

基于深度学习的高密度城市住区污染物扩散模型构建

刘帅勇¹, 许筱雯¹, 崔冬瑾²

摘要: 城市中建筑组团布局对污染物扩散有显著影响, 构建污染物扩散模型有助于快速优化建筑组团布局以改善城市局部自然通风性能, 加速污染物扩散。以深圳市为例, 使用基于真实城市数据的聚类方法建立住区组团的几何模型, 对模型进行 CFD 仿真模拟, 将模拟结果制作为污染物扩散数据集, 导入生成式对抗网络模型以学习不同形态布局下的污染物扩散空间分布规律, 进而实现对设计优化和污染物浓度实时监测场景下的污染物扩散浓度场预测, 并对模型的预测结果进行评估。研究表明: 基于生成式对抗网络的污染物扩散模型能够学习到几何形体变化和污染物浓度空间分布变化之间的关联, 模型可近实时预测污染物浓度, 与 CFD 模拟结果误差较小。研究结果可为城市空气污染问题改善和污染物浓度监测提供可靠的科学依据。

关键词: 高密度城市; 住宅组团; 污染物扩散; 生成式对抗网络; 聚类方法

Keywords: High Density City; Residential Block; Pollutant Dispersion; Generative Adversarial Network; Clustering Method

资助项目情况: 国家自然科学基金项目 (52378026); 深圳市科技计划资助 (No. 20220809120650001); 深圳市教育科学计划资助 (szy23009)

引言

近年来我国城市发展迅速, 高层住宅数量激增, 建筑密度不断提高, 导致区域性空气污染问题日益凸显, 对公众健康造成危害。在此背景下, 城市大气环境方向的研究日益增多, 许多研究对城市环境中的污染物扩散情况进行分析, 发现建筑组团布局对污染物扩散有着显著影响, 比如街区尺度的污染物流动就受到建筑密度[1]、街道纵横比[2]、建筑形态布局[3]的干扰。过往研究中, CFD 仿真模拟被视作可靠、便捷的研究方法, 广泛应用于城市环境中的流体问题研究。然而, CFD 方法计算密集且较为耗时, 对于一些需要快速反馈的应用场景, 如以污染物暴露风险优化为导向的建筑群体设计及污染物浓度的实时监测, 求解所需的时长是难以接受的。

针对上述缺陷, 近年来使用机器学习, 深度学习方法提升流体问题计算速度的研究数量增长明显。在城市风环境和污染物扩散方向, 最早的相关研究可以追溯到 20 多年前[4], 主要集中在利用风场或者实测数据来估计风速风压的干扰因素。如 BHATNAGAR S 等人的研究应用低成本空气污染物传感器对室内二氧化碳、PM2.5 等进行监测, 使用随机森林和长短时记忆神经网络等机器学习模型对室内污染物浓度的时间序列建模, 以预测危害健康的高浓度时间点[5]。前人的研究

¹ 刘帅勇, 深圳大学建筑与城市规划学院, 硕士研究生

¹ 许筱雯, 深圳大学建筑与城市规划学院, 硕士研究生

² 崔冬瑾(✉), 深圳大学建筑与城市规划学院, 副教授, jena.djcui@szu.edu.cn

证明了深度学习方法在城市污染物扩散领域的应用潜力,但在如何结合深度学习方法对高密度住区的污染物扩散进行快速预测的研究仍较为缺少。本研究以深圳市住区组团为研究对象,基于真实城市数据的聚类方法建立住区组团的几何模型,对模型进行城市行人层的污染物扩散 CFD 仿真模拟,将模拟结果处理为生成式对抗网络可读取的数据格式,制作污染物扩散数据集,导入生成式对抗网络模型以学习不同形态布局下的污染物扩散空间分布规律,进而实现对设计优化和污染物浓度实时监测场景下的高密度住区污染物扩散浓度场的近实时预测,并对模型的预测结果进行评估。

1 几何布局模型的生成

1.1 理想的几何布局模型

布局模型是城市风环境研究的基础,城市环境中的建筑群有着高度复杂的形体,在进行污染物扩散研究时,为了获得更有概括性的结果,通常采用高度抽象的模型以表示理想情况下的城市街区建筑组团形态。正方形阵列是最常用的建筑组团几何模型,Di Sabatino S 等人在正方形阵列理想城市街区中通过 CFD 方法研究了不同建筑密度下 CO 的扩散分布差异[6]。Hanna S R 等人在基础的正方形阵列规则布局上增加一定扰动,衍生错落的阵列排布,研究街道高宽比、单体迎风面积比,迎风角度等多种因素影响下的大气运动变化规律[7]。虽然错落的布局在理想方形阵列上增加了异质性,但当下的城市形态非常复杂,理想模型已不足以概括现代城市街区的复杂性,需更具现实特征的几何布局来支持城市街区中污染物扩散规律的研究。Yang F 等人的研究基于上海小区的几何信息抽象概括了典型布局,用于研究天空视野系、建筑覆盖率等指标和自然通风潜力之间的关联[8]。

