

基于机器学习的居住区风环境多维度预测方法

王虹宇¹, 刘大龙²

摘要: 传统 CFD 技术模拟区域风环境存在流程繁琐和效率低下等明显缺点, 这极大地限制了以性能优化为导向的设计方法的普及。机器学习作为一种寻找输入和输出数据之间映射关系的一种工具, 在工程领域具有极大的应用价值, 为解决这一问题提供了一种可能性。以夏热冬冷地区典型城市杭州市的气象条件和点板混合式高层住宅区建筑布局特点作为研究基础, 搭建用于神经网络训练的数据库。通过学习建筑布局和冬夏两季风环境之间的对应关系, 从整体风场和测点风速两个维度对居住区内部风环境进行优化和调控。实验结果表明: 该方法可在有限的误差范围内快速预测生成整体风环境模拟图像以及目标测点的风速。建筑师可使用该方法在设计初期对方案进行调整, 提高工作效率, 营造舒适的人居环境。

关键词: 条件生成对抗网络; BP 神经网络; 风环境; 性能预测; 居住区布局

Keywords: Conditional Generation Adversarial Network; BP Neural Network; Wind Environment; Performance Prediction; Residential Area Layout

引言

随着城市常住人口的增长, 高层住宅区已成为城市中的主要建筑类型。研究表明, 不同高度的住宅单元分布显著影响着住区内部的风环境。高层建筑的出现导致建筑群内部风场发生剧烈变化, 风环境问题日益突出^[1,2]。如何在保证开发商经济效益的同时, 提升居民居住舒适度, 已成为住区开发中的关键问题。

对于城市风环境的研究, 主要以风洞试验、现场实测和基于计算流体力学理论 (CFD) 的计算机模拟为主^[3]。其中, CFD 所具有的直观性、便捷性、准确性、高性价比等特点受到广泛的认可, 且被大量应用于现有研究中。但传统 CFD 模拟过程中, 模拟结果的准确性和计算效率主要取决于模拟区域大小、参数设置、网格疏密以及计算机硬件配置等。此外, 常见基于 CFD 优化的流程为: 建模-模拟-分析-优化, 这往往导致性能优化过程耗时长、工作效率较低等明显缺点, 这也限制了此类方法在方案初期性能模拟优化方面的运用。

随着机器学习技术的发展, 以数据驱动对建筑性能进行预测的运用越来越多。特别是神经网络在设计领域的应用, 使设计师无需复杂的目标函数即可预测未知数据。如: Narahara T 等^[4] 构建的深度学习模型快速生成了密集城市建筑形态; Erik Swahn 等^[5] 将 CGAN 应用于城市和建筑设计, 展示了其巨大潜力。数据驱动方法预测结果的准确性主要依赖于输入数据的准确性, 不涉及模拟参数的设置。同时, 运用训练完成的神经网络进行预测的过程耗时较短, 因此从结果准确性和计算效率两个角度来讲,

¹ 王虹宇, 西安建筑科技大学建筑学院, 在读博士研究生

² 刘大龙 (✉), 西安建筑科技大学建筑学院, 副教授, coffeercv@xauat.edu.cn

数据驱动方法更适用于方案初期对建筑性能的判定^[6]。在以性能优化为导向的生成式设计领域，季云竹^[7]等结合环境性能模拟、机器学习、多目标优化技术等，从住区环境性能的综合提升出发展开研究；朱姝妍^[8]等依托机器学习和参数化技术建立了面向方案设计阶段能耗主导的建筑性能快速优化方法；Yijun Lu^[9]等集成参数化设计、性能仿真和机器学习，提出了一种能快速优化建筑环境性能的设计方法。总的来看，在将机器学习技术运用到建筑性能优化方面相关的研究主要还是结合参数化平台来实现。该类方法需要建筑从业人员同时具备参数化建模能力和算法编程能力，在实际运用方面具有一定局限性。本研究基于机器学习技术构建风环境预测模型，并以18组杭州市典型点板混合式高层住宅区为例，将其作为数据来源，归纳其布局特征和尺寸数据。依据杭州市相关法规，生成了81组布局方案及其风环境模拟数据，构建了实验数据集。使用这种方法设计师只需向神经网络提供特征数据和目标数据，不用计算复杂的目标函数，操作难度较低。

1 训练数据集的制作

1.1 建筑选型

本文通过调研杭州市典型点板混合式高层住宅区的平面布局和体量数据，结合实地调研与统计结果，对实验中的建筑布局、平面体量和建筑高度进行了简化，选取18组案例作为研究样本（图1）。这种方法在降低研究成本和时间的同时，确保了结果的可靠性和代表性。通过对这些样本的分析比较，可以总结出高层住宅区建筑布局与体量设计的规律和经验。

