

# 基于卷积神经网络的室外热环境快速评估方法研究

黎贻森<sup>1</sup>, 冯锦滔<sup>2</sup>, 钟国栋<sup>3</sup>, 许雪松<sup>4</sup>, 袁磊<sup>5</sup>

## 摘要:

在城市化进程中, 室外热环境评估对于优化城市生活质量至关重要, 由于现场测量、数值模拟耗时耗力, 不能满足快速评估的要求。为提高热环境模拟评估的效率, 本研究利用卷积神经网络模型, 对夏至日下午 2 点的室外空气温度 (T)、相对湿度 (RH) 及平均辐射温度 (MRT) 进行快速预测。研究方法以 Vgg-net 为基础, 使用预训练+微调 (Pre-training+Fine-tuning) 方法, 构建了逐点计算的卷积神经网络, 还探索了单任务学习与多任务学习对性能的影响。结果显示, 模型能够实现对于抽象案例及真实案例热环境的快速预测, 预测  $R^2$  (决定系数) 均达到 0.9 以上。此外, 多任务学习的模型能进一步学习到多变量之间的关系。本研究提出的基于卷积神经网络的逐点热环境预测模型, 大大提高了城市街区热环境评估效率。

**关键词:** 热环境; 神经网络; 快速预测; 预训练+微调

**Keywords:** Thermal environment; Neural networks; Rapid prediction; Pre-training+Fine-tuning

## 引言

城市热环境对人的健康和热舒适性有显著影响。多项研究指出, 长期暴露在恶劣的城市热环境中可能导致多种健康问题, 甚至危及生命安全<sup>(1,2)</sup>。例如, 城市热岛效应是其中一个主要因素, 它会导致城市热环境恶化, 提高城市温度, 降低室外热舒适性。

传统的城市热环境评价方法包括现场测量<sup>(3,4)</sup>、数值模拟<sup>(5,6)</sup>等, 但传统方法容易受到时间、人力成本和实验空间的限制。现场测量是一种在自然环境或城市环境中进行的直接测量技术。例如, Marialena 等人<sup>(7)</sup>为了研究微气候条件如何影响地中海气候下城市开放空间的使用, 通过便携式微型气象站进行了长达半年时间的现场测量。数值模拟是一种使用计算机模型来模拟和分析城市或特定环境中的微气候现象的方法。数值模拟中常用的方法之一是计算流体力学 (CFD), 然而 CFD 模拟需要使用者具备一定的专业知识, 其具有建模复杂和计算成本高的缺陷, 而且模拟的准确性受到模型假设、初始输入参数和模型分辨率的影响<sup>(8)</sup>。

既有研究<sup>(9-15)</sup>不断证明使用数据驱动方法预测城市热环境能够在保持一定精度的同时达到快速预测的效果。针对热环境快速预测的过程探索了各种基于数据驱动的代理模型, 包括人工

1 黎贻森, 深圳大学建筑与城市规划学院、深圳市建筑环境优化设计研究重点实验室, 学生

2 冯锦滔, 深圳市建筑环境优化设计研究重点实验室、深圳大学建筑设计研究院有限公司, 中级工程师

3 钟国栋, 深圳大学建筑与城市规划学院、深圳市建筑环境优化设计研究重点实验室, 学生

4 许雪松, 深圳市建筑环境优化设计研究重点实验室、深圳大学建筑设计研究院有限公司, 高级工程师

5 袁磊 (✉), 深圳大学建筑与城市规划学院、深圳市建筑环境优化设计研究重点实验室, 教授,

yuanlei@szu.edu.cn

神经网络 (ANN)<sup>(9-11)</sup>、随机森林 (RF)<sup>(12-14)</sup> 和生成式对抗网络 (GAN)<sup>(15)</sup>，这些方法只能预测 CFD 流场中有限的一部分，例如，预测物体表面一组点的风速<sup>(9)</sup>。大多数现有方法通常用于处理低维度、线性或非线性关系问题，不擅长处理图像或具有空间结构的输入<sup>(9-11)</sup>，而且需要根据大量良好的数据进行建模。例如，孙全德等人使用 51480 个样本量进行训练<sup>(14)</sup>。

事实证明，卷积神经网络 (CNN) 能够识别空间特征并拟合几何形态与流场之间关系的能力<sup>(16,17)</sup>。卷积层可以显著提高模型对空间特征的分析能力，具有较强的泛化能力，这可能与卷积层参数的“局部连通性、参数共享”等特点有关。一些研究证明了它的有效性，Guo 等人<sup>(17)</sup>使用 CNN 方法构建了汽车横截面流场的近似模型，Tanaka 等人<sup>(18)</sup>使用 CNN 作为 CFD 流场预测方法的替代方案来预测建筑物周围的风环境。

然而，现有的基于 CNN 网络构建代理模型在热环境预测方面存在不足。根据我们团队之前的研究<sup>(19)</sup>，大多数使用卷积神经网络为代理模型的方法是将建筑物形态及其风速、温度、辐射等分布视为图像对象，建立的是图像到图像的模型，模型构建方式是基于空间场和性能场之间的关系。但这样对于数据的利用并不充分。相反，在特定的前提下，通过建立逐点计算的模型，关注测点周边空间与该点性能值之间的联系，可以更充分有效地利用数据集<sup>(20)</sup>。

此外，案例数据集的多样性极大影响了机器学习模型预测结果的准确性。目前关于城市热环境的现有研究数据集通常来源于理想模型<sup>(21)</sup>，或者只针对特定的现实城市形态进行分析<sup>(22)</sup>。在实际应用中，理想化模拟（如长方体阵列）的结果存在难以推广到实际城市环境的问题，而案例研究通常具有很强的地域性。因此，为了提高模型的泛化能力，需要扩大数据集的多样性以及实用性。

热环境是有多个复杂指标共同构成，现有模型一般仅针对单一指标预测<sup>(23,24)</sup>，只专注于单一模型可能会忽略不同指标之间的相互关系，难以全面评估城市热环境。而多任务共同学习可以通过神经网络学习到不同任务之间的共享表征，有助于在相同输入的情况下实现更好的性能<sup>(25)</sup>。