然而,数据驱动型的深度学习模型依赖于较大的数据集,以上方法数据量仍不足。Ma R 等人基于 OSM 数据和地理信息系统将城市地理数据转化为建筑组团数据集,对 1062 个形态块进行建筑形态布局的聚类分析[9]。聚类方法得出的建筑组团布局模型数量可控,符合真实城市的形态特征,并且其通过大量数值或图像的特征概括建筑组团的共性、异性特点,对深度学习的数据集平衡很有帮助,后续研究将基于该方法确定 CFD 模拟所需的几何布局模型。

1.2 数据来源及处理

本研究基于深圳市的城市数据来建立布局模型,该地区地理信息数据来源丰富,为形态布局分析提供了基础。数据来源包括政府开放数据、遥感卫星图像、高德地图、百度地图等 API,同时为弥补数据缺失,研究通过多源数据来完善研究所需的相关特征。遥感图像和开源地图数据用于获取城市底图和坐标、高度等基础信息,该方法在过往研究中通过了精度评估[10]。Zhang X 的研究使用开放地图 API 收集 POI 数据,并结合高精度遥感图像分类技术区分城市功能区[11],为研究提供了参考。研究还考虑了 POI 数据的完整性和数量,住宅组团的范围以住区 AOI 为界限。最终获取的参数包含建筑密度、容积率、绿地率、POI ID、住区名、经纬度坐标、行政区、平均高度、高度标准差、用地面积、总建筑面积、面积标准差等,不同来源的数据根据坐标和住区名合并。还整理了建筑组团的矢量图像数据,通过图像分类方法区分平面不同的组合布局,矢量图像数据集通过 Arcgis 制作,不同类别的图像用数值区分作为一项特征。对异常数据进行处理后共获得 1997 条深圳住区样本,特征包括容积率、建筑密度、总建筑面积、用地面积等。数据中存在连续型特征和分类特征并存的情况,在聚类前分别进行了处理。对于连续型特征,在使用基

于距离计算的聚类方法时应进行标准化, 将其转化为无量纲数值, 不同单位或量级的指标才能够进行计算和比较, 本实验采用 Z-Score 标准化方法处理。类别型特征如图像标签, 不存在大小、序列关系, 因此采用独热编码方式对分类标签重新编码。

1.3 基于 wk-means 的几何布局聚类

wk-means 是基于 k-means 聚类的一种改进算法。k-means 算法平等地对待所有特征, 数据挖掘过程中不考虑对特征的选择。但在实践中, 对聚类问题特征的选择依赖于研究者对业务问题的理解, 一个具有大量特征的数据集意味着问题需要在高维空间内求解, 这其中可能存在噪声维度, 在这些噪声维度的干扰下原先成簇的数据将不可区分[12], 而 wk-means 算法可以通过权重项削弱噪声维度带来的负面影响[13]。在该研究中, 三维建筑群形态布局相似性判断需要的特征较难分析, 开源数据也可能存在精度问题, 因此选用 wk-means 以避免错误或异常特征对聚类结果的影响

$$P(U, Z, W) = \sum_{l=1}^k \sum_{i=1}^n \sum_{j=1}^m u_{i,l} w_j^\beta d(x_{i,j}, z_{l,j}) \quad (1)$$

式中: U 是簇分配矩阵, $u_{i,l}$ 是二进制变量, $u_{i,l} = 1$ 表示对象 i 被分配给簇 l , 反之为 0; $Z = \{Z_1, Z_2, \dots, Z_k\}$ 是一个由 k 维向量组成的集合, 代表 k 簇的质心; $d(x_{i,j}, z_{l,j})$ 是基于距离或相似度的度量, 表示第 j^{th} 变量中对象 i 和簇 l 质心之间的差距, $W = [w_1, w_2, \dots, w_m]$ 为特征的权重矩阵, w_j^β 为权重项, 其中 β 是特征权重 w_j 的参数。

聚类结果可视化采用 t-SNE 方法, t-SNE 将高维空间中的数据点映射到低维空间中, 并使高维和低维数据样本的概率分布尽可能不变, 从而减少维度。(图 1) 结果表明, 当 k 值为 7 时存在数据量较少的簇, 为确保聚类结果有典型性, 簇内样本数量少于总量 3% 时, 应当排除在聚类结果外。筛除后, 最终保留了 6 个簇的聚类标签。