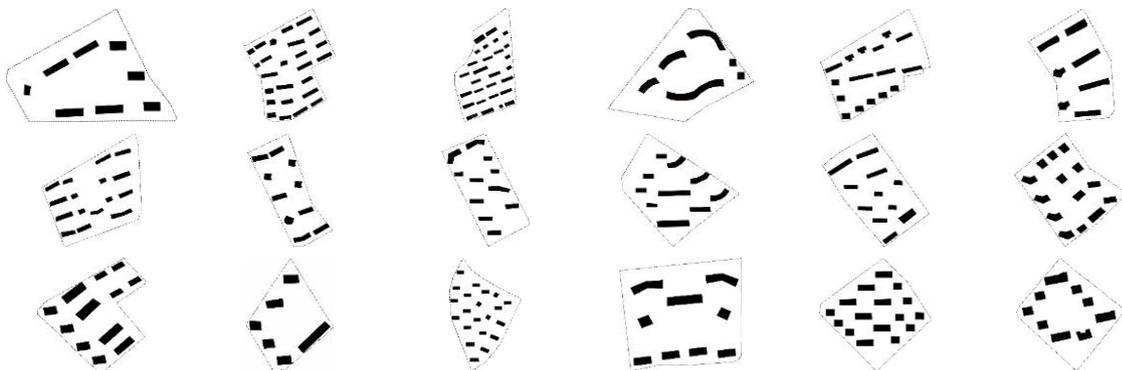


图1 典型点板混合式居住区案例选取（图片来源：作者自绘）

调研发现，居住区内常见3种不同高度的建筑共存。根据我国建筑规范，不同高度的建筑需满足不同的防火和日照间距要求。因此，11F、18F和30F的住宅成为设计师的常见选择。通过调研总结发现点式和板式住宅的常见尺寸在一定范围内，并遵循特定的长宽比。综合已建成居住区案例，本研究确定了建筑单元模块尺寸（见表1），点式住宅建筑用P表示，板式住宅建筑用B表示。

表1 实验建筑选型表

建筑类型	编号	平面尺寸/m（长×宽）	层数/F
板式建筑	B1	60×15	11
	B2	40×15	18
	B3	60×15	18
	B4	40×15	30
	B5	60×15	30
点式建筑	P1	20×15	11
	P2	20×15	18
	P3	20×15	30

1.2 人工布局数据集

通过对夏热冬冷地区杭州市点板混合式住区的调研，发现该气候区的住区建筑布局具有以下规律（后期 81 组布局方案均参照这些规律）：

- 1) 点式建筑通常位于住区南侧或中央，板式建筑围合布置；
- 2) 住区总图多采用中轴对称布局；
- 3) 在相同条件下，楼栋数量越少，开发成本越低；
- 4) 住区建筑密度通常控制在 20%~25%。

相邻建筑间距按照《建筑设计防火规范》^[10]和《城市居住区规划设计标准》^[11]，并结合日照模拟软件计算结果，以确保建筑满足基本的日照采光标准和消防要求（表 2）。

表 2 建筑控制间距

平面尺寸/m (长×宽)	层数/F	南北间距/m	东西间距/m
40×15	18	33	13
	30	40	13
	11	44	13
60×15	18	48	13
	30	63	13
	11	16.3	13
20×15	18	17	13
	30	17	13

本次实验设定的用地规模为 390m×240m，人工布局的容积率控制在 2.60~2.65 之间。基于前文调研归纳的建筑尺寸和高度数据，每个人工布局方案选用 2 种点式建筑和 2 种板式建筑，其中板式建筑严格南北向放置，不考虑角度偏转，最终生成 81 组人工布局方案，如图 2 所示。

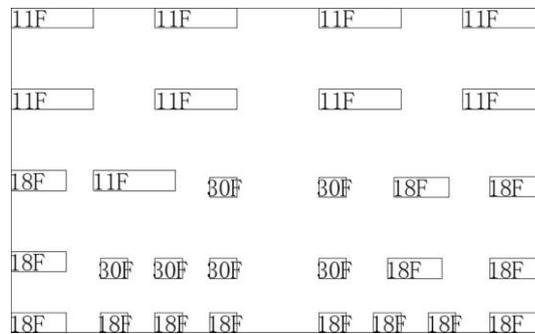


图 2 人工布局方案示意（图片来源：作者自绘）

1.2 风环境模拟训练数据集

(1) 模型建立

将上文的人工布局方案 CAD 文件导入 Rhino 软件，进行三维建模，并导出为 STL 格式以便在 Phoenix 中进行风环境模拟。本文研究的是居住区规划设计前期建筑分布与风环境的关系。由于布局 and 高度是关键因素，建模时忽略了建筑形体和材料，将模型简化为规整形体。

(2) 计算域与模拟边界条件设置

根据《中国建筑热环境分析专用数据集》^[12]及中国气象数据的综合分析，本次风环境模拟的实验风速设定为 3 m/s，夏季考虑正南风向，冬季考虑正北风向。Phoenix 软件基于雷诺时均方程自动选择计算条件。初始风设置如下：地表附近风速随高度降低而减小，300 m 至 500 m 范围内风速不受地表

影响，自由流动。来流面风速的变化以指数率表示：

$$U(z) = UG \times \frac{z}{zG}^\alpha \quad (1)$$

式中， $U(z)$ 为任意高度 z 处的平均风速， UG 是标准高度 zG 处的平均风速，指数 α 为描述地面粗糙度的参数。模拟中标准高度 zG 设定为 400 m，该高度处平均风速 UG 为 13 m/s， α 为 0.25。湍流强度假定为地面 52 m 以上 12%^[13]。