因此，本研究的目的是基于卷积神经网络，构建空气温度 (T)、相对湿度 (RH) 和平均辐射温度 (MRT) 的快速评估模型。本文将从以下几个方面来叙述：（1）首先，通过逐点预测的方法，使用抽象案例数据集分别预训练 T、RH、MRT 的神经网络模型（2）使用微调方法，在获得初步模型后使用真实案例进行微调，提升神经网络模型的泛化能力。（3）对比单任务和多任务学习对街区热环境预测性能的影响。

## 1 研究方法

### 1.1 数据集生成

#### 1.1.1 案例生成方式

本研究的抽象案例集首先通过 Grasshopper 平台随机生成 50 个抽象公共建筑布局。图 1 表示抽象案例具体生成方法，通过边界生成、场地退线、地块划分、划分区块并产生建筑红线、生成建筑等 5 个步骤最终导出 50 个抽象案例数据集。

研究进一步收集从 GIS 中获取深圳市南山区建筑形态、下垫面及道路信息的 50 个真实案例集作为补充训练。




图1 抽象案例生成流程示意图（图片来源：作者自绘）

### 1.1.2 热环境模拟参数设置

项目研究以深圳市南山区作为研究气候背景。我们采用 ENVI-met5.5 对研究案例进行模拟来获得训练集数据。在这项研究中，将 50 个抽象案例和 50 个真实案例为模拟对象，选择夏至日下午 2:00 作为我们的模拟时间，气象参数使用 EPW 输入数据。ENVI-met 模型的设置参数如表 1 所示。

表 1 ENVI-met 输入参数设置（表格来源：作者自绘）

类型	内容	设置
位置	地点	深圳市南山区
	日期	2023 年 6 月 23 日
时间日期	开始时间	06:00
	总模拟时间	12 小时
	10 米高度风速	2.5m/s
初始气象条件	风向	正北向
	粗糙度长度	0.100
笛卡尔坐标网格	网格数量	105×116×49
	单元格尺寸	3×3×3m

### 1.2 模拟设置及数据收集

几何模型和材料物理信息输入到神经网络模型需进行转译。常用的几何模型有很多种表示方法，如 NURBS 方法，点云法等；而材料物理信息则包含密度、比热容、传热系数等变量。为简化几何输入同时保留不同下垫面对热环境的影响作用。研究拟采用建筑高度、反照率（Albedo）、透射率(Transmissivity)矩阵作为输入，均基于笛卡尔坐标系构建，如图 2 所示。

建筑高度矩阵以 3 米为精度，网格数量为 105×116，建筑所在格点表示为所在建筑的高度，无建筑的格点高度为 0，形成二维矩阵，维度为 (105×116)。下表 2 为下垫面反照率、透射率设置参数，反照率矩阵和透射率矩阵与建筑高度矩阵相同设置，下垫面格点取对应材质的反照率或透射率。默认下垫面及建筑所在的网格定义为裸土，反照率取值为 0，形成二维矩阵，矩阵维度为 (105×116)。最后，将建筑高度、下垫面反照率和透射率矩阵组合形成神经网络训练数据集。

表 2 下垫面反照率、透射率设置（表格来源：作者自绘）

	裸土	沥青路面	混凝土路面	草坪
反照率	0	0.12	0.8	0
透射率	0	0	0	0.2




图2 二维矩阵图（图片来源：作者自绘）

### 1.3 网络模型构建

本文中我们提出网络模型是以 VGG 模型<sup>(26)</sup>为基础构建，VGG 是一种在图像视觉领域取得成功的卷积神经网络（CNN）模型，CNN 已被证明比 CFD 求解器快 2 到 4 个数量级<sup>(17)</sup>。相比于 ResNet 和 Inception 等其他 CNN 架构，VGG 模型提供了一个更加简洁且连贯的框架，这使得我们更容易深入探讨卷积层在提升神经网络性能中的关键作用。图 3 所示本研究模型是以 VGG-11 为基础架构，采用的网络模型输入通道数为 3，每个通道都由 5 个块（block）组成，每个块包括卷积层、最大池化层、归一化层和激活函数。我们使用 Pytorch 深度学习框架来训练上述网络。所有的模型均采用 Adam 优化器进行模型参数的优化<sup>(27)</sup>，并将初始学习率设置为 0.0001，epsilon 设定为 1e-5。训练时 batch size 为 32，最大迭代步数设定为 200 次。最终，模型都将在一台配置为 NVIDIA GeForce RTX 4060 显卡的 WINDOWS PC 上进行训练。当损失收敛时，模型停止训练。