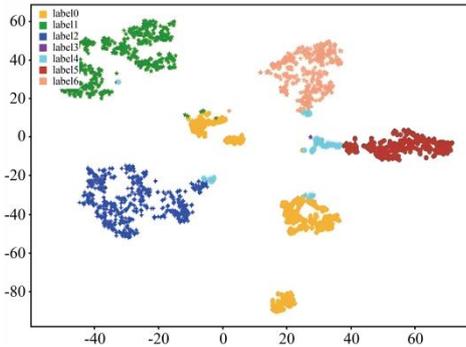


图 1 wk-means 聚类结果可视化 (图片来源: 作者自绘)

对聚类后的住区组团进行可视化分析, 并举 k-means 结果以观察加权后的聚类结果差距。如(图 2), k-means 不考虑各特征的权重, 因此数据较大的面积类特征对聚类结果影响很大, wk-means 的各簇之间则表现出更明显的几何差异, 受面积特征影响小, 更好地代表了真实城市中的建筑组团特征。

| 类别 | k-Means | wk-Means |
|----------|---------|----------|
| Cluster0 | | |
| Cluster1 | | |
| Cluster2 | | |
| Cluster3 | | |
| Cluster4 | | |
| Cluster5 | | |

图2 k-means 与 wk-means 的聚类结果对比（图片来源：作者自绘）

2 基于生成式对抗网络的污染物传播模型构建

2.1 CFD 仿真模拟设置及模拟数据的后处理

在各簇中按比例选取 136 个住宅组团，导出二维底图以及建筑高度信息，使用 CAD 建立三维模型，全部简化为体块。为平衡精度和时间成本，在 Fluent 中，将几何模型进行缩尺处理，Liu S 等研究表明，几何相似和边界层流相似在模型缩放时是相对容易实现的[14]。

CFD 仿真模拟中计算域按照研究区域中的最大建筑高度 H 确定，计算域内的建筑距离进风侧和两侧边界的距离各为 $3H$ ，距离出场边界 $10H$ ，最高建筑至上边界为 $5H$ 。网格在 ICEM 中采用非结构性网格划分，总数控制在 1×10^7 至 3×10^8 ，最小特征表面保证至少有 10 个单元网格。本研究选用 RANS 标准 $k-\epsilon$ 模型，采用速度入口模式，使用基于湍流强度和平均风速为特征的测量垂直剖面，出口边界采用压力出口，侧面以及顶部采用自由滑移的对称面，地面以及建筑物外立面采用无滑移固壁，采用标准壁面函数，不引入粗糙壁面修正设置。求解算法为压力耦合的 SIMPLE 算法，压力插值设为二阶迎风，二阶离散化方案用于控制方程的对流和黏性项。污染源设置在建筑群北面 $20m$ 外的居中位置，为 $7m \times 7m$ 面源，采用一氧化碳与空气混合模式，将 CO 作为示踪气体。污染源的边界采用速度入口模式，以平均速度为特征垂直于面源释放，对每个污染源采用相同的 $0.001m/s$ 的释放速率。污染物质量分数设定为 1，计算域中的初始污染物浓度设置为 0，计算结果对 CO 浓度进行无量纲化。具体设置（如图 3）。

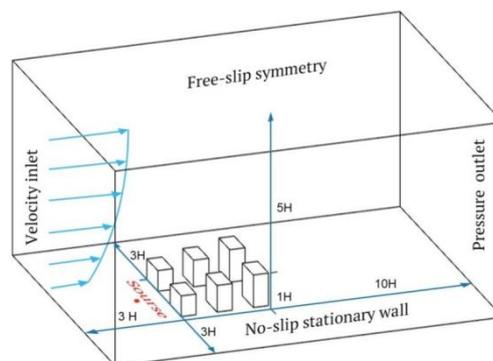


图3 CFD 模拟的计算域设置（图片来源：作者自绘）

研究采用 Tecplot 作为 Fluent 计算结果的后处理工具，对行人层高度（ $1.5m$ 处）的污染物

扩散浓度使用云图方式进行可视化，显示时统一 CO 浓度标尺。对 Tecplot 产生的云图进一步处理，使其格式适配生成式对抗网络模型的输入。由于计算域的边界是根据区域内最高建筑确定的，左右两侧和前后场的比例不一致，因此完整的计算域是长宽比不等的矩形。为保证模型训练时具有相同的输入尺寸，对模拟结果进行了裁剪，在保证浓度场的完整性前提下对空白区域进行省略，处理成正方形等尺寸图像作为目标数据。污染源位置使用固定红色标识，监测场景下各传感器点位上的 RGB 值与 Tecplot 对应的 CO 浓度进行统一标识，建筑群高度映射为灰度值在图像上表示三维信息。最终将成对的标签数据和目标数据进行拼接，如（图 4），通过自定义方法加载成对的图像数据，输入各生成式对抗网络模型进行下一步训练。