对于模拟区域大小，Chang 等^[14]建议建筑模型与模拟区域边缘的距离至少为建筑高度的 3~5 倍。因此，在不考虑周边环境的情况下，模拟区域尺寸设定为 1170 m × 720 m × 270 m，网格大小为 X、Y 方向各 3 m，Z 轴方向 1.5 m 内设 3 个网格。减少网格尺寸会显著增加网格数和计算时间，综合考虑后确定本次模拟的网格设置。本次模拟采用 κ - ϵ 湍流模型，收敛精度为 0.0001，迭代 10000 次至收敛，部分参数如表 3 所示。

表 3 风环境模拟条件设置

类别	设定条件
计算域	1170 m × 720 m × 270 m
湍流模型	κ - ϵ 湍流模型
迭代次数	10000 次
收敛精度	0.0001
来流边界	夏季正南风向;冬季正北风向;实验风速 3m/s
出流边界	自然出流边界
边界条件	顶部及侧面:自由滑移边界;地面:无滑移边界
网格划分	390(X) × 240(Y) × 3(Z)=280800 个计算单元

2 整体风场预测模型

基于风场分布以图像形式呈现的特点，本次风场预测模型采用条件生成对抗网络 (CGAN)，以图像作为输入和输出进行搭建和训练。训练数据集可以通过多种方法获取，其中物理性能训练模式分为基于物理模型和数据驱动两类。利用 TensorFlow 工具的简便性和灵活性，可以作为高级机器学习库，对 CGAN 的生成器网络、鉴别器网络和损失函数进行调试。

2.1 人工布局数据集转译

通过 CGAN 学习居住区平面布局与风环境的关系，最终模型能快速生成任意布局方案的风环境模拟图。为实现这一目标，首先需要确定平面布局方案的表达形式。为此，本研究采用图底关系图作为人工布局方案的转译形式，因其能清晰表达建筑布局和场地关系。研究表明，不同高度建筑对风环境有显著影响，因此在图底关系图中用灰度表示建筑高度，不同高度对应不同灰度值，如图 3 所示。

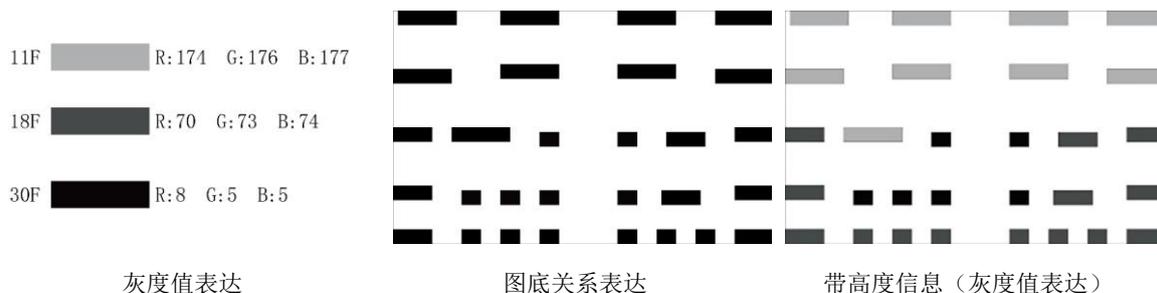


图 3 人工布局数据集转译示意 (图片来源: 作者自绘)

2.2 风场预测 CGAN 模型结构

风场预测 CGAN 模型由生成器网络和鉴别器网络组成，两者相互博弈，最终实现风环境模拟图像的预测生成（图 4）。该过程分为以下步骤：

- (1) 生成器网络接收带有灰度高度信息的总平面布局图及随机噪声，生成风环境预测图像，其目标是迷惑鉴别器，使预测图像尽可能接近真实图像；
- (2) 鉴别器网络接收预测图像，并与真实图像对比，以判别其真实性。当预测图像足够接近真实图像，成功迷惑鉴别器时，模型输出该预测图像。

风环境预测 CGAN 模型的生成器网络以带灰度值的平面布局图为输入，生成对应的风环境模拟图像。网络采用 U-Net 架构，在传统编码器-解码器结构上加入跳跃连接，实现输入与输出的底层信息共享。编码器使用卷积层提取特征并下采样，解码器使用反卷积层丰富特征并上采样。生成器通过 dropout 层为输入添加随机噪声。