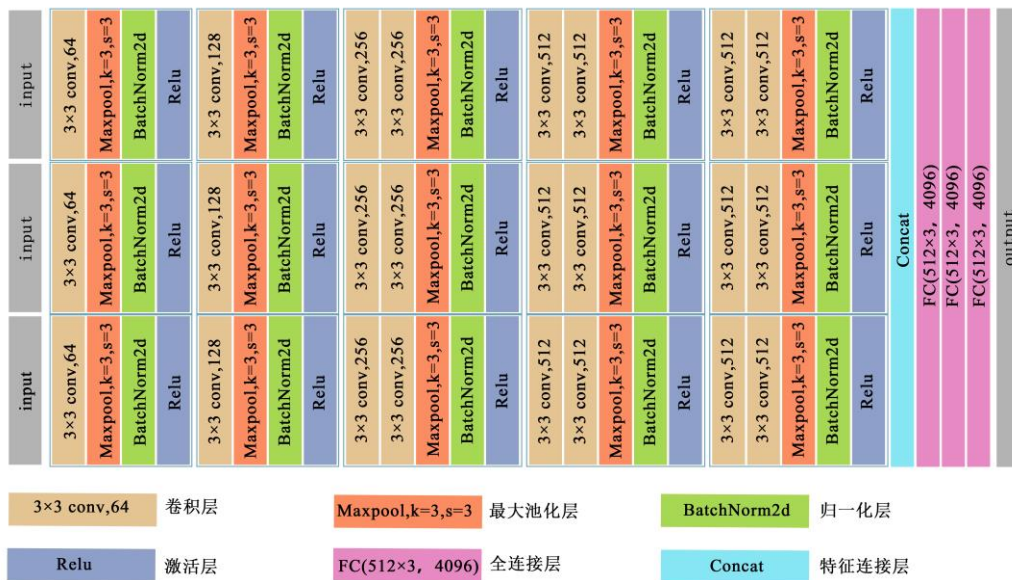


图3 三通道 Vgg-net 模型结构图（图片来源：作者自绘）

### 1.4 模型训练方法

研究采用一种基于 ENVI-met 数据预训练的神经网络模型来预测街区热环境参数分布情况。模型训练主要包含预训练与微调两个主要部分，训练流程如下图 4 所示：

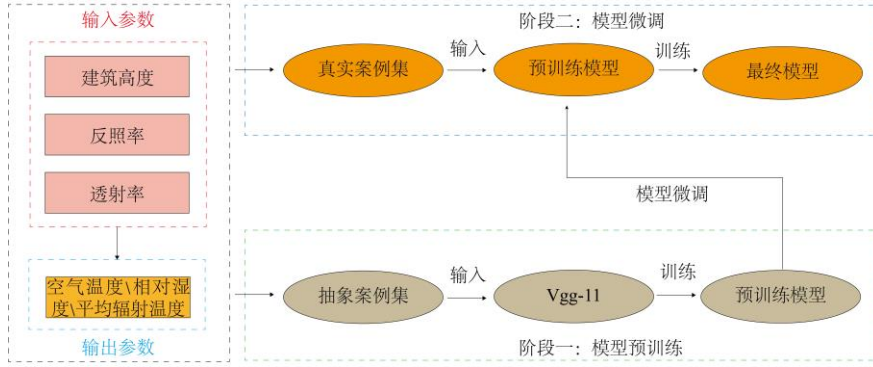


图4 预训练+微调流程图（图片来源：作者自绘）

#### 1.4.1 模型预训练流程

该流程的主要目标是使用抽象案例数据集对神经网络模型进行训练，获得预训练模型。首先，通过 ENVI-met 软件对抽象案例数据集进行模拟，以获取模拟温度（T）、湿度（RH）、平均辐射温度（MRT）等数据。通常情况下，ENVI-met 软件模拟的数据能够反映理想条件下建筑室外的热环境。接下来，将 T、RH、MRT 等模拟数据输入 VGG-net 进行训练。通过这一过程，预训练模型能够学习室外建筑热环境的分布规律，并预测理想建筑布局情况下的 T、RH、MRT 等参数。该流程可以减少在现实建筑布局过于复杂的情况下导致的热环境分布规律不明显问题，减少了模型需要的样本数量。然后，预训练模型可以用于微调流程的再训练。

#### 1.4.2 模型微调流程

该流程的主要目标是使用真实案例数据对预训练中获得的模型进行微调。在预训练阶段，模型通过学习抽象案例数据集，获取了建筑布局和热环境之间的关联。但是，由于抽象案例和真实案例之间仍存在一定程度的误差，并不能准确的描述真实的建筑室外热环境分布。因此，有必要添加一个微调步骤。通过微调可以利用真实的建筑案例数据集继续训练神经网络模型来调整参数，从而提高模型的泛化能力。

#### 1.5 神经网络不同任务学习设置

为对比不同任务学习设置导致的性能差异，研究采用了两种设置方式：单任务学习，多任务学习。

单任务学习是将 T、RH、MRT 分别单独训练一个 VGG-net 卷积神经网络模型。而多任务学习则通过编码方式的改变将这三个参数合并训练成一个神经网络模型，使其能够同时预测这三个参数。但由于不同变量存在不同量纲，因此在进行多个不同量纲训练技术处时需要不同变量进行归一化。研究通过将 T、RH、MRT 标定在一定范围，将具体数值变成无量纲的比例数值，消除了不同量纲之间的影响。具体方法如下：

对于输入数据：

$$T_{norm} = \frac{T - T'}{T'' - T'} \quad (1)$$

$$RH_{norm} = \frac{RH - RH'}{RH'' - RH'} \quad (2)$$

$$MRT_{norm} = \frac{MRT - MRT'}{MRT'' - MRT'} \quad (3)$$

其中，T、RH、MRT是输入数据原始值，T'、RH'、MRT'分别为经验常量温度、湿度、平

均辐射温度的最小原始输入参数， $T''$ 、 $RH''$ 、 $MRT''$ 是经验常量值最大原始输入参数。 $T_{norm}$ 、 $RH_{norm}$ 、 $MRT_{norm}$ 是归一化后的输入参数。

对于输出数据：

在模型输出之后，需要将归一化过的结果还原回原始的温度、湿度以及平均辐射温度，以便最终结果能在实际应用中具有可解释性和实用性。公式如下所示：

$$T_{pre} = T_{norm}(T'' - T') + T' \quad (4)$$

$$RH_{pre} = RH_{norm}(RH'' - RH') + RH' \quad (5)$$

$$MRT_{pre} = MRT_{norm}(MRT'' - MRT') + MRT' \quad (6)$$

其中 $T_{pre}$ 、 $RH_{pre}$ 、 $MRT_{pre}$ 是归一化还原后的温度、湿度、平均辐射温度值。

## 2 结果与分析

### 2.1 模型评估指标

为了评估模型的有效性，使用决定系数（ $R^2$ ）及均方根误差（RMSE）对各模型的精度进行横向对比。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (8)$$

其中  $n$  是样本数量， $y_i$  是观测到的目标值（真实值）， $\hat{y}_i$  是模型对第  $i$  样本的预测值， $\bar{y}$  是观测到的目标值的平均值。

### 2.2 预训练模型验证

我们使用一个不属于训练集的案例对预训练模型进行验证，表 3 和附录图 A 显示了验证抽象案例和真实案例的预测结果，相对误差显示了预测值和真实值之间的差异。从抽象案例可视化结果来看， $T$  和  $RH$  的预测结果与 ENVI-met 模拟结果相似，但在建筑周边、相邻建筑间和尾流区域出现了预测误差。 $MRT$  的预测效果较差，尤其是建筑阴影区域和低层建筑预测的部分，因为训练案例集中低层建筑数量较少，以及我们在设置训练案例集 ENVI-met 单元格大小为  $3 \times 3m$  过大的原因。从真实案例可视化结果来看，预训练模型对真实案例的预测精度较低，说明预训练模型对于真实的复杂布局适应性不良，不能很好的预测真实建筑布局下热环境参数分布情况。由此也表明，使用对于真实案例的微调步骤，提高模型对于真实案例的预测精度的必要性。

