

零样本超分辨率通过基于变换器的神经算子从非结构化数据进行城市微气象研究

Yuki Yasuda^{1,2} and Ryo Onishi^{1,2}

¹*Supercomputing Research Center, Institute of Integrated Research, Institute of Science Tokyo, Tokyo, Japan*

²*d.weather inc., Tokyo, Japan*

Corresponding author: Yuki Yasuda, Supercomputing Research Center, Institute of Integrated Research, Institute of Science Tokyo, Tokyo, Japan, 2-12-1 Ookayama, Meguro-ku, Tokyo 1528550, Japan, E-mail: yasuda.yuki@scrc.iir.isct.ac.jp

摘要

本研究证明，基于变换器的神经算子（TNO）可以实现城市地区地面附近二维温度场的零样本超分辨率。在训练过程中，从 100 米的水平分辨率进行到 20 米的超分辨率处理，而在测试中，则是从 100 米提升至更精细的 5 米分辨率。这种设置被称为零样本，因为在训练数据集中不包含目标 5 米分辨率的数据。20 米和 5 米分辨率的数据是通过使用一种基于物理学的微气象模型对 100 米的数据进行动态降尺度处理而独立获得的，该模型可以解析建筑物的影响。与卷积神经网络相比，TNO 在再现 5 米分辨率下的温度分布方面更为准确，并将测试误差降低了约 33%。此外，即使是在训练数据为无结构化的情况下（其中网格点随机排列），TNO 也能成功实现零样本超分辨率。这些结果表明，TNO 能够独立于网格点位置识别建筑物形状，并自适应地推断出由建筑物引起的温度场。

1 介绍

神经算子最近在物理科学的数值模拟中被广泛使用 (Azizzadenesheli et al., 2024)。神经算子使用神经网络近似函数到函数的映射（即函数空间中的算子），从而使得推断与网格点的位置无关。在物理学中，大多数量以“场”表示，这些场是以将空间位置映射到物理量的函数形式表达的（例如 $T(\mathbf{x})$ ）。

因此，神经算子非常适合于通过偏微分方程描述场的时间演变的物理学问题，并且它们已被应用于诸如数值天气预报等场景 (e.g., Kurth et al., 2023)。

神经算子也被应用于超分辨率 (SR; e.g., Wei and Zhang, 2023)。超分辨率是一种用于增强数据分辨率的技术，已经广泛使用神经网络 (Lepcha et al., 2023) 进行研究。神经算子将图像视为“场”，并把超分辨率表述为从低分辨率场到高分辨率场的映射。这种方法使得神经算子能够实现任意尺度的超分辨率 (Liu et al., 2024)，这是传统的基于卷积的网络无法做到的。因此，神经算子可以在比训练时更高的分辨率下执行超分辨率，这种实验设置被称为零样本超分辨率 (e.g., Wei and Zhang, 2023)。

神经算子在气象学中最近开始被应用 (Jiang et al., 2023; Yang et al., 2024; Sinha et al., 2025)。这些研究针对的是水平分辨率几公里或更粗的中尺度或全球尺度。相比之下，城市微气象学需要几米的分辨率来解析由建筑物引起的气流 (Toparlar et al., 2017)。对于推断此类高分辨率数据而言，超分辨率的有效性已经得到证明 (Onishi et al., 2019; Wu et al., 2021; Teufel et al., 2023; Yasuda and Onishi, 2025)。然而，这些研究利用了传统的基于卷积的网络，基于神经算子的超分辨率在城市微气象学中的有效性尚未确立。

本研究采用基于变压器的神经算子 (TNO) 来证明，在城市地区的近地面二维温度场中，零样本超分辨率是可行的。TNO 即使从随机排列网格点的非结构化数据中也能学习超分辨率，并被认为能够自适应地推断由建筑物引起的温度场。

2 方法

对于本研究中的零样本超分辨率，训练时从 100 米的水平分辨率推断到 20 米，测试时从 100 米推断到 5 米 (图 1)，其中 5 米分辨率的数据在训练过程中未使用 (i.e., zero-shot configuration; Azizzadenesheli et al., 2024)。这些数据来自 2013 年至 2020 年的极端炎热日的模拟 (Yasuda and Onishi, 2025)，使用多尺度地球环境仿真器 (MSSG; Onishi and Takahashi, 2012; Takahashi et al., 2013; Sasaki et al., 2016; Matsuda et al., 2018) 获得。100 米分辨率的数据由中尺度模拟生成，而 20 米和 5 米的数据则通过动力降尺度独立获得 (有关数据详情，请参见 Yasuda and Onishi (2025))。神经网络被训练以模仿这种动力降尺度，并在零样本设置下进行评估。

