, 李少星, 2025. 济南市不同地理单元下蓝绿景观格局对地表温度的影响及分异规律[J]. 地理科学, 45(5): 1143–1156.
- 王刚, 张秋平, 肖荣波, 等, 2018. 秋冬季节广州城市绿地对热岛效应的调控作用差异分析[J]. 中山大学学报(自然科学版), 57(5): 38–48.
- 王佳, 李龙, 李晨, 等, 2025. 城市景观格局影响地表热环境的多尺度分析——以上海市为例[J]. 中国园林, 41(6): 86–93.
- 许晓聪, 李冰洁, 刘小平, 等, 2021. 全球 2000 年–2015 年 30 m 分辨率逐年土地覆盖制图[J]. 遥感学报, 25(9): 1896–1916.
- Apley D W, Zhu J, 2020. Visualizing the effects of predictor variables in black box supervised learning models[J]. J R Stat Soc Ser B Stat Methodol, 82(4): 1059–1086.
- Bao Y, Wang Z, 2025. Impact of 3D building landscape pattern on land surface temperature and its scaling effect [J]. Energy Build, 347: 116291.
- Cao W, Wang L, Li R, et al, 2025. Unveiling the nonlinear relationships and co-mitigation effects of green and blue space landscapes on PM_{2.5} exposure through explainable machine learning[J]. Sustain Cities Soc, 122: 106234.
- Fu X, Wang M, Zhang D, et al, 2025. An XGBoost–SHAP framework for identifying key drivers of urban flooding and developing targeted mitigation strategies [J]. Ecol Indic, 175: 113579.
- He J, Shi Y, Xu L, et al, 2024. An investigation on the impact of blue and green spatial pattern alterations on the urban thermal environment: A case study of Shanghai[J]. Ecol Indic, 158: 111244.
- He M, Yuan C, Zhang X, et al, 2023. Impacts of green–blue–grey infrastructures on high–density urban thermal environment at multiple spatial scales: A case study in Wuhan [J]. Urban Clim, 52: 101714.
- Jiang S, Zhao Y, Zhao L, et al, 2026. Nonlinear impacts of urban size and vegetation cover on global surface urban heat: Insights from 6022 cities[J]. Remote Sens Environ, 333: 115154.
- Kumar P, Debele S E, Khalili S, et al, 2024. Urban heat mitigation by green and blue infrastructure: Drivers, effectiveness, and future needs [J]. Innovation, 5(2): 100588.
- Lin Z, Peng J, Xu H, et al, 2025. The impact of gray–green space features on thermal environments across urban core–fringe gradients: A path–interaction and non–linear analysis[J]. Sustain Cities Soc, 134: 106950.
- Qu C, Xu J, Li W, et al, 2025. Quantifying the nonlinear effects of urban–rural blue–green landscape combination patterns on the trade–off between carbon sinks and surface temperature: An approach based on self–organizing mapping and interpretable machine learning [J]. Sustain Cities Soc, 130: 106608.
- Shao L, Liao W, Li P, et al, 2023. Drivers of global surface urban heat islands: Surface property, climate background, and 2D/3D urban morphologies[J]. Build Environ, 242: 110581.
- Wang H, Yi T, Lu Y, et al, 2025. Patterns of nighttime surface urban heat island patch in mega urban agglomerations: A case study in the Pearl River Delta, China [J]. Sustain Cities Soc, 128: 106465.
- Wang Q, Wang X, Zhou Y, et al, 2022. The dominant factors and influence of urban characteristics on land surface temperature using random forest algorithm [J]. Sustain Cities Soc, 79: 103722.
- Wu X, Zhang X, Liao W, et al, 2025. Contrasting 2D/3D urban morphology drivers of surface and canopy temperatures under different spatial scales [J]. Build Environ, 283: 113389.
- Xu Z, Zhao S, 2024. Fine–grained urban blue–green–gray landscape dataset for 36 Chinese cities based on deep learning network[J]. Sci Data, 11: 266.
- Yang M, Ren C, Wang H, et al, 2024. Mitigating urban heat island through neighboring rural land cover [J]. Nat Cities, 1(8): 522–532.
- Zhang M, Tan S, Zhang C, et al, 2024. Machine learning in modelling the urban thermal field variance index and assessing the impacts of urban land expansion on seasonal thermal environment [J]. Sustain Cities Soc, 106: 105345.

(责任编辑 江 睿)