表 3 预训练模型的预测结果对比（表格来源：作者自绘）

	抽象案例		真实案例	
	RMSE	$R^2$	RMSE	$R^2$
T	0.20	0.9998	1.27	0.9892
RH	0.47	0.9994	3.37	0.9684
MRT	2.34	0.9869	9.59	0.7574

### 2.3 微调后模型验证

我们在预训练模型基础上，使用了 50 个真实案例进行微调，训练使用的超参数设置不变。表 5 和图 5 显示了模型微调前后的真实案例验证结果对比。研究表明：（1）微调显著提高了对真实案例的预测精度。相较于微调前，真实案例的 T、RH、MRT 的 RMSE 均有降低， $R^2$  均有提升。（2）微调后，抽象案例中 T、RH、MRT 的 RMSE 有所上升， $R^2$  有所下降，表明真实案例微调后模型对抽象案例的预测性能会有降低。（3）微调后的模型中真实案例与抽象案例的预测结果相比，真实案例 T、RH、MRT 的预测精度都比抽象案例略差，其中一个原因是真实案例的建筑布局更为复杂，即使通过微调能提升模型性能，但对复杂案例的信息处理和规律学习能力仍有待加强。

表 5 微调前后各模型预测结果对比（表格来源：作者自绘）

		微调前		微调后	
		RMSE	$R^2$	RMSE	$R^2$
T	真实	1.27	0.9892	0.67	0.9968
	抽象	0.2	0.9998	0.6	0.9978
RH	真实	3.37	0.9684	1.05	0.9973
	抽象	0.47	0.9994	0.93	0.9978
MRT	真实	9.59	0.7574	5.52	0.9069
	抽象	2.34	0.9869	2.79	0.9803




图 5 微调前后各模型预测结果对比：图 (a) RMSE；图 (b)  $R^2$ （图片来源：作者自绘）

附录图 B 展示了模型微调后对 T、RH、MRT 的预测可视化结果，并通过相对误差分析来比较预测结果与 ENVI-met 模拟结果之间的差异。可以发现：（1）模型在建筑周边和建筑之间的温度、湿度场预测仍存在不足，微调虽提升了预测精度，但改进效果有限，需要增加更多此类案例以提高模型性能。（2）MRT 的预测精度较低，主要在于建筑阴影区域，尤其是针对低层建筑。这一现象的原因包括建筑形状复杂且布局丰富，以及训练案例集中单元格设置过大（ $3 \times 3m$ ）导致模型无法捕捉到周围环境的细节，特别是在建筑阴影区域。低层建筑与周围环境接触更为紧密，过大的网格单元进一步减弱了 MRT 模型捕捉低层建筑微观特征的能力。

因此，研究采用的预训练+微调训练流程能很好的提升模型对于建筑布局的热环境预测能

力。虽然在模型进行微调后会降低对抽象案例的精度，但能提高模型对真实复杂案例的预测能力。

### 2.4 不同任务学习设计的实验结果与分析

表 6、图 6、附录图 C1 和图 C2 展示了单模型不同任务学习 T、RH、MRT 的可视化结果。观察结果发现：（1）在多任务学习的 T 和 RH 相对误差图中，误差位置相似，因为多任务学习模型共享底层卷积层的特征学习，通过共享这些特征，模型能更好地学习数据中的共同模式，提高整体性能。（2）多任务学习方法的 T、RH 预测性能高于单任务学习方法，MRT 略有降低。这可能因为热环境指标 T、RH、MRT 存在相互影响，多任务学习设置的神经网络模型能更好地体现不同性能指标之间的关系，而单任务学习模型则无法做到这一点。

因此，多任务学习设置能够更好地理解多变量之间的关联性，提高预测精度。此外，多任务学习方法中模型大小与单任务学习方法相近，但训练及预测时间仅为单任务学习方法的 1/3，具有较高的效率。

表 6 不同任务学习模型的性能（表格来源：作者自绘）

		单任务学习		多任务学习	
		RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>
T	真实	0.67	0.9968	0.50	0.9982
	抽象	0.60	0.9978	0.47	0.9987
RH	真实	1.05	0.9973	0.97	0.9977
	抽象	0.93	0.9978	0.88	0.9980
MRT	真实	5.52	0.9069	5.81	0.8981
	抽象	2.79	0.9803	2.81	0.9804




图 6 单模型不同任务学习预测结果对比：图（a）RMSE；图（b）R<sup>2</sup>（图片来源：作者自绘）

## 3 结论

### 3.1 研究结果

本文提出了基于 VGG 神经网络的数据驱动热环境模型，取代传统的热环境性能模拟，能够



快速评估街区热环境并输出温度、湿度和平均辐射温度。该方法可以以精度小幅下降为代价，在节约大量模拟时间的同时，提高了热环境模拟的效率。

该模型在抽象案例和真实案例预测中表现良好。在验证抽象案例上，预测 T、RH、MRT 的  $R^2$  均在 0.9 以上，在验证真实案例上，预测 T、RH、MRT 的  $R^2$  分别为 0.9892，0.9684，0.7574。验证结果显示，基于 VGG 网络的逐点计算方法能够在热环境领域取得良好结果。

研究采用了预训练+微调的训练方式，通过预训练获得理想建筑布局的热环境预测模型，然后通过真实案例微调获得最终模型。虽然微调后模型在预测理想抽象模型时性能略有下降，但在预测复杂真实案例时性能有较大提升。这证明了预训练+微调的预测方法能简化复杂问题，并提高神经网络对复杂布局的适应性。研究还探讨不同任务学习方法对神经网络模型的影响。结果表明，对于存在相关关系的多个变量，采用多任务学习方法能够在预测精度上取得较单任务学习方法提升。而且，多任务学习的方法具有预测时间短、模型体积不变等优点。