2.1 数据

图 2 显示了 MSSG 模拟的计算域。所有域的中心是日本的东京站。中尺度模拟使用双向嵌套，包含三个计算域，其中域 1、域 2 和域 3 的水平分辨率分别为 1 公里、300 米和 100 米。解析建筑物的微气象学模拟采用单向嵌套进行，域 3 的结果用作边界和初始条件。具体来说，在所有方向上分别进行了均匀分辨率为 20 米或 5 米的独立模拟，并将高度为 2 米处的温度作为真实值。

神经网络利用中尺度模拟数据作为输入。这些包括最低五层的温度和水平风速、地面温度以及垂直插值的 2 米温度。此外，输入还包括微气象学模拟中的静态数据：建筑物高度、土地使用指数以及输出网格点的 (x, y) 坐标。真实值（以及神经网络输出）是 20 米或 5 米分辨率下的 2 米高度温度。所有变量覆盖以东京车站为中心的 1.6 公里正方形区域，且是一分钟平均值来自 MSSG 的数据。100 米分辨率的输入通过最近邻插值上采样至 80×80 网格（对于 20 米的情况）或 320×320 网格（对于 5 米的情况）。2013 年至 2019 年的数据用于训练（共 2,880 组），而 2020 年的数据用于测试（共 540 组）。第 3 节中的所有结果均基于测试数据。

非结构化网格数据也被创建以确认神经算子的推断与网格点的位置无关 (Azizzadenesheli et al., 2024)。对于每个地面真实值（20 米或 5 米分辨率），我们随机散布了与原始网格数据相同数量的点，并通过双三次插值分配值。对于 100 米分辨率的输入，在与地面真实值相同的分散点上也使用双三次插值计算了值。这些非结构化数据可以直接馈送到神经算子，但不能用作需要规则网格的基于卷积网络的输入。

2.2 神经网络

图 3 展示了本研究提出的基于变压器的神经算子 (TNO)。该模型集成了来自 Cao (2021) 的变压器模块，并基于计算机视觉的 SR 模型开发 (Wei and Zhang, 2023)。作为城市微气象学的具体适应，用作输入的坐标向量被扩展以包含每个空间点的建筑物高度和土地使用指数。完整实现可在我们的 Zenodo 仓库中获得（参见数据可用性）。

核心变换块 (Cao, 2021) 可以被视为傅里叶神经算子 (FNO; Li et al., 2021) 的扩展。FNO 受计算流体动力学中的伪谱方法启发，通过使用傅里叶变换实现了与网格无关的推理。Cao (2021) 的变换块在数学上被认为是将基函数从三角函数扩展到可学习函数。具体来说，在图 3 中，“Value” 和 “Key” 之间的矩阵乘法 (MM) 对应于傅里叶变换，随后与 “Query” 的 MM 对应于逆傅里叶变换。Cao (2021) 证明了该变换块的数值稳定性；即近似误差独立于网格点的数量。

作为对比，我们采用了由 Yasuda et al. (2022) 提出的基于卷积的网络。该模型通过引入通道注意力机制 (Hu et al., 2018) 增强了 SRCNN 这个超分辨率神经网络 (Dong et al., 2014)。此模型的有效性已在城市区域推断温度场方面得到证实 (Yasuda et al., 2022)。这个卷积神经网络在下文中简称为 CNN。

AdamW 优化器 (Loshchilov and Hutter, 2019) 被用于训练 TNO 和 CNN。训练的损失函数是平均绝对误差 (MAE; 也称为 L1 损失)。在评估时，我们报告了两个指标：量化点误差的 MAE，以及衡量模式相似性误差的结构相似度指数测量 (SSIM) 损失。对于这两个指标来说，数值越小表示推断结果与真实值越接近。这些评估指标在超分辨率研究 (Lepcha et al., 2023; Liu et al., 2024) 中被广泛采用。所有测试数据上的 MAE 和 SSIM 损失的平均值分别称为 M-MAE 和 M-SSIM 损失。为了评估 M-MAE 和 M-SSIM 损失差异的统计显著性，我们进行了五次训练，每次使用不同的初始权重参数，并计算了这两个指标的标准差。

3 结果与讨论

图 4 展示了一个 SR 结果的示例。为了验证成功的训练，模型首先使用了来自 2020 年的 20 米分辨率数据进行评估。CNN 和 TNO 都准确地再现了 20 米分辨率下的温度场 (图 4a)。此推理执行从 100 米到 20 米分辨率的 SR (即, $5\times$ SR)，这与训练期间相同。相比之下，在零样本情况下 (图 4b)，SR 执行到了 5 米分辨率，比训练过程中使用的更精细 (即, $20\times$ SR)。尽管 TNO 存在高温偏差，但它定性地很好地再现了 5 米分辨率的温度场模式。CNN 生成了有噪声的推理，并且无法再现建筑物引起的温度场。例如，CNN 推理 (图 4b) 显示，在右上角的 L 形低温区域 (对应于河流上方的一个区域) 存在噪声，并且也未能捕捉到中心由建筑阴影引起的低温区域。这些结果在其他测试数据中是一致观察到的。