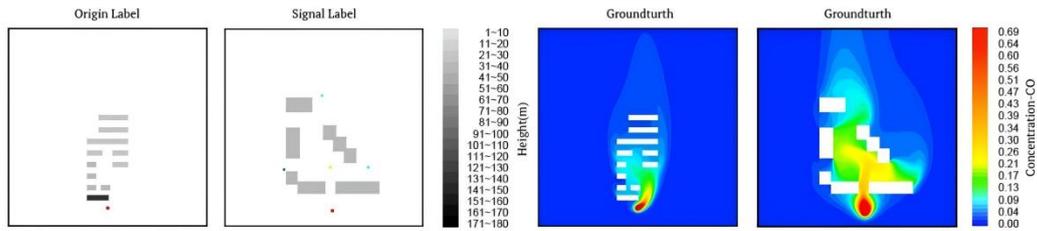


图 4 两种模式下的数据集格式（图片来源：作者自绘）

2.2 模型实现与模型预测结果评价指标

生成式对抗网络是一种深度学习模型，由 Ian Goodfellow 提出，是各类改进型 GAN 的基础。模型由生成器和鉴别器构成，这两部分在训练过程中相互竞争，促进模型性能的不不断提升。研究基于 Pix2Pix、CycleGAN、Pix2PixHD 三种进阶生成式对抗网络搭建污染物扩散模型。Pix2Pix 由 Isola P 等人在 2017 年提出，是一种基于 CGAN 模型的深度学习模型，被认为能够良好适配图像翻译问题[15]。CycleGAN 是 Zhu J Y 等人提出的模型[16]，该模型训练时不需要成对的配对样本，只需要源域和目标域的图像即可完成图像的迁移。由于 Pix2Pix 或者 CycleGAN 在高分辨率下的生成结果不理想，而如果对低分辨率的输出结果直接放大将会导致图片的模糊。在城市污染物扩散的研究场景中，任何尺寸图片的像素网格或者说矩阵都带有现实意义上的尺度信息，高分辨率意味着更精细的网格，因此基于生成高清且准确的结果这个目标，Pix2PixHD 被提出[17]。研究分别设置设计优化模式和监测模式，对它们分别建模训练。不同场景下的数据集均有 136 对案例，以 9:1 的比例随机划分训练集和测试集。训练参数如（表 1）。

表 1 模型训练参数表（表格来源：作者自绘）

| 模型 | 训练参数 | |
|----------|---|---|
| | 设计优化模式 | 监测模式 |
| Pix2Pix | Input: 256*256, Epoch:160, Batch_size: 1, 随机正态分布初始化, Adam 优化器, 初始学习速率: 0.0002 学 习率衰减: 100 Output: 256*256/1024*1024 | Input: 256*256, Epoch:200, Batch_size: 1, 随机正态分布初始化, Adam 优化器, 初始学习速率: 0.0002 学 习率衰减: 100 Output: 256*256/1024*1024 |
| CycleGAN | Input: 256*256, Epoch:160 Batch_size: 1, 随机正态分布初始化, Adam 优化器, 初始学习速率: 0.0002 学 习率衰减: 100 | Input: 256*256, Epoch:200 Batch_size: 1, 随机正态分布初始化, Adam 优化器, 初始学习速率: 0.0002 学 习率衰减: 100 |

| | Output: 256*256 | Output: 256*256 |
|-----------|--|---|
| Pix2PixHD | Input: 1024*1024 / 512*512, Epoch:100 (Global) 80 (Local) Batch_size: 1, 随机正态分布初始化, Adam 优化器, 初始学习速率: 0.0002 学 习率衰减: 100 VGG content Loss:True | Input: 1024*1024 / 512*512 Epoch:200 (Global) 60 (Local) Batch_size: 1, 随机正态分布初始化, Adam 优化器, 初始学习速率: 0.0002 学 习率衰减: 100 VGG content Loss:True |

训练开始前,首先在完整的数据集中选取一部分样本对各模型进行拟合训练以排除模型的明显错误。设计优化模式下 Pix2Pix、CycleGAN、Pix2PixHD 对训练集的拟合精度分别可达 88.1%, 91.1%, 96.8%, 误差可视化结果如(图 5)。监测模式下三者对训练集的拟合精度分别可达 94.9%, 91.7%, 95.1%, 误差可视化结果如(图 6)。