### 3.2 局限性和未来工作

本研究促进了使用基于 VGG 神经网络对室外热环境进行评估的方法，模型能实现一定的预测效果。但是，从模型预测图的可视化结果来看，可以观察到预测的最大误差主要集中在建筑的转角、建筑之间的区域，以及尾流区域。为解决这些误差，有必要深入研究更多的参数表达方式，考虑补充该类型空间数据，以便模型能够更好地学习此类空间与热环境分布的关系。此外，本研究中对于 MRT 的预测虽然预测精度较高，但对于阴影部分的预测精度不高，尤其是阴影边缘部分及低层建筑部分。由于研究采用的案例容积率较高，建筑主要以中高层建筑为主，缺乏低层建筑案例，过于集中的建筑高度可能使网络无法准确判断建筑高度与阴影范围之间的关系。后续研究可以尝试对训练案例进行补充，降低由于案例缺失带来的影响。

## 5. 附录

### 附录 A

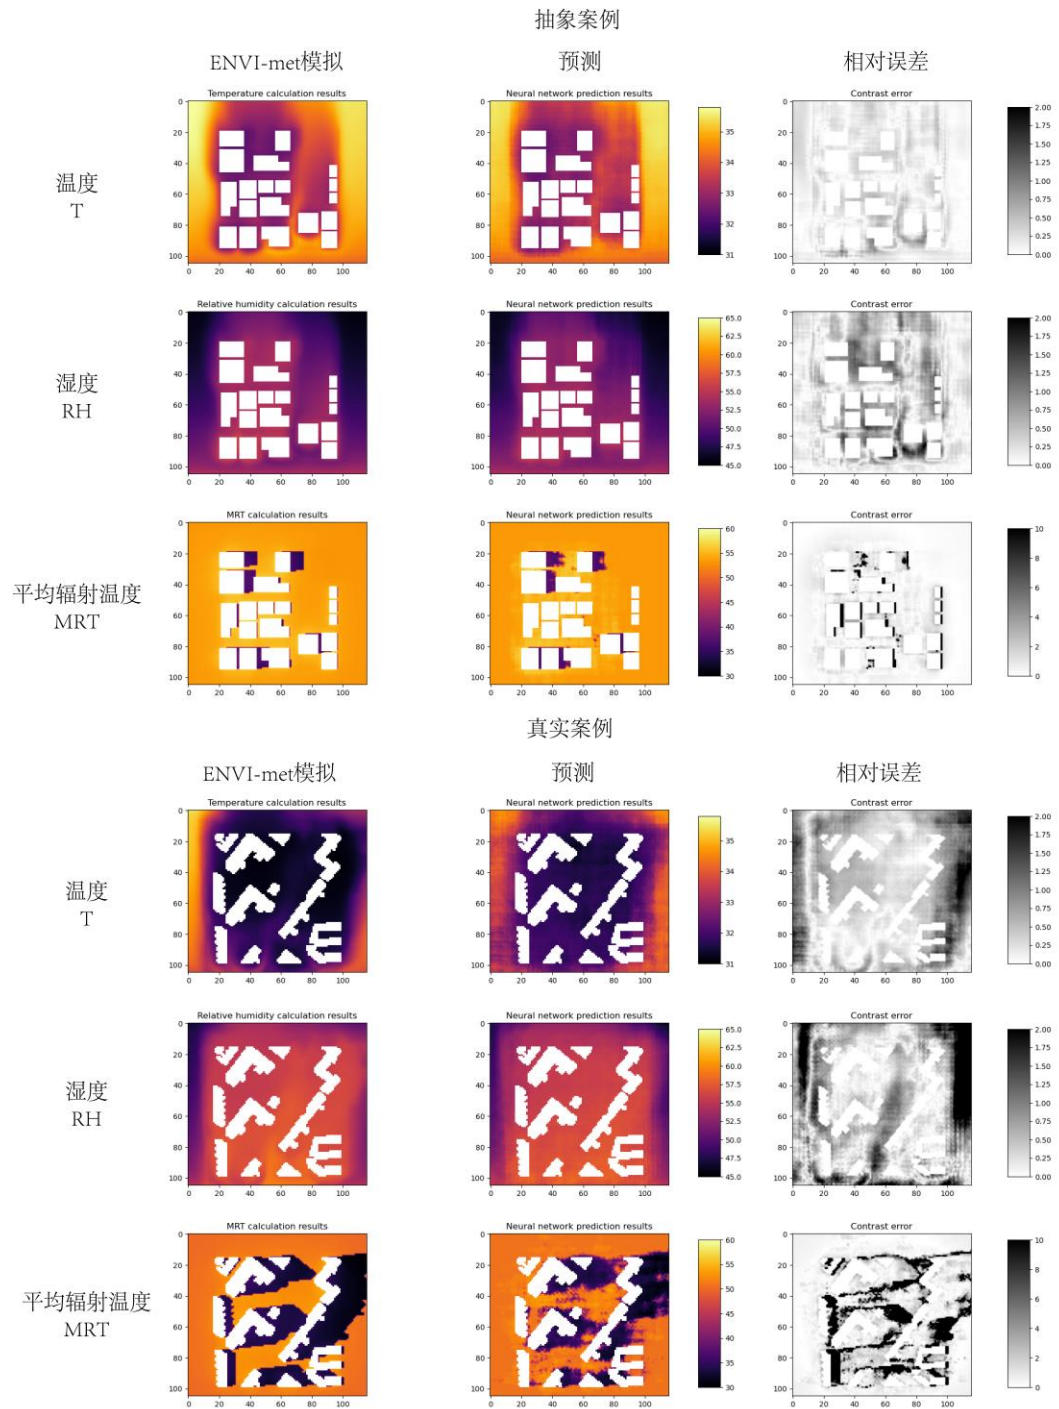


图 A 抽象案例、真实案例 T、RH、MRT 的预测结果可视化（图片来源：作者自绘）

## 附录 B

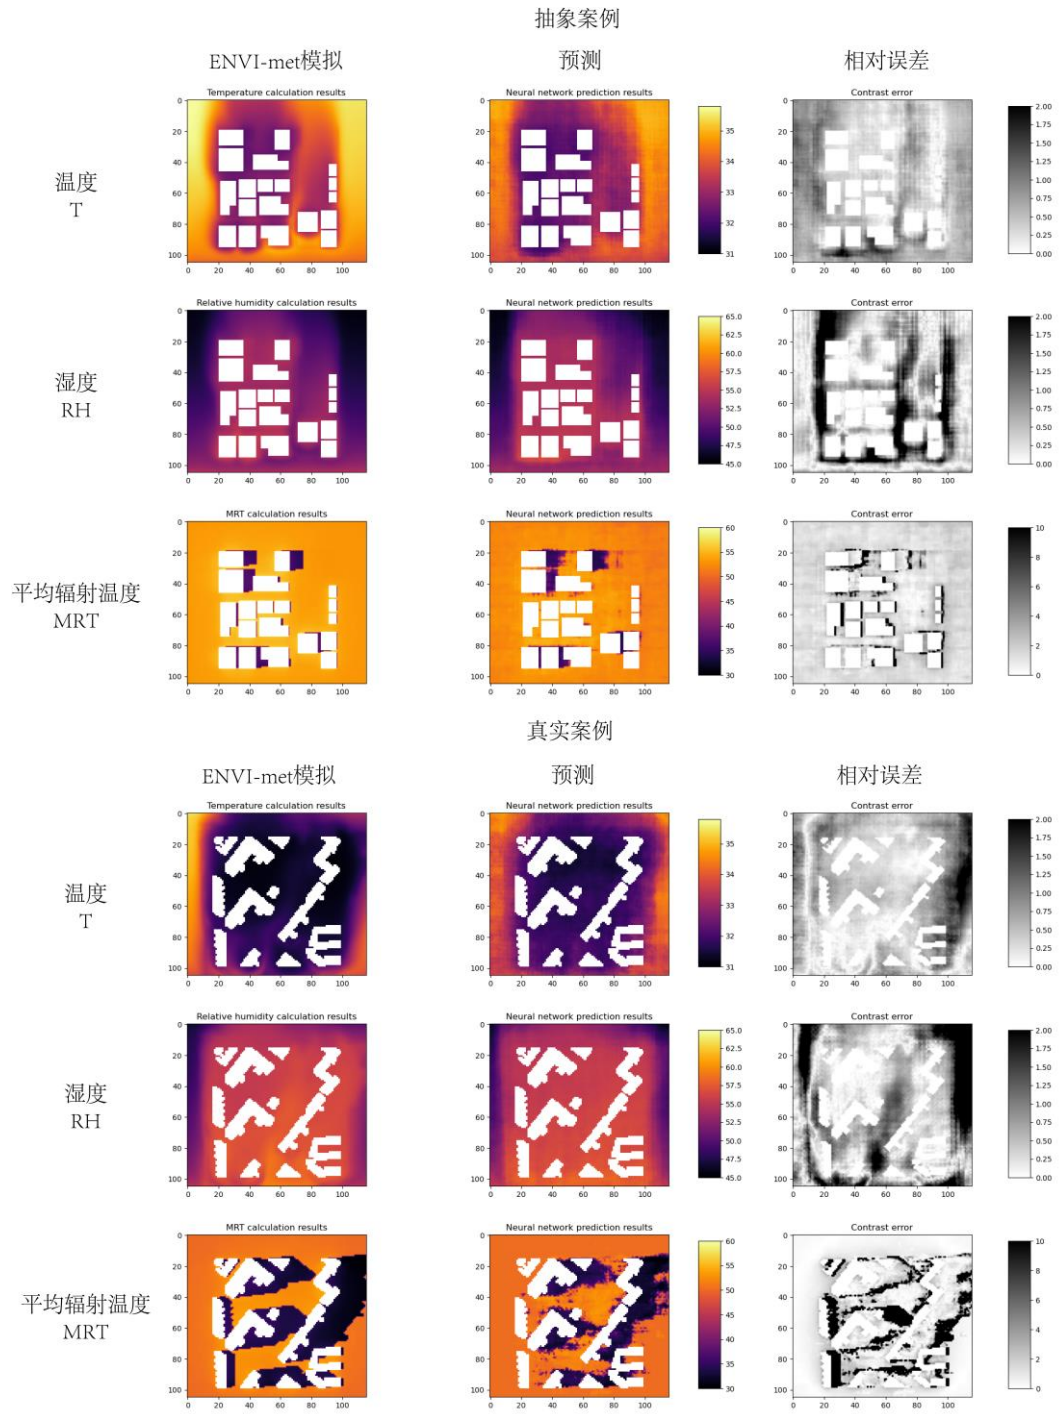


图 B 微调后抽象案例、真实案例 T、RH、MRT 的预测结果（图片来源：作者自绘）

## 附录 C

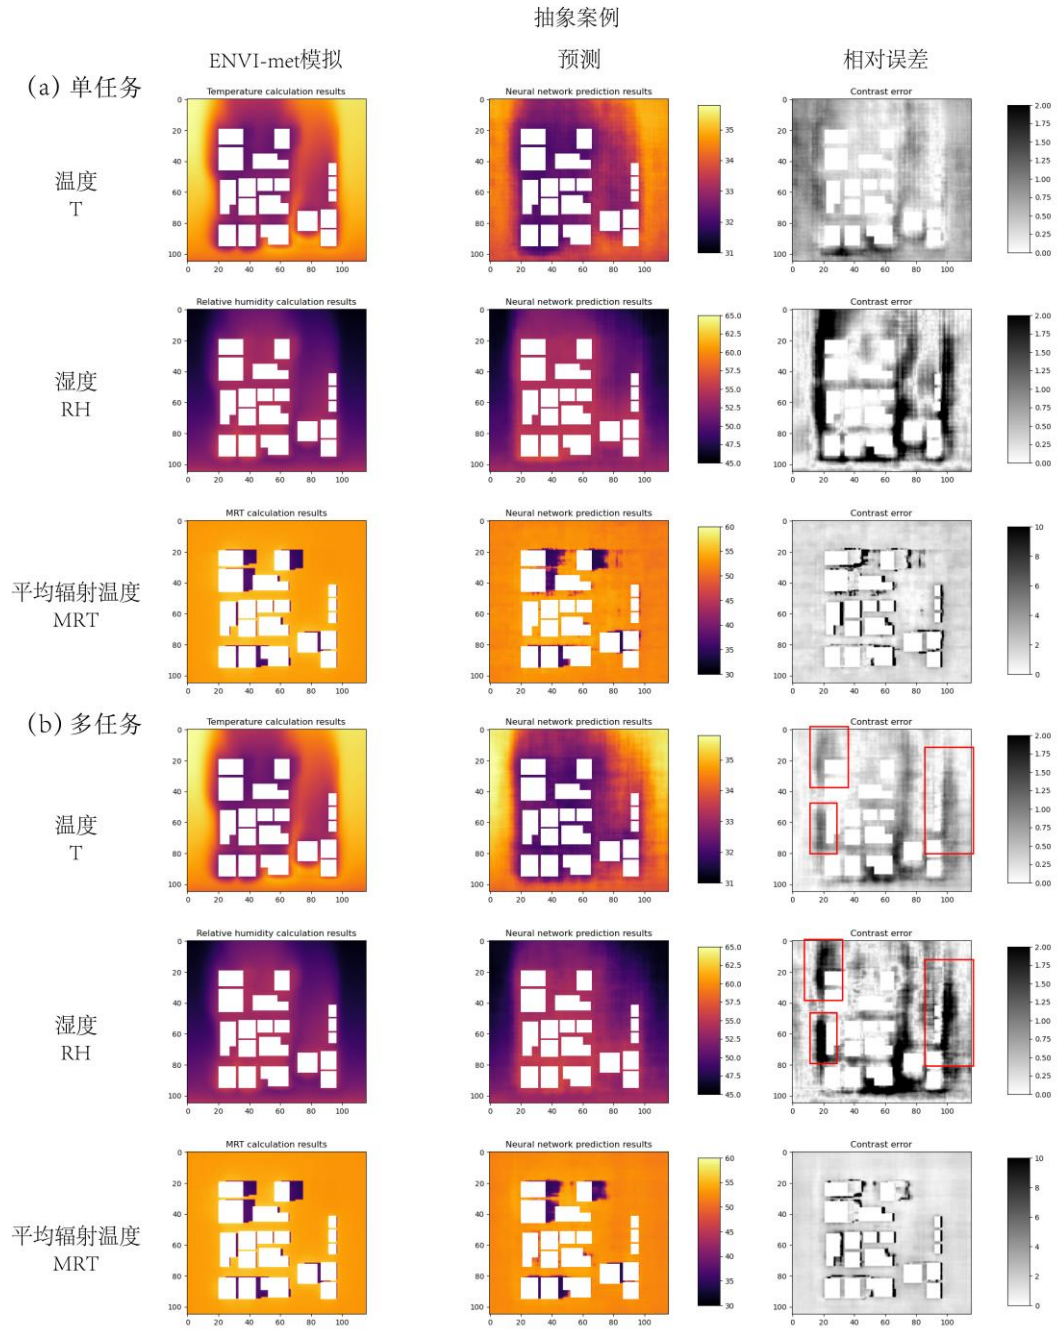


图 C1 抽象案例不同任务学习预测 T、RH、MRT 的比较 (a) 单任务学习 (b) 多任务学习 (图片来源: 作者自绘)