表 1 显示了所有测试数据的平均误差值。我们首先讨论训练数据是有结构的情况。对于 20 米分辨率的测试数据，CNN 显示出比 TNO 稍小的误差。这一结果可以解释为，由于参数数量较多，CNN 在固定分辨率下具有更高的表达能力。实际上，通过增加 TNO 中的变压器块数量 (即增加参数数量)，我们确认了误差的减少。这种特性——即通过堆叠变压器块来提高表达能力——也在 Cao (2021) 中进行了讨论。尽管参数数量大约只有 CNN 的七分之一，TNO 展示了更高的泛化能力。对于 5 米分辨率的数据，TNO 显示出比 CNN 更小的误差，M-MAE 和 M-SSIM 损失分别减少了约 25% 和 31%。CNN 较大的误差反映了其在 5 米分辨率下的噪声推理，如图 4b 所示。这些结果表明，传统的基于卷积模型对分辨率和网格点位置敏感，而神经算子对此相对不敏感，从而实现零样本超分辨率。这些发现与计算机视觉领域的先前结果 (e.g., Wei and Zhang, 2023; Liu et al., 2024) 一致。

图 5 展示了一个使用非结构化数据训练的 TNO 进行推断的例子。在图 5a 中，对等间距网格（间距为 20 米或 5 米）进行了推断，这些与图 4 中的一致；而在图 5b 中，使用了与训练期间相同的非结构化网格类型进行推断。请注意，在此训练过程中，我们使用了来自 20 米分辨率温度的非结构化数据作为真实值。TNO 在每个测试数据集指定的网格点上准确地进行了温度推断，这表明对网格形状的独立性。事实上，等间距网格的测试误差并不强烈依赖于训练期间使用的网格类型（表 1）。与 CNN 相比，M-MAE 和 M-SSIM 损失分别减少了大约 28% 和 38%，平均减少约 33% (~)。这些误差降低率高于使用结构化网格获得的值（分别为 25% 和 31%），这表明在训练过程中使用非结构化网格增强了泛化能力。

这些结果表明，TNO 内部将物理量识别为“场” (Azizzadenesheli et al., 2024)。对于普通图像，神经算子可能仍然需要输入尺度因子（即低分辨率与高分辨率的比率）(e.g., Wei and Zhang, 2023)。在本研究中，TNO 独立于网格点位置识别给定建筑的形状，并自适应地推断这些建筑物引起的温度场（图 5）。因此，TNO 不需要输入尺度因子或结构化的输入输出数据。这些发现可能特定于城市微气象学领域，在该领域中，建筑物特征化了流体尺度。

4 结论

本研究提出了一种基于变压器的神经算子 (TNO)，并展示了其在城市地区近地面二维温度场中的零样本超分辨率 (SR) 能力。测试结果表明，TNO 比传统的卷积神经网络 (CNN) 更准确地再现了温度分布。来自 TNO 的测试误差比 CNN 小约 33%。TNO 还成功从非结构化数据（即随机排列的点云数据）中学习了 SR。这些结果表明，TNO 能够自适应推断出由建筑物引起的温度场。

未来的研究方向包括提高准确性和将方法扩展到三维数据。例如，零样本学习 (Shocher et al., 2018) 可能在保持零样本配置（即测试时对未知分辨率进行推理）的同时提高准确性。对于实际应用，物理量的垂直结构很重要，需要对三维数据进行超分辨率处理。由于神经算子可以应用于三维数据 (e.g., Qin et al., 2025)，三维零样本超分辨率是城市微气象学中一个有前景的研究方向。

致谢

微气象学模拟在日本海洋地球科学与技术机构 (JAMSTEC) 的地球模拟器系统上进行（项目 ID: 1-23007 和 1-24009）。深度学习实验在一个配备 NVIDIA RTX 6000 GPU 板的本地工作站上进行。

数据可用性

深度学习模型的源代码保存在 Zenodo 仓库 (<https://doi.org/10.5281/zenodo.15307703>) 中, 并在 GitHub 仓库 (<https://github.com/YukiYasuda2718/zero-shot-sr-urban-mm>) 中公开开发。支持本研究发现的数据可在合理请求下由通讯作者提供。