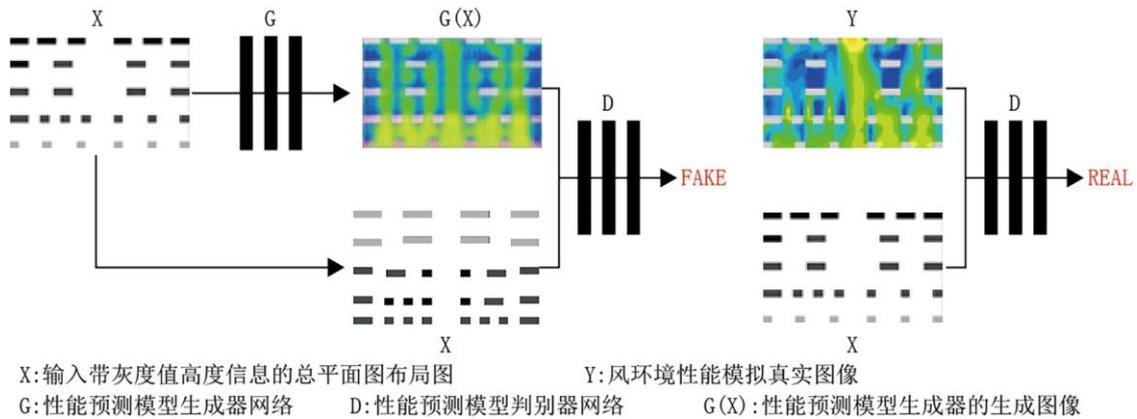


图 4 风场预测 CGAN 模型结构（图片来源：作者自绘）

2.3 风场预测 CGAN 模型训练过程

训练参数分为优化器超参数和模型超参数，模型超参数参考了 pix2pix 算法的默认设置，优化器超参数重点调试了学习率和迭代次数。以 pix2pix 算法为参考，通过控制变量法对风场预测 CGAN 模型进行测试，夏季（南风）为例。以学习率 0.0002 为基准，迭代 80 次，测试不同学习率（0.0001、0.0002、0.0003）下的效果，结果见表 4。结果显示，生成器损失函数呈上升趋势，鉴别器损失函数下降，但学习率为 0.0001 时，鉴别器损失下降最平稳，且预测图像与真实图像的风环境分布相似度最高，因此将学习率设定为 0.0001。

在此基础上，测试了不同迭代次数（1、100、200、400、500）。综合考虑相似度和训练时间，迭代 500 次时效果最佳，图像相似度高且边界清晰，训练时间较短。因此，模型的迭代次数设定为 500。部分参数设置见表 5。

表 4 风场预测 CGAN 模型不同学习率的训练效果

学习率	生成器/鉴别器loss函数	训练结果
0.0001		<div style="display: flex; justify-content: space-around;"> <div style="text-align: center;"> <p>居住区布局</p> </div> <div style="text-align: center;"> <p>真实图像</p> </div> <div style="text-align: center;"> <p>预测图像</p> </div> </div>

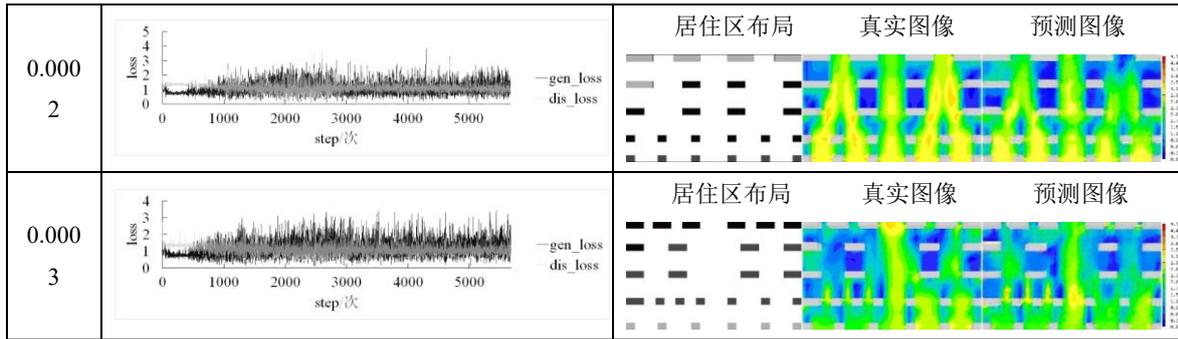


表 5 风场预测 CGAN 模型部分参数设置

生成器网络层数/层	鉴别器网络层数/层	随机噪声数	学习率	迭代次数/次	Adam beta1	Batch size
UNet构架						
16 (8层卷积层+8层反卷积层)	5	1234	0.0001	500	0.5	1

2.4 预测效果验证

基于结构相似性 (SSIM) 的图像质量评估算法是一种全参考指标, 通过比较图像的亮度、对比度和结构信息来计算相似性, 适合于图像之间的相似度计算。SSIM 的取值范围为[0,1], 数值越接近 1, 相似度越高^[15]。将验证数据集中的 10 组平面布局方案输入训练好的冬季和夏季风场预测 CGAN 模型, 并计算预测图像与模拟图像的 SSIM 相似度 (表 6)。结果显示, 预测图像与模拟结果的相似度高, 且预测时间仅为 1 秒, 大大提高了效率。

表 6 风场预测 CGAN 模型 SSIM 值计算结果

	测试方案编号									
	1	2	3	4	5	6	7	8	9	10
冬季风场预测CGAN模型	0.88	0.89	0.84	0.86	0.86	0.88	0.89	0.88	0.85	0.86
夏季风场预测CGAN模型	0.90	0.90	0.91	0.85	0.88	0.91	0.90	0.92	0.91	0.91
预测时长/s	1	1	1	1	1	1	1	1	1	1