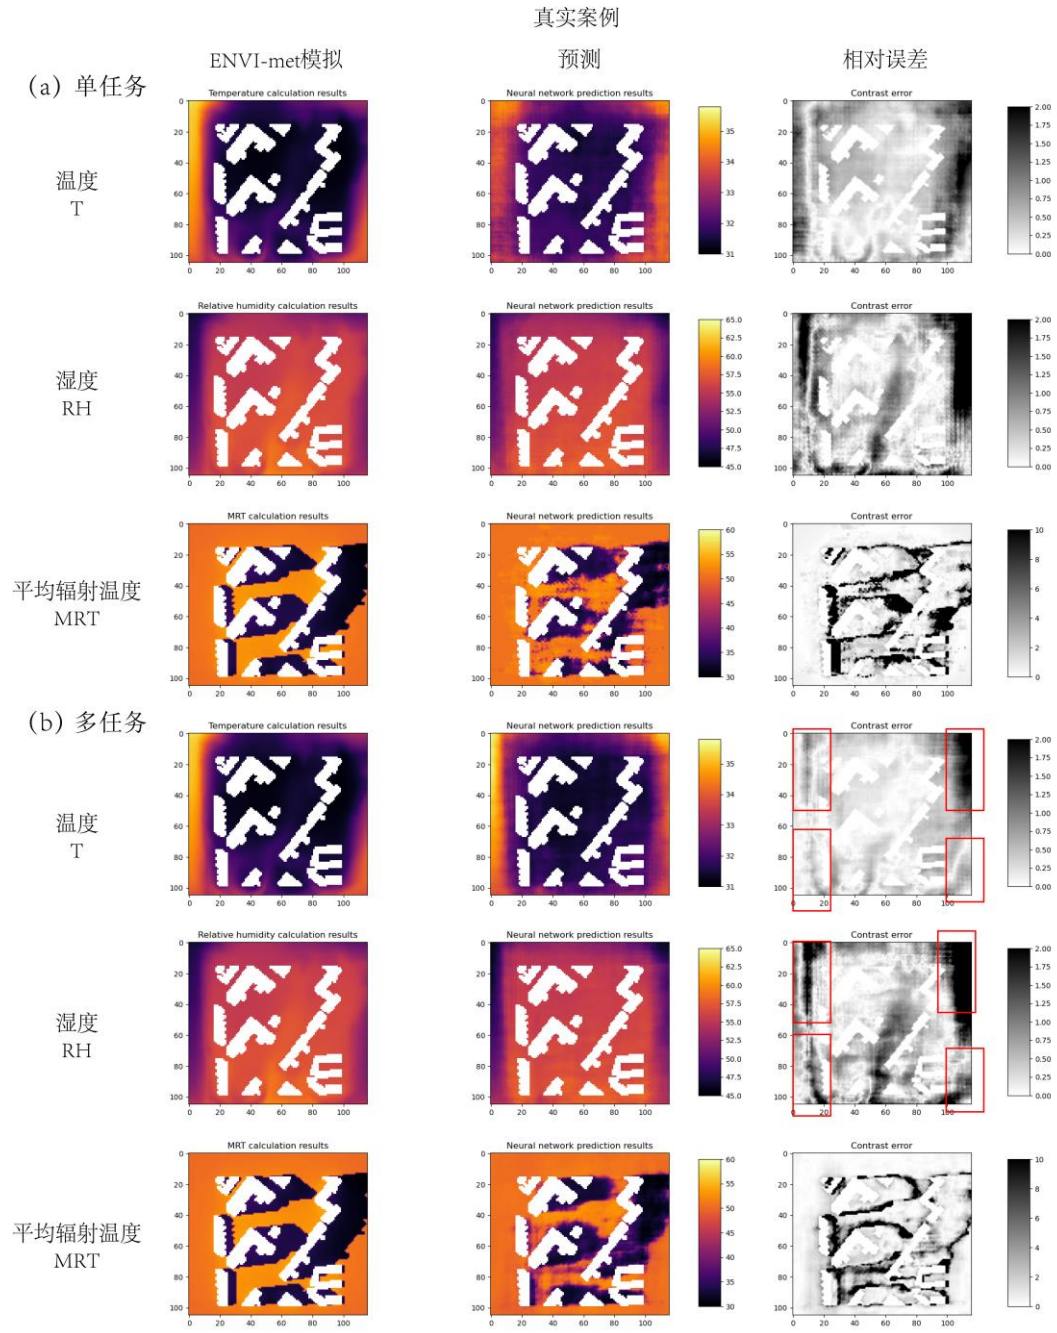


图 C2 真实案例不同任务学习预测 T、RH、MRT 的比较 (a) 单任务学习 (b) 多任务学习 (图片来源: 作者自绘)

## 参考文献

- 1 Horton A, Jones S J, Brunt H. Air pollution and public health vulnerabilities, susceptibilities and inequalities in Wales, UK. *Journal of Public Health*, 2023, 45(2): 432~441
- 2 Kurt O K, Zhang J, Pinkerton K E. Pulmonary health effects of air pollution. *Current Opinion in Pulmonary Medicine*, 2016, 22(2): 138
- 3 Zhang J, Cui P, Song H. Impact of urban morphology on outdoor air temperature and microclimate optimization strategy base on Pareto optimality in Northeast China. *Building and Environment*, 2020, 180: 107035
- 4 Li Y, Wang D, Li S, 等. Impact Analysis of Urban Morphology on Residential District Heat Energy Demand and Microclimate Based on Field Measurement Data. *Sustainability*, 2021, 13(4): 2070
- 5 He X, Gao W, Wang R. Impact of urban morphology on the microclimate around elementary schools: A case study from Japan. *Building and Environment*, 2021, 206: 108383
- 6 Antoniou N, Montazeri H, Neophytou M, 等. CFD simulation of urban microclimate: Validation using high-resolution field measurements. *Science of The Total Environment*, 2019, 695: 133743
- 7 Nikolopoulou M, Lykoudis S. Use of outdoor spaces and microclimate in a Mediterranean urban area. *Building and Environment*, 2007, 42(10): 3691~3707
- 8 许亘昱, 石玉蓉, 张宇峰. 规划控制要素视角下城市热环境的测度与优化——以广州中心城区为例. *热带地理*, 2023, 43(6): 1070~1082
- 9 Wilkinson S, Bradbury G, Hanna S. Reduced-order urban wind interference. *SIMULATION*, 2015, 91(9): 809~824
- 10 Javanroodi K, Nik V M, Giometto M G, 等. Combining computational fluid dynamics and neural networks to characterize microclimate extremes: Learning the complex interactions between meso-climate and urban morphology. *Science of The Total Environment*, 2022, 829: 154223
- 11 Labe Z M, Johnson N C, Delworth T L. Changes in United States Summer Temperatures Revealed by Explainable Neural Networks. *Earth's Future*, 2024, 12(2): e2023EF003981
- 12 Alonso L, Renard F. A New Approach for Understanding Urban Microclimate by Integrating Complementary Predictors at Different Scales in Regression and Machine Learning Models. *Remote Sensing*, 2020, 12(15): 2434