参考文献

- Azizzadenesheli, K., N. Kovachki, Z. Li, M. Liu-Schiaffini, J. Kossaifi, and A. Anandkumar, 2024: Neural operators for accelerating scientific simulations and design. *Nature Reviews Physics*, **6**(5), 320–328.
- Cao, S., 2021: Choose a transformer: fourier or galerkin. In *Proceedings of the 35th International Conference on Neural Information Processing Systems, NIPS '21*, Curran Associates Inc., Red Hook, NY, USA.
- Dong, C., C. C. Loy, K. He, and X. Tang, 2014: Learning a deep convolutional network for image super-resolution. In *Computer Vision – ECCV 2014*, Springer International Publishing, Cham, 184–199.
- Hu, J., L. Shen, and G. Sun, 2018: Squeeze-and-excitation networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Jiang, P., Z. Yang, J. Wang, C. Huang, P. Xue, T. C. Chakraborty, X. Chen, and Y. Qian, 2023: Efficient super-resolution of near-surface climate modeling using the fourier neural operator. *Journal of Advances in Modeling Earth Systems*, **15**(7), e2023MS003800. e2023MS003800 2023MS003800.
- Kurth, T., S. Subramanian, P. Harrington, J. Pathak, M. Mardani, D. Hall, A. Miele, K. Kashinath, and A. Anandkumar, 2023: Fourcastnet: Accelerating global high-resolution weather forecasting using adaptive fourier neural operators. In *Proceedings of the Platform for Advanced Scientific Computing Conference, PASC '23*, Association for Computing Machinery, New York, NY, USA.

- Lepcha, D. C., B. Goyal, A. Dogra, and V. Goyal, 2023: Image super-resolution: A comprehensive review, recent trends, challenges and applications. *Information Fusion*, **91**, 230–260.
- Li, Z., N. B. Kovachki, K. Azizzadenesheli, B. Liu, K. Bhattacharya, A. Stuart, and A. Anandkumar, 2021: Fourier neural operator for parametric partial differential equations. In *International Conference on Learning Representations*.
- Liu, H., Z. Li, F. Shang, Y. Liu, L. Wan, W. Feng, and R. Timofte, 2024: Arbitrary-scale super-resolution via deep learning: A comprehensive survey. *Information Fusion*, **102**, 102015.
- Loshchilov, I., and F. Hutter, 2019: Decoupled weight decay regularization. In *International Conference on Learning Representations*.
- MapBox, 2022: Mapbox. accessed 8 August 2024.
- Matsuda, K., R. Onishi, and K. Takahashi, 2018: Tree-crown-resolving large-eddy simulation coupled with three-dimensional radiative transfer model. *Journal of Wind Engineering and Industrial Aerodynamics*, **173**, 53–66.
- Onishi, R., D. Sugiyama, and K. Matsuda, 2019: Super-resolution simulation for real-time prediction of urban micrometeorology. *SOLA*, **15**, 178–182.
- Onishi, R., and K. Takahashi, 2012: A warm-bin – cold-bulk hybrid cloud microphysical model*. *Journal of the Atmospheric Sciences*, **69**, 1474–1497.
- OpenStreetMap, 2022: Openstreetmap. accessed 8 August 2024.
- Qin, S., D. Zhan, D. Geng, W. Peng, G. Tian, Y. Shi, N. Gao, X. Liu, and L. L. Wang, 2025: Modeling multivariable high-resolution 3d urban microclimate using localized fourier neural operator. *Building and Environment*, **273**, 112668.
- Sasaki, W., R. Onishi, H. Fuchigami, K. Goto, S. Nishikawa, Y. Ishikawa, and K. Takahashi, 2016: Mjo simulation in a cloud-system-resolving global ocean-atmosphere coupled model. *Geophysical Research Letters*, **43**, 9352–9360.

- Shocher, A., N. Cohen, and M. Irani, 2018: Zero-shot super-resolution using deep internal learning. In *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 3118–3126.
- Sinha, S., B. Benton, and P. Emami, 2025: On the effectiveness of neural operators at zero-shot weather downscaling. *Environmental Data Science*, **4**, e21.
- Takahashi, K., R. Onishi, Y. Baba, S. Kida, K. Matsuda, K. Goto, and H. Fuchigami, 2013: Challenge toward the prediction of typhoon behaviour and down pour. *Journal of Physics: Conference Series*, **454**, 012072.
- Teufel, B., F. Carmo, L. Sushama, L. Sun, M. N. Khaliq, S. Bélair, A. Shamseldin, D. N. Kumar, and J. Vaze, 2023: Physics-informed deep learning framework to model intense precipitation events at super resolution. *Geoscience Letters*, **10(1)**, 19.
- Toparlar, Y., B. Blocken, B. Maiheu, and G. van Heijst, 2017: A review on the cfd analysis of urban microclimate. *Renewable and Sustainable Energy Reviews*, **80**, 1613–1640.
- Ulyanov, D., A. Vedaldi, and V. S. Lempitsky, 2016: Instance normalization: The missing ingredient for fast stylization. *CoRR*, **abs/1607.08022**.
- Wei, M., and X. Zhang, 2023: Super-Resolution Neural Operator . In *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE Computer Society, Los Alamitos, CA, USA, 18247–18256.
- Wu, Y., B. Teufel, L. Sushama, S. Belair, and L. Sun, 2021: Deep learning-based super-resolution climate simulator-emulator framework for urban heat studies. *Geophysical Research Letters*, **48(19)**, e2021GL094737. e2021GL094737 2021GL094737.
- Yang, Q., A. Hernandez-Garcia, P. Harder, V. Ramesh, P. Sattigeri, D. Szwarcman, C. D. Watson, and D. Rolnick, 2024: Fourier neural operators for arbitrary resolution climate data downscaling. *Journal of Machine Learning Research*, **25(420)**, 1–30.