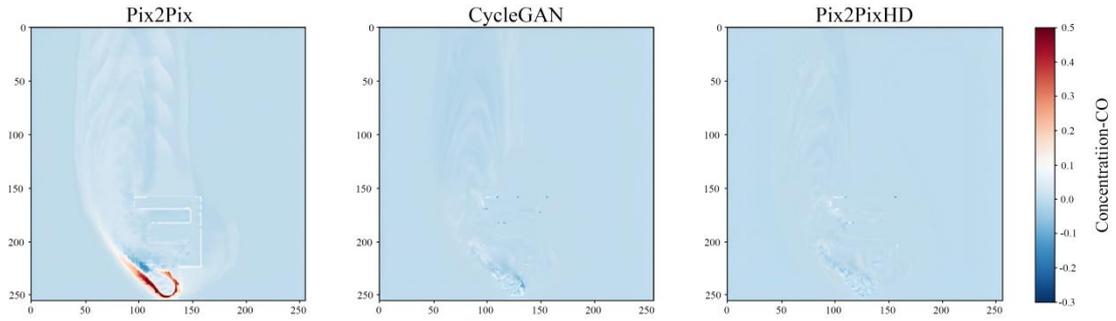


图 5 设计优化模式训练集拟合误差 (图片来源: 作者自绘)

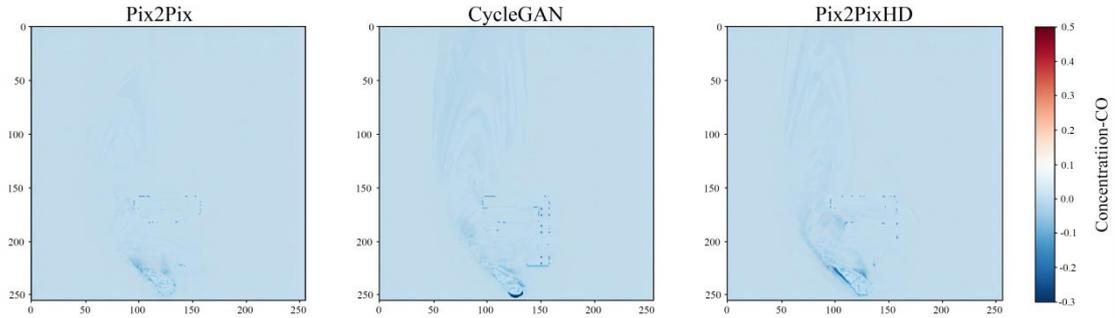


图 6 监测模式训练集拟合误差 (图片来源: 作者自绘)

参考过往研究,研究使用 MAE、RMSE 和 MRE 衡量模型的预测性能[18]。式中: y_i , \hat{y}_i 分别表示 CFD 仿真模拟结果和模型预测结果中的第 i 个像素的浓度值, 各评价指标对各模型产生的全部预测图像进行平均计算。MAE 指标用于衡量模拟结果和模型预测结果的绝对误差平均值。该指标被广泛应用于回归模型的准确度验证中。MAE 分数越低, 表示在给定建筑组团几何形状输入的情况下, 模型重建相应的浓度场的能力越好。

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

RMSE 指标衡量模拟结果和模型预测结果之间的偏差, 并且对数据中的异常值较为敏感, 相比起 MSE, RMSE 消除了量纲的影响, RMSE 分数越低说明模型对浓度场的预测极端异常值越小。

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

MRE 指标用于量化模拟结果与模型求解浓度产生的平均相对误差。该度量反映预测值与真值

偏离的比例，能够直观表达模型预测结果的可信程度。

$$\text{MRE}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (4)$$

研究为对比三个模型在各模式下的性能表现，对每个模型都进行多次训练后取评价指标的均值。不同模式下各模型指标见(表 2)。

表 2 各模型评价指标结果对比表(表格来源: 作者自绘)

| 模型 | 设计优化模式 | | | 监测模式 | | |
|-----------|--------|-------|-------|-------|-------|-------|
| | MAE | RMSE | MRE | MAE | RMSE | MRE |
| Pix2Pix | 0.212 | 0.501 | 0.479 | 0.142 | 0.389 | 0.249 |
| CycleGAN | 0.232 | 0.472 | 0.458 | 0.197 | 0.426 | 0.358 |
| Pix2PixHD | 0.162 | 0.403 | 0.305 | 0.137 | 0.385 | 0.235 |

2.3 模型预测结果分析

设计优化模式下, Pix2PixHD 模型相比起 CycleGAN 和 Pix2Pix 模型, MRE 差距达 15.3% 和 17.4%, MAE 和 RMSE 也有较好的提升, 异常浓度值偏移程度更小。从测试集中随机抽取 5 对样本观察, 如(图 7), Pix2Pix 模型产生了更清晰的浓度分布界限, 但震荡明显, 容易产生与模拟结果不符的浓度分布。CycleGAN 的预测结果浓度过渡平滑, 但容易将污染物浓度场范围预测地更小。综合来看 Pix2PixHD 的预测结果更接近模拟结果, 但对于一些在训练集中出现较少的建筑群布局, 也会有不合理的浓度分布。