3 测点风速预测模型

测点风速与测点的各类特征 (如其在居住区内的位置、周围建筑的围合情况、与周边建筑的距离等) 之间存在复杂关系。鉴于此, 本文采用人工神经网络 (ANN) 进行测点风速预测模型的搭建和训练。

3.1 基于遗传算法 (GA) 优化的反向传播 (BP) 神经网络

BP 神经网络因其简单结构、丰富的可调参数和良好的操作性被广泛应用^[16]。然而, 传统 BP 神经网络存在学习收敛慢、难以保证全局最优解、网络结构难以确定等问题。此外, 网络结构、初始权值和阈值的选择对训练效果有显著影响, 但这些参数难以准确获取。为解决这些问题, 本文采用遗传算法对 BP 神经网络进行优化。遗传算法在优化人工神经网络方面已被多个研究验证, 如 Le Thi Le 等^[17]的研究表明, 遗传算法相比其他优化算法, 能获得更好的拟合结果和较小的误差。

本文的优化流程如图 5 所示, 主要步骤包括: 确定 BP 神经网络结构、使用遗传算法优化权值和阈值、进行网络训练和预测。BP 神经网络结构根据样本的输入输出参数数量确定, 以决定遗传算法优化的参数数量和种群编码长度。遗传算法的目标是确定最佳初始权值和阈值^[18]。最终, 本文建立了一个包含输入层、隐含层和输出层的 BP 神经网络, 初始权值和阈值通过遗传算法优化获得。

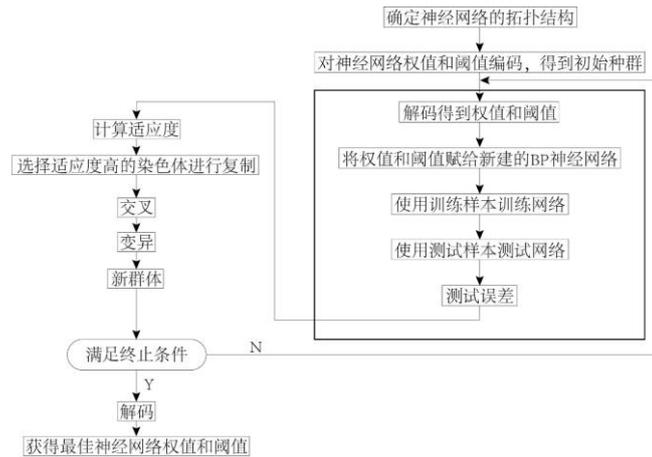


图 5 基于遗传算法 (GA) 优化的反向传播 (BP) 神经网络流程图 (图片来源: 作者自绘)

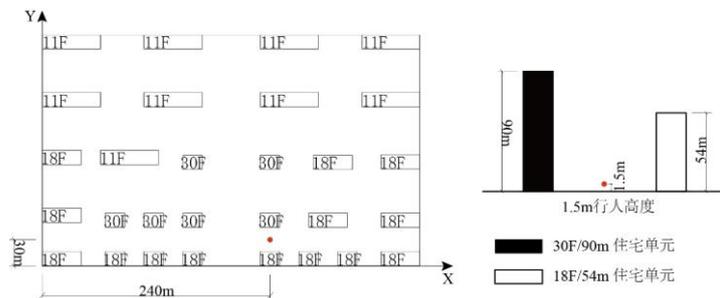


图 6 测点特征表达示意图 (图片来源: 作者自绘)

3.2 数据集准备及隐含层中的神经元数量

本节对前文建立的人工布局和冬夏季风环境模拟数据进行量化。测点优先选择住区中庭和楼栋间宽敞区域等人流量大的代表性区域。测点特征表达如图 6 所示, 以居住区左下角为原点建立坐标系, X轴为东西向, Y轴为南北向, 位置由2个坐标特征值确定。研究关注1.5m行人高度的风速^[9], 因此测点高度均定为1.5m。此外, 统计测点北、南、西、东4个方向的建筑高度作为围合情况的4个特征值。每个测点由6个特征值表示, 1.5m高度的风速为唯一目标值。以图 6测点夏季为例, 其特征和目标值如表 7所示。

表 7 测点特征值表达

特征1: 建筑高度 (北) (单位: m)	特征2: 建筑高度 (南) (单位: m)	特征3: 建筑高度 (西) (单位: m)	特征4: 建筑高度 (东) (单位: m)	特征5: X轴 (单位: m)	特征6: Y轴 (单位: m)	目标值: 风速 (单位: m/s)
90	54	0	0	240	30	2.08

本研究将449组样本随机分为训练集 (80%) 和测试集 (20%), 并将数据归一化至[0,1]范围。使用 MATLAB 2023a构建神经网络, 通过调整隐藏神经元数量进行训练。结果表明, 随着神经元数量增加, 网络稳定性提高, 其中隐含层包含14个神经元的模型表现最佳 (见图 7)。