Yasuda, Y., and R. Onishi, 2025: Two-stage super-resolution simulation method of three-dimensional street-scale atmospheric flows for real-time urban micrometeorology prediction. *Urban Climate*, **59**, 102300.

Yasuda, Y., R. Onishi, Y. Hirokawa, D. Kolomenskiy, and D. Sugiyama, 2022: Super-resolution of near-surface temperature utilizing physical quantities for real-time prediction of urban micrometeorology. *Building and Environment*, **209**, 108597.

插图

- 1 零样本超分辨率的实验设置。使用 MSSG 动态降尺度获取低分辨率的 100 米数据以获得 20 米或 5 米的数据。在训练阶段（上图），神经网络被训练用于从 100 米降至 20 米分辨率，使用 20 米分辨率的真实地面数据。在测试阶段（下图），训练好的网络将分辨率从 100 米降低至 5 米，并使用 5 米分辨率的真实地面数据进行评估。在训练阶段完全不使用 5 米分辨率的数据。 11
- 2 中尺度和微气象模拟的计算域。使用 MSSG 进行了从中尺度到微尺度的动力降尺度。所有域的中心是日本的东京站。建筑物高度分布中的黑色方块表示图 4 和 5 所示的区域。卫星图像来自 MapBox (2022) 和 OpenStreetMap (2022)。 12
- 3 基于 Transformer 的神经算子 (TNO)。“线性”表示线性变换，“SiLU”表示 Sigmoid 线性单元，“Norm”表示实例归一化 (Ulyanov et al., 2016)，“MM”表示矩阵乘法，而“ReLU”表示修正线性单元。完整的实现可在我们的 Zenodo 仓库中找到（参见数据可用性）。 . . 13
- 4 温度分布的 SR 结果示例，分别为 (a) 20 米和 (b) 5 米分辨率。图中显示的是靠近东京站的一个 500 米见方的区域，由图 2 中的黑色方块指示。“LR”表示 100 米分辨率（低分辨率）下的 2 米温度，“GT”表示 2 米温度的真实值，而“Bldg. Height”表示建筑物高度分布。“LR”在两行中指代相同的数据，但相应的 MAE 不同，因为真实值的分辨率为 20 米和 5 米。 14
- 5 测试结果示例，使用非结构化数据训练的 TNO。在上图中，真实数据是通过 (a) 具有 20 米间距的结构化网格和 (b) 非结构化的三角形网格以 20 米分辨率获得的。对于 (a)，本测试使用了与图 4 相同的真实数据。网格用灰色线条明确表示。在下图中，真实数据同样是以 5 米分辨率而非 20 米分辨率获取的。 15