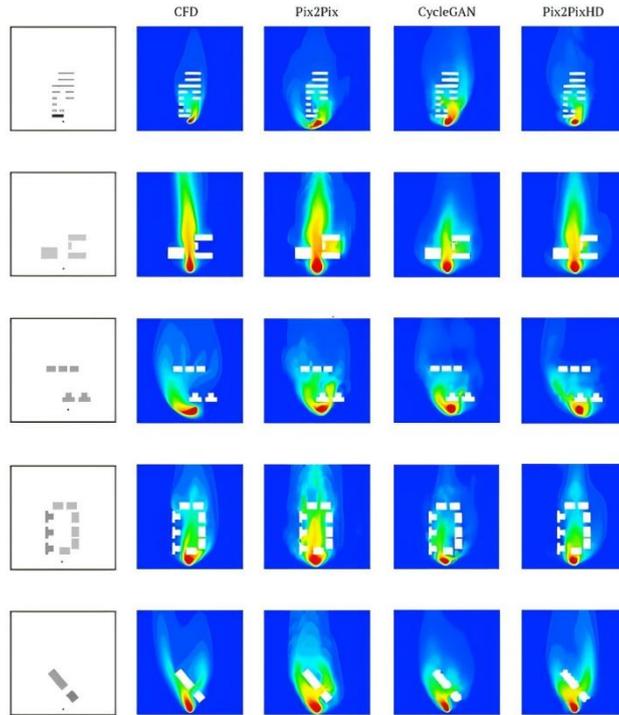


图 7 设计优化模式下各模型预测结果(图片来源: 作者自绘)

将误差可视化后可以发现, Pix2PixHD 的预测误差更小, 而 Pix2Pix 的 RMSE 较高说明容易出现较大常偏差。如(图 8), 污染物源处出现了异常高浓度值外扩, 右侧三面围合的建筑组团中

也产生了较高的浓度值区域，与 CFD 模拟结果不符。CycleGAN 和 Pix2PixHD 模型更接近模拟结果，预测出污染物将沿着 y 轴通道扩散稀释，围合范围内污染物滞留现象也不明显。

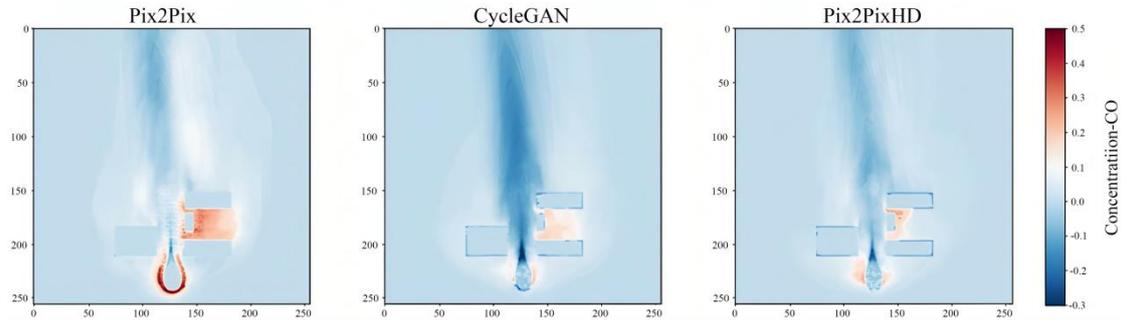


图 8 设计优化模式下各模型预测误差（图片来源：作者自绘）

监测模式下的各模型性能均有提升，监测点的浓度值提供了更多信息，帮助模型更好地拟合污染物在空间上的传输规律。其中 Pix2Pix 模型受影响最为明显，其与 Pix2PixHD 的各项性能差距被缩小。CycleGAN 的提升相对较小，其 RMSE 和 MRE 指标与另两个模型有明显差距，不同建筑群几何布局下，其预测结果都比较模糊，浓度值整体偏低，如（图 9）。将误差可视化后可以发现，如（图 10），监测点信息减少了 Pix2Pix 和 Pix2PixHD 的整体预测误差，污染物空间分布更接近模拟结果。两个模式的误差对比可以证明各模型对监测点信息具有敏感性。