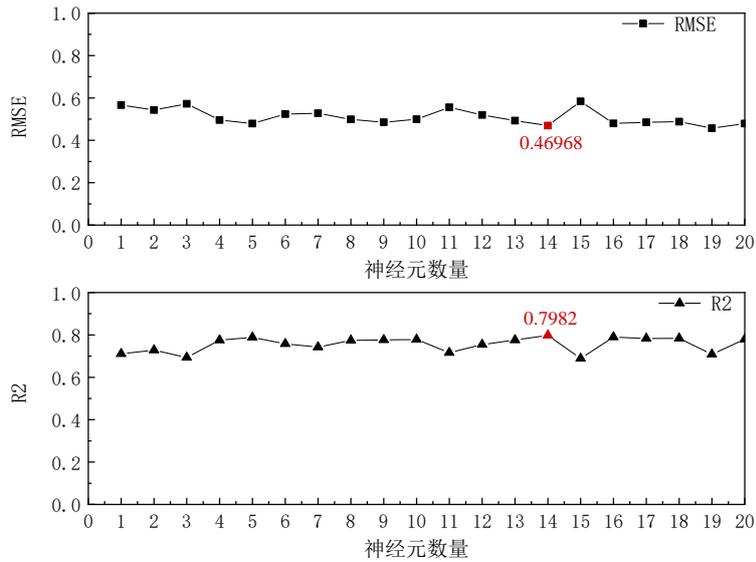


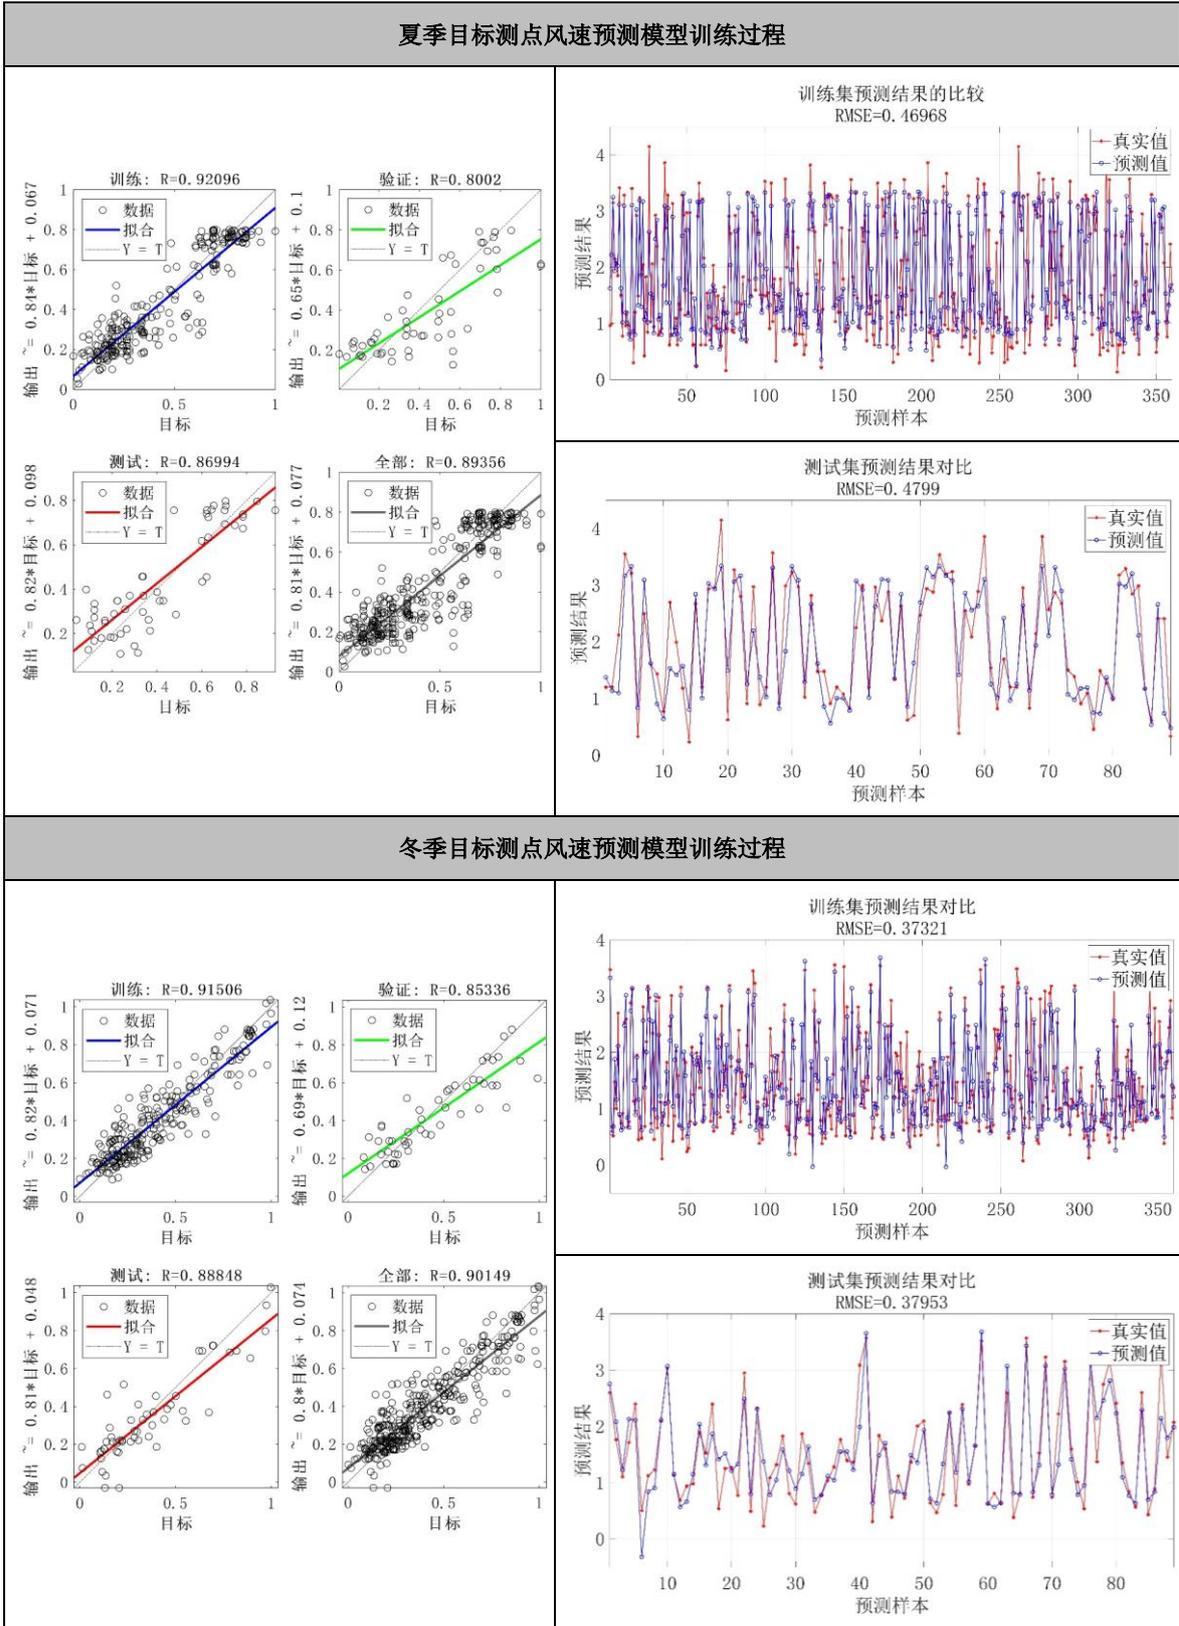
图 7 不同隐藏神经元数量训练效果对比 (图片来源: 作者自绘)