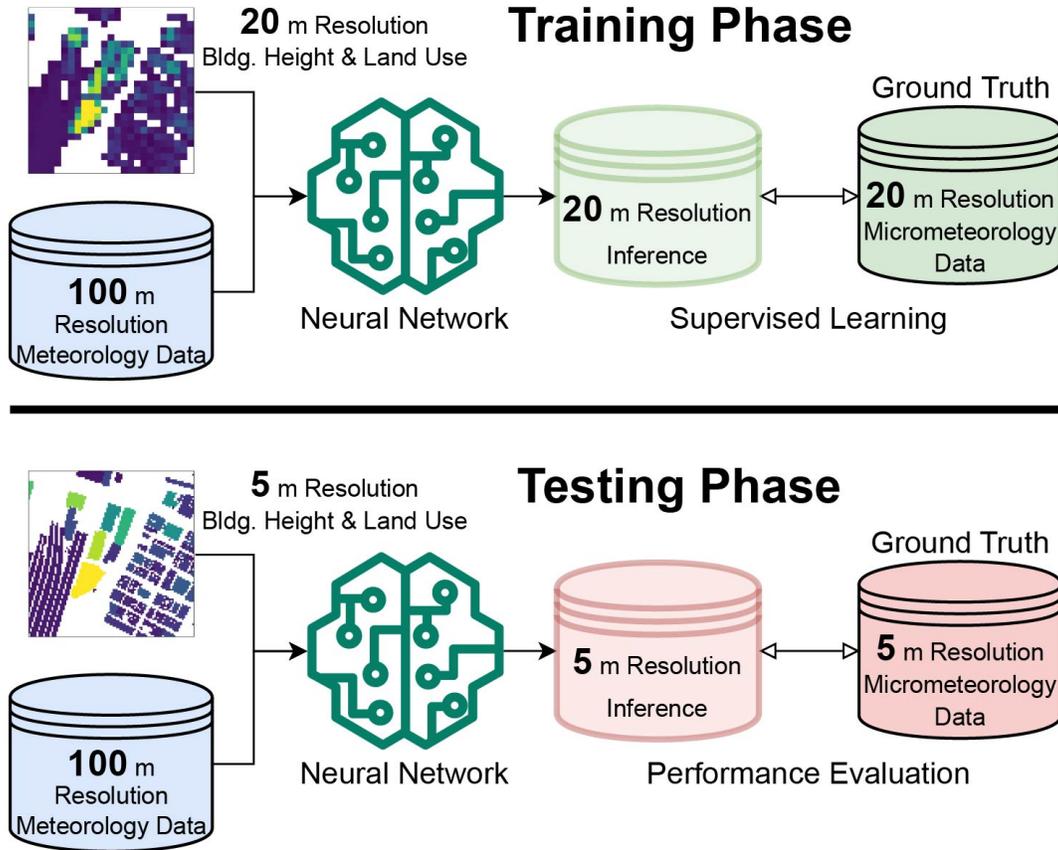


图 1: 零样本超分辨率的实验设置。使用 MSSG 动态降尺度获取低分辨率的 100 米数据以获得 20 米或 5 米的数据。在训练阶段 (上图), 神经网络被训练用于从 100 米降至 20 米分辨率, 使用 20 米分辨率的真实地面数据。在测试阶段 (下图), 训练好的网络将分辨率从 100 米降低至 5 米, 并使用 5 米分辨率的真实地面数据进行评估。在训练阶段完全不使用 5 米分辨率的数据。

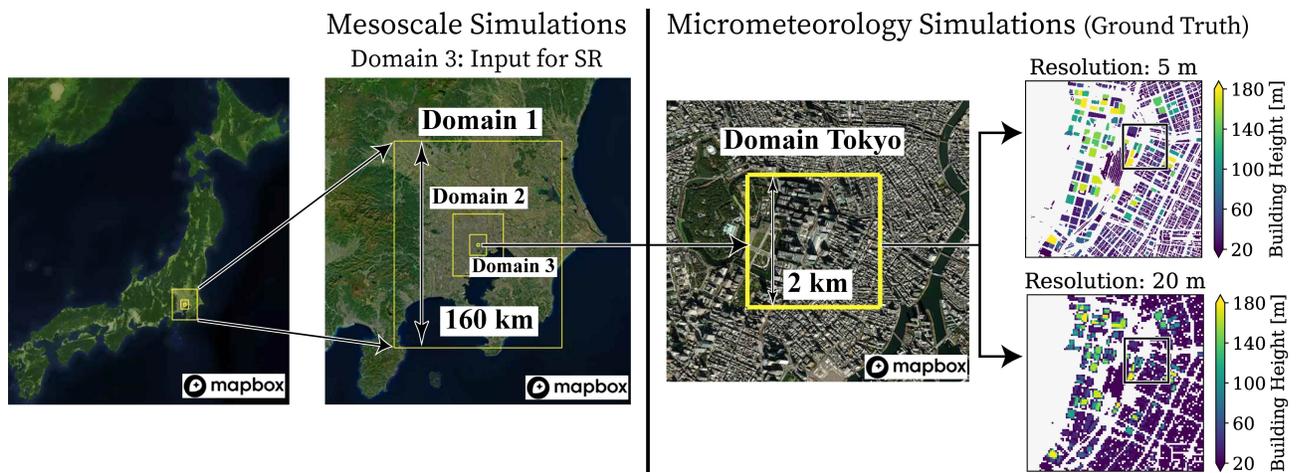


图 2: 中尺度和微气象模拟的计算域。使用 MSSG 进行了从中尺度到微尺度的动力降尺度。所有域的中心是日本的东京站。建筑物高度分布中的黑色方块表示图 4 和 5 所示的区域。卫星图像来自 MapBox (2022) 和 OpenStreetMap (2022)。