- 13 Oukawa G Y, Krecl P, Targino A C. Fine-scale modeling of the urban heat island: A comparison of multiple linear regression and random forest approaches. *Science of The Total Environment*, 2022, 815: 152836
- 14 孙全德, Quande S U N, 焦瑞莉, 等. 基于机器学习的数值天气预报风速订正研究. *气象*, 2019. ISSN 1000-0526
- 15 Huang C, Zhang G, Yao J, 等. Accelerated environmental performance-driven urban design with generative adversarial network. *Building and Environment*, 2022, 224: 109575
- 16 Socher R, Huval B, Bhat B, 等. Convolutional-Recursive Deep Learning for 3D Object Classification
- 17 Guo X, Li W, Iorio F. Convolutional Neural Networks for Steady Flow Approximation
- 18 Tanaka H, Matsuoka Y, Kawakami T, 等. Optimization Calculations and Machine Learning Aimed at Reduction of Wind Forces Acting on Tall Buildings and Mitigation of Wind Environment. *International Journal of High-Rise Buildings*, 2019, 8(4): 291~302
- 19 Zhong G, Xu X, Feng J, 等. A Convolutional Neural Network for Steady-State Flow Approximation Trained on a Small Sample Size. *Atmosphere*, 2023, 14(9): 1462
- 20 Zhong G. Convolutional Neural Network Model to Predict Outdoor Comfort UTCI Microclimate Map. *Atmosphere*, 2022, 13(11): 1860
- 21 Wang J, Song Y, Liu F, 等. Analysis and application of forecasting models in wind power integration: A review of multi-step-ahead wind speed forecasting models. *Renewable and Sustainable Energy Reviews*, 2016, 60: 960~981
- 22 Giometto M G, Christen A, Meneveau C, 等. Spatial Characteristics of Roughness Sublayer Mean Flow and Turbulence Over a Realistic Urban Surface. *Boundary Layer Meteorol*, 2016, 160(3): 425~452
- 23 Petrakis T, Kavga A, Thomopoulos V, 等. Neural Network Model for Greenhouse Microclimate Predictions. *Agriculture*, 2022, 12(6): 780
- 24 Lu T, Viljanen M. Prediction of indoor temperature and relative humidity using neural network models: model comparison. *Neural Comput & Applic*, 2009, 18(4): 345~357
- 25 Misra I, Shrivastava A, Gupta A, 等. Cross-stitch Networks for Multi-task Learning. *arXiv*, 2016.
- 26 Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv*, 2015.
- 27 Kingma D P, Ba J. Adam: A Method for Stochastic Optimization. *arXiv*, 2017.