3.3 测点风速预测模型训练过程及预测结果验证

基于遗传算法 (GA) 优化的反向传播 (BP) 神经网络的训练过程及结果如表 8。R 值用于衡量输入与目标之间的相关性, R 值越接近 1, 预测精度越高。结果显示, 在各次拟合中, 37.5% 的 R 值达到 0.9 及以上, 50% 的 R 值达到 0.85 及以上, 数据关联性较强; RMSE 均在 [0.1, 1] 之间, 表明冬夏两季测点风速预测模型均达到了良好的训练效果。

将 10 组验证数据导入训练完成的神经网络模型, 以预测结果与 Phoenics 软件模拟结果比较来验证神经网络的准确性, 验证结果如图 8。结果表明, 基于 GA 优化的 BP 神经网络训练完成的测点风速预测模型能够达到和模拟软件计算结果误差较小的预测效果。

表 8 冬夏两季测点风速预测模型训练过程



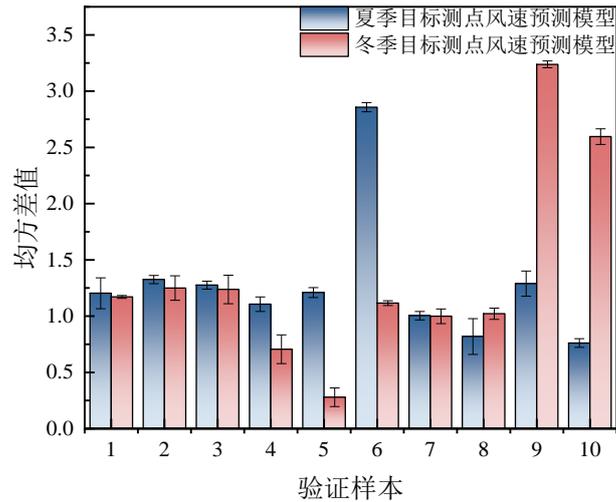


图 8 冬夏两季测点风速预测模型预测效果验证 (图片来源: 作者自绘)