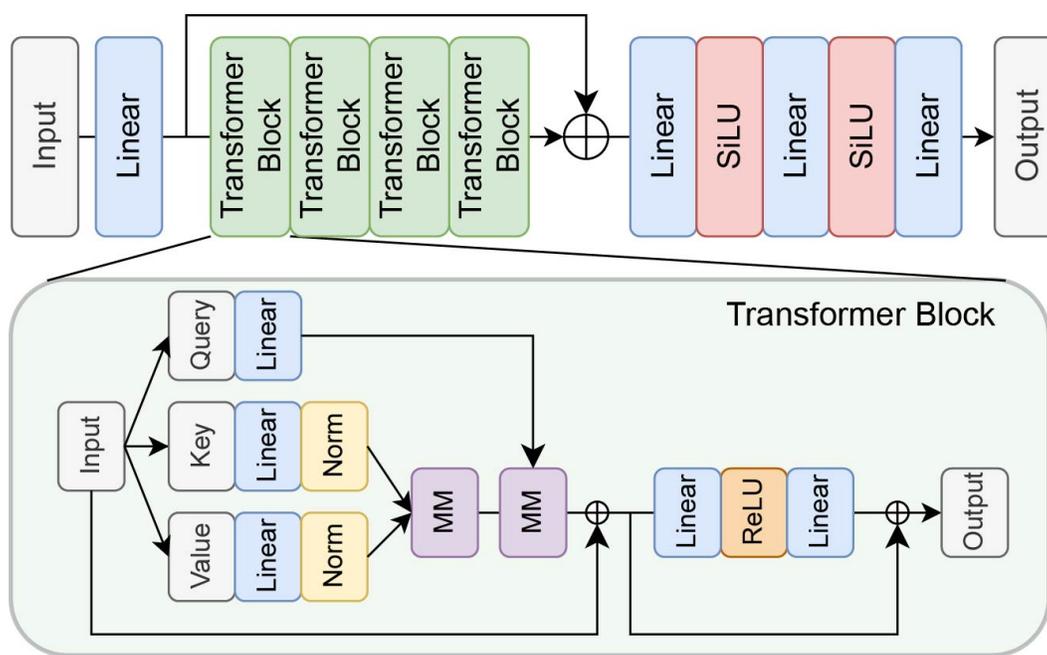


图 3: 基于 Transformer 的神经算子 (TNO)。“线性”表示线性变换,“SiLU”表示 Sigmoid 线性单元,“Norm”表示实例归一化 (Ulyanov et al., 2016),“MM”表示矩阵乘法,而“ReLU”表示修正线性单元。完整的实现可在我们的 Zenodo 仓库中找到 (参见数据可用性)。

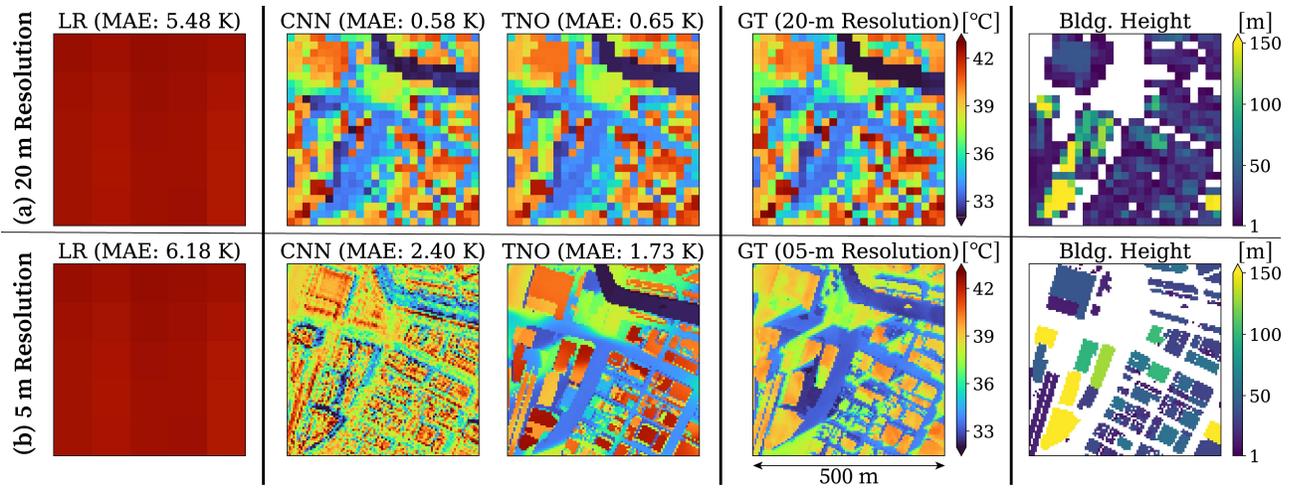


图 4: 温度分布的 SR 结果示例, 分别为 (a) 20 米和 (b) 5 米分辨率。图中显示的是靠近东京站的一个 500 米见方的区域, 由图 2 中的黑色方块指示。“LR”表示 100 米分辨率 (低分辨率) 下的 2 米温度, “GT”表示 2 米温度的真实值, 而 “Bldg. Height” 表示建筑物高度分布。“LR”在两行中指代相同的数据, 但相应的 MAE 不同, 因为真实值的分辨率为 20 米和 5 米。