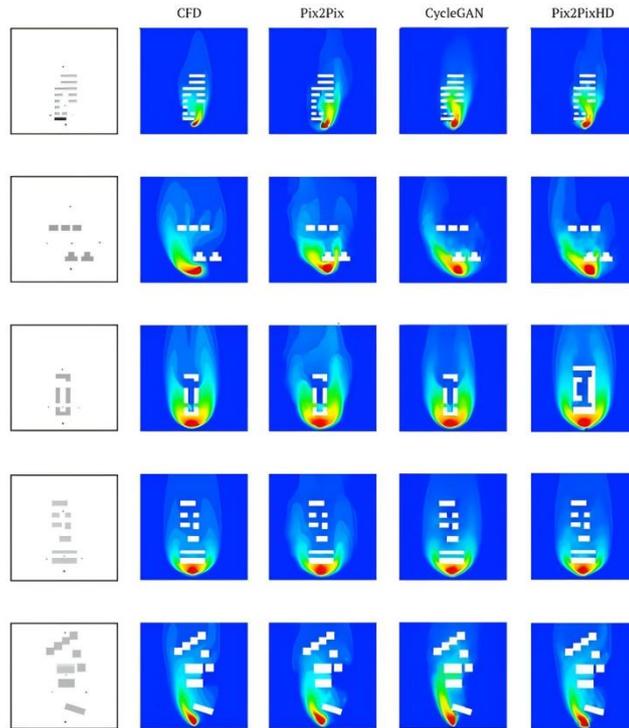


图 9 监测模式下各模型预测结果（图片来源：作者自绘）

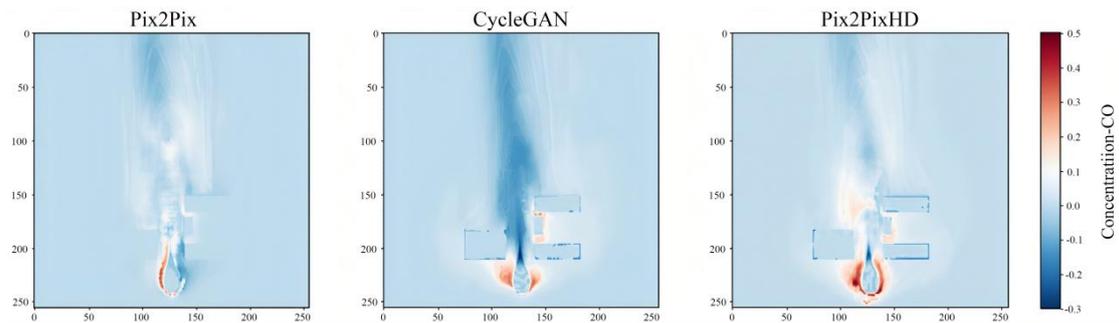


图 10 监测模式下各模型预测误差 (图片来源: 作者自绘)

结语

研究通过生成式对抗网络结构建立了街区尺度的数据驱动污染物扩散模型,以深圳市聚类住区模型为例,研究不同几何输入与特定流场条件下污染物浓度的分布差异,探究了该方法在建筑群设计优化及污染物实时监测场景中的应用潜力。研究的主要结论如下:(1)基于城市数据聚类得到的建筑几何模型确立,对真实城市环境中复杂的建筑组合有更好的适应性。(2)基于生成式对抗网络的污染物扩散模型能够学习到几何形体变化和污染物浓度空间分布变化之间的关联(3)相比起CFD数值仿真方法,数据驱动型的深度学习模型没有湍流中复杂方程的限制,从数据分布中逼近污染物运动规律,在计算速度上得到了极大提升,能实现近实时预测。(4)针对不同类别形态布局建筑群对比了三个模型的预测结果,整体上Pix2PixHD模型对不同形态布局的几何输入表现更为稳健,精度更高。其次为Pix2Pix模型,性能接近Pix2PixHD,在设计模式下稳定性稍落后于Pix2PixHD,监测模式下精度差异较小。CycleGAN的非配对数据集训练不适合污染物扩散场景下的建模,在两种模式下的性能都落后于Pix2Pix和Pix2PixHD模型。

研究运用的数据驱动模型虽然能压缩污染物扩散的预测时间,但其拟合的是CFD仿真结果数据,不包含符合湍流模型的物理约束,因此其精度只能逼近CFD的模拟结果,后续研究可以通过为模型添加流体力学的物理约束以进一步提升预测精度。