结语

本文利用神经网络建立预测模型, 实现了在有限误差范围内两个维度风环境的快速预测。首先, 基于开源平台, 采用 CGAN 构建并训练风场预测模型, 通过制作数据集、搭建生成器和鉴别器网络, 并调整参数, 最终模型能快速准确生成性能模拟图像。其次, 基于 MATLAB 平台, 利用遗传算法优化 BP 神经网络的初始权值和阈值, 通过神经网络拟合测点特征与风速目标值, 最终模型能够快速准确预测测点风速。

实验结果证明:

- (1) 条件生成对抗网络 (CGAN) 在图像生成方面表现优异, 能够在有限误差范围内快速生成性能模拟图像, 具有良好的前景和实用价值;
- (2) 测点周围空间围合情况与风速之间存在显著关联, 通过 BP 神经网络拟合可有效描述测点位置和围合情况的特征值与风速值之间的关系, 实现风速的快速准确预测;
- (3) 两个维度的预测模型可从宏观和微观两个角度优化和调节住区风环境, 在方案初期具有较强的实用价值。

本研究基于类型学原理搭建用于模型训练的基础数据库具有一定局限性: 首先, 训练数据来自于杭州市典型点板混合式住区, 所以预测模型仅与点半混合式住区适配度较高。其次, 训练数据集中的布局方案基于一些具有代表性的条件设定, 如固定地块、有限的容积率和建筑密度范围以及固定的建筑高度组合等, 因此风环境预测结果并不完全适配于任意住区布局。但本文提供的两种风环境预测工具均能表现建筑高度分布与风环境之间的强关联性, 可为不同地块建筑布局的高度分布从风环境角度提供优化参考。

参考文献

- [1] Ping H. Numerical simulation of air flow in a urban area with regularly aligned blocks[J]. Journal of Wind Engineering and Industrial Aerodynamics, 1997, Volumes 67–68:281-291.
- [2] Murakami Shuzo. Current status and future trends in computational wind engineering[J]. Journal of Wind Engineering and Industrial Aerodynamics, 1997, Volumes 67–68:3-34.
- [3] 李井海, 高菲, 曾黎. 基于CFD的城市风环境模拟与应用研究[J]. 智能城市, 2019,5(01):1-3.
- [4] T N. Collective Construction Modeling and Machine Learning: Proc 35th e CAADe Conference- Volume 2. Rome: e CAADe Press[C], 2017.
- [5] Swahn E. Markovian Drift-Iterative substitutional synthesis of 2D and 3D design data using Markov models of source data[D]., 2018.
- [6] Li Z, Lin B, Zheng S, et al. A review of operational energy consumption calculation method for urban buildings[C], 2020. Springer, 2020.
- [7] 季云竹, 姚佳伟, 郝桐平, 等. 基于机器学习与环境性能优化导向的住区智能生成方法研究[J]. 建筑技艺, 2023,29(07):70-74.
- [8] 朱姝妍, 马辰龙, 向科, 等. 面向方案阶段能耗主导的建筑性能快速优化方法[J]. 建筑师, 2021(06):69-76.
- [9] Lu Y, Wu W, Geng X, et al. Multi-Objective Optimization of Building Environmental Performance: An Integrated Parametric Design Method Based on Machine Learning Approaches: Energies[Z]. 2022: 15.
- [10] 中华人民共和国住房和城乡建设部. 《建筑设计防火规范》GB50016—2018[S]. 北京: 中国计划出版社, 2018.
- [11] 中华人民共和国住房和城乡建设部. 《城市居住区规划设计标准》GB50180-2018[S]. 北京: 中国建筑工业出版社, 2018.
- [12] 中国气象局气象信息中心气象资料室. 中国建筑热环境分析专用气象数据集[M]. 中国建筑工业出版社, 2005.
- [13] Kubota T, Miura M, Tominaga Y, et al. Wind tunnel tests on the relationship between building density and pedestrian-level wind velocity: Development of guidelines for realizing acceptable wind environment in residential neighborhoods[J]. Building and environment, 2008,43(10):1699-1708.
- [14] Chang C, Meroney R N. Concentration and flow distributions in urban street canyons: wind tunnel and computational data[J]. Journal of wind engineering and industrial aerodynamics, 2003,91(9):1141-1154.
- [15] 陈森. 图像质量评估算法及其应用研究[D]. 西安电子科技大学, 2018.
- [16] Feng Y, Liu Y, Wang X, et al. Performance prediction and optimization of an organic Rankine cycle (ORC) for waste heat recovery using back propagation neural network[J]. Energy Conversion and Management, 2020,226:113552.
- [17] Le L T, Nguyen H, Dou J, et al. A Comparative Study of PSO-ANN, GA-ANN, ICA-ANN, and ABC-ANN in Estimating the Heating Load of Buildings' Energy Efficiency for Smart City Planning: Applied Sciences[Z]. 2019: 9.
- [18] Li N, Yu W, Li B Z. Assessing Adaptive Thermal Comfort Using Artificial Neural Networks in Naturally-Ventilated Buildings[J]. INTERNATIONAL JOURNAL OF VENTILATION, 2012,11(2):205-217.
- [19] 石邢, 李艳霞. 面向城市设计的行人高度城市风环境评价准则与方法[J]. 西部人居环境学刊, 2015,30(05):22-27.