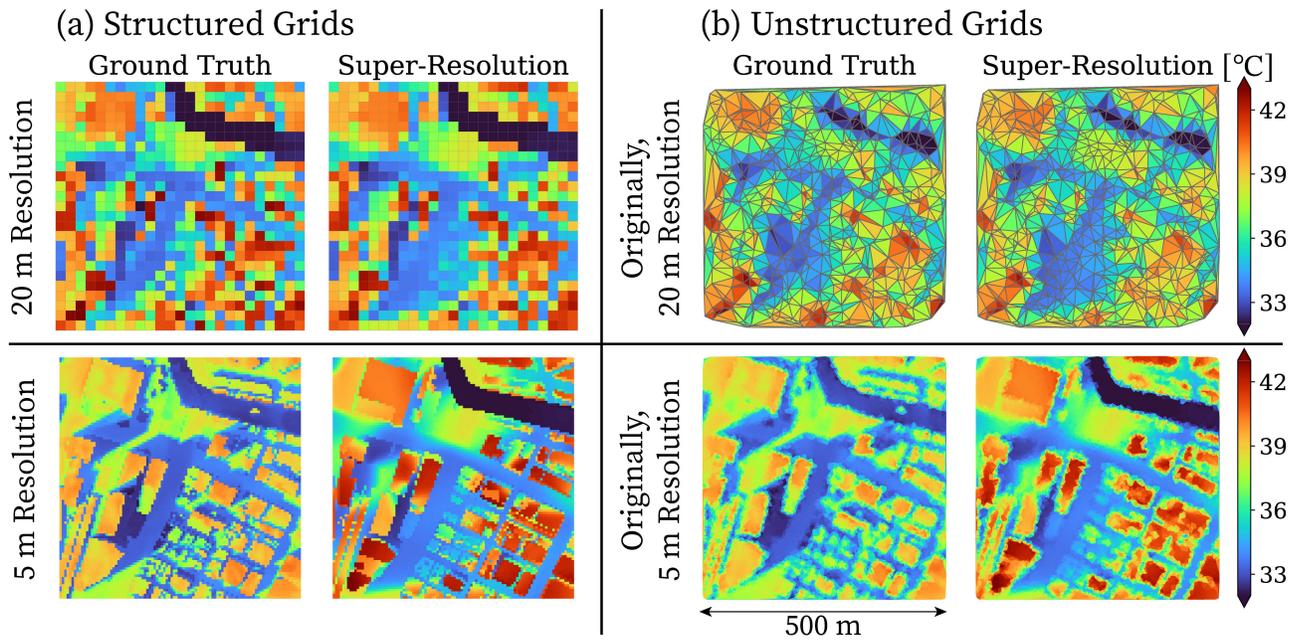


图 5: 测试结果示例, 使用非结构化数据训练的 TNO。在上图中, 真实数据是通过 (a) 具有 20 米间距的结构化网格和 (b) 非结构化的三角形网格以 20 米分辨率获得的。对于 (a), 本测试使用了与图 4 相同的真实数据。网格用灰色线条明确表示。在下图中, 真实数据同样是以 5 米分辨率而非 20 米分辨率获取的。

表格

- 1 误差值在所有测试数据上的平均值 (M-MAE 和 M-SSIM 损失) 分别对应 20 米和 5 米分辨率, 各列表示模型类型、训练数据的网格类型以及参数数量。用于训练的所有真实值均源自 20 米分辨率下的 2 米温度, 无论数据是结构化还是非结构化的。括号中的数值是 M-MAE 和 M-SSIM 损失的标准差。缩写 “Res.” 表示分辨率。 17

表 1: 误差值在所有测试数据上的平均值 (M-MAE 和 M-SSIM 损失) 分别对应 20 米和 5 米分辨率, 各列表示模型类型、训练数据的网格类型以及参数数量。用于训练的所有真实值均源自 20 米分辨率下的 2 米温度, 无论数据是结构化还是非结构化的。括号中的数值是 M-MAE 和 M-SSIM 损失的标准差。缩写 “Res.” 表示分辨率。

模型	Grid Type of Training Data	Number of Parameters	M-MAE [K] (20 m Res.)	M-SSIM Loss (20 m Res.)	M-MAE [K] (5 m Res.)	M-SSIM Loss (5 m Res.)
CNN	Structured	4,505,153	0.57 (± 0.01)	0.029 (± 0.001)	2.21 (± 0.05)	0.485 (± 0.015)
TNO	Structured	599,041	0.64 (± 0.01)	0.041 (± 0.001)	1.65 (± 0.01)	0.337 (± 0.004)
TNO	Unstructured	599,041	0.75 (± 0.02)	0.055 (± 0.003)	1.60 (± 0.02)	0.302 (± 0.001)