参考文献

- [1] BUCCOLIERI R, SANDBERG M, DI SABATINO S. City breathability and its link to pollutant concentration distribution within urban-like geometries[J/OL]. Atmospheric Environment, 2010, 44(15): 1894-1903. DOI:10.1016/j.atmosenv.2010.02.022.
- [2] BARATIAN-GHORGHI Z, KAYE N B. The effect of canyon aspect ratio on flushing of dense pollutants from an isolated street canyon[J/OL]. Science of The Total Environment, 2013, 443: 112-122. DOI:10.1016/j.scitotenv.2012.10.064.
- [3] HAGISHIMA A, TANIMOTO J, NAGAYAMA K, 等. Aerodynamic Parameters of Regular Arrays of Rectangular Blocks with Various Geometries[J/OL]. Boundary-Layer Meteorology, 2009, 132(2): 315-337. DOI:10.1007/s10546-009-9403-5.
- [4] ENGLISH E C, FRICKE F R. The interference index and its prediction using a neural network analysis of wind-tunnel data[J/OL]. Journal of Wind Engineering and Industrial Aerodynamics, 1999, 83(1-3): 567-575. DOI:10.1016/S0167-6105(99)00102-6.
- [5] BHATNAGAR S, AFSHAR Y, PAN S, 等. Prediction of aerodynamic flow fields using convolutional neural networks[J/OL]. Computational Mechanics, 2019, 64(2): 525-545. DOI:10.1007/s00466-019-01740-0.
- [6] DI SABATINO S, BUCCOLIERI R, PULVIRENTI B, 等. Simulations of pollutant dispersion within idealised urban-type geometries with CFD and integral models[J/OL]. Atmospheric Environment, 2007, 41(37): 8316-8329. DOI:10.1016/j.atmosenv.2007.06.052.
- [7] HANNA S R, TEHRANIAN S, CARISSIMO B, 等. Comparisons of model simulations with observations of mean flow and turbulence within simple obstacle arrays[J/OL]. Atmospheric Environment, 2002, 36(32): 5067-5079. DOI:10.1016/S1352-2310(02)00566-6.

- [8] YANG F, QIAN F, LAU S S Y. Urban form and density as indicators for summertime outdoor ventilation potential: A case study on high-rise housing in Shanghai[J/OL]. *Building and Environment*, 2013, 70: 122-137. DOI:10.1016/j.buildenv.2013.08.019.
- [9] MA R, LI X, CHEN J. An elastic urban morpho-blocks (EUM) modeling method for urban building morphological analysis and feature clustering[J/OL]. *Building and Environment*, 2021, 192: 107646. DOI:10.1016/j.buildenv.2021.107646.
- [10] REN C, CAI M, LI X, 等. Developing a rapid method for 3-dimensional urban morphology extraction using open-source data[J/OL]. *Sustainable Cities and Society*, 2020, 53: 101962. DOI:10.1016/j.scs.2019.101962.
- [11] ZHANG X, DU S, WANG Q. Hierarchical semantic cognition for urban functional zones with VHR satellite images and POI data[J/OL]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 132: 170-184. DOI:10.1016/j.isprsjprs.2017.09.007.
- [12] KRISHNA K, NARASIMHA MURTY M. Genetic K-means algorithm[J/OL]. *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, 1999, 29(3): 433-439. DOI:10.1109/3477.764879.
- [13] HUANG J Z, NG M K, HONGQIANG RONG, 等. Automated variable weighting in k-means type clustering[J/OL]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(5): 657-668. DOI:10.1109/TPAMI.2005.95.
- [14] LIU S, PAN W, CAO Q, 等. CFD simulations of natural cross ventilation through an apartment with modified hourly wind information from a meteorological station[J/OL]. *Energy and Buildings*, 2019, 195: 16-25. DOI:10.1016/j.enbuild.2019.04.043.
- [15] ISOLA P, ZHU J Y, ZHOU T, 等. Image-to-Image Translation with Conditional Adversarial Networks[C/OL]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI: IEEE, 2017: 5967-5976[2023-11-20]. <http://ieeexplore.ieee.org/document/8100115/>. DOI:10.1109/CVPR.2017.632.
- [16] ZHU J Y, PARK T, ISOLA P, 等. Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks[C/OL]//2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE, 2017: 2242-2251[2023-11-20]. <http://ieeexplore.ieee.org/document/8237506/>. DOI:10.1109/ICCV.2017.244.
- [17] WANG T C, LIU M Y, ZHU J Y, 等. High-Resolution Image Synthesis and Semantic Manipulation with Conditional GANs[C/OL]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 8798-8807[2023-11-20]. <https://ieeexplore.ieee.org/document/8579015/>. DOI:10.1109/CVPR.2018.00917.
- [18] CHEN D, GAO X, XU C, 等. FlowGAN: A Conditional Generative Adversarial Network for Flow Prediction in Various Conditions[C/OL]//2020 IEEE 32nd International Conference on Tools with Artificial Intelligence (ICTAI). Baltimore, MD, USA: IEEE, 2020: 315-322[2023-11-20]. <https://ieeexplore.ieee.org/document/9288323/>. DOI:10.1109/ICTAI50040.2020.00057.