



论文分享: Diffusion model-based probabilistic downscaling for 180-year East Asian climate reconstruction

讲述人姓名
沈宝平

答辩日期
2024/12/17

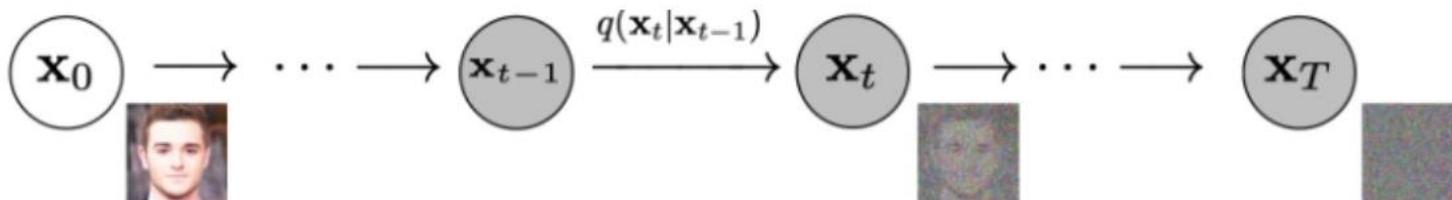
降尺度 (Downscaling)：把大尺度、低分辨率的全球气候模式输出的信息转化为小尺度、高分辨率的区域地面气候变化信息的一种方法。

由于降尺度与计算机视觉中图像超分辨任务的相似性，采用深度学习的方法往往基于超分辨率模型并利用高分辨率网格化的气象场作为监督，以提高特定网格尺度下的分辨率。

超分辨率 (Super-Resolution)，简称超分 (SR) 简单来说就是增大图像的分辨率，对低分辨率图像的细节进行重建。

SR一般会采取的几种架构：CNN的，Resnet的，GAN的，Transformer的，Diffusion的

正向过程



Algorithm 1 Training

- 1: **repeat**
 - 2: $\mathbf{x}_0 \sim q(\mathbf{x}_0)$
 - 3: $t \sim \text{Uniform}(\{1, \dots, T\})$
 - 4: $\epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$
 - 5: Take gradient descent step on

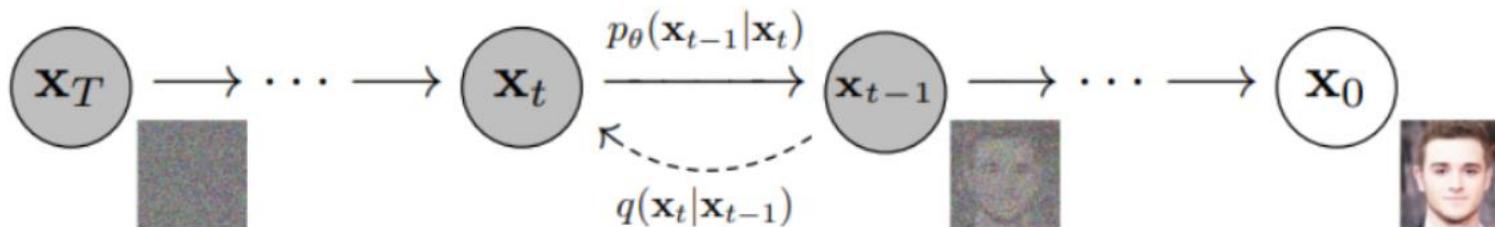
$$\nabla_{\theta} \|\epsilon - \epsilon_{\theta}(\sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t)\|^2$$
 - 6: **until** converged
-

$$q(\mathbf{x}_t | \mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t; \sqrt{1 - \beta_t} \mathbf{x}_{t-1}, \beta_t \mathbf{I})$$

定义 $\alpha_t = 1 - \beta_t$ 和 $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$ ，于是有 $\mathbf{x}_t = \sqrt{\alpha_t} \mathbf{x}_{t-1} + \sqrt{1 - \alpha_t} \epsilon_{t-1}$

$$\mathbf{x}_t = \sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon$$

反向过程

**Algorithm 2** Sampling

- 1: $\mathbf{x}_T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$
- 2: **for** $t = T, \dots, 1$ **do**
- 3: $\mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ if $t > 1$, else $\mathbf{z} = \mathbf{0}$
- 4: $\mathbf{x}_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_{\theta}(\mathbf{x}_t, t) \right) + \sigma_t \mathbf{z}$
- 5: **end for**
- 6: **return** \mathbf{x}_0

$$\mathbf{x}_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_{\theta}(\mathbf{x}_t, t) \right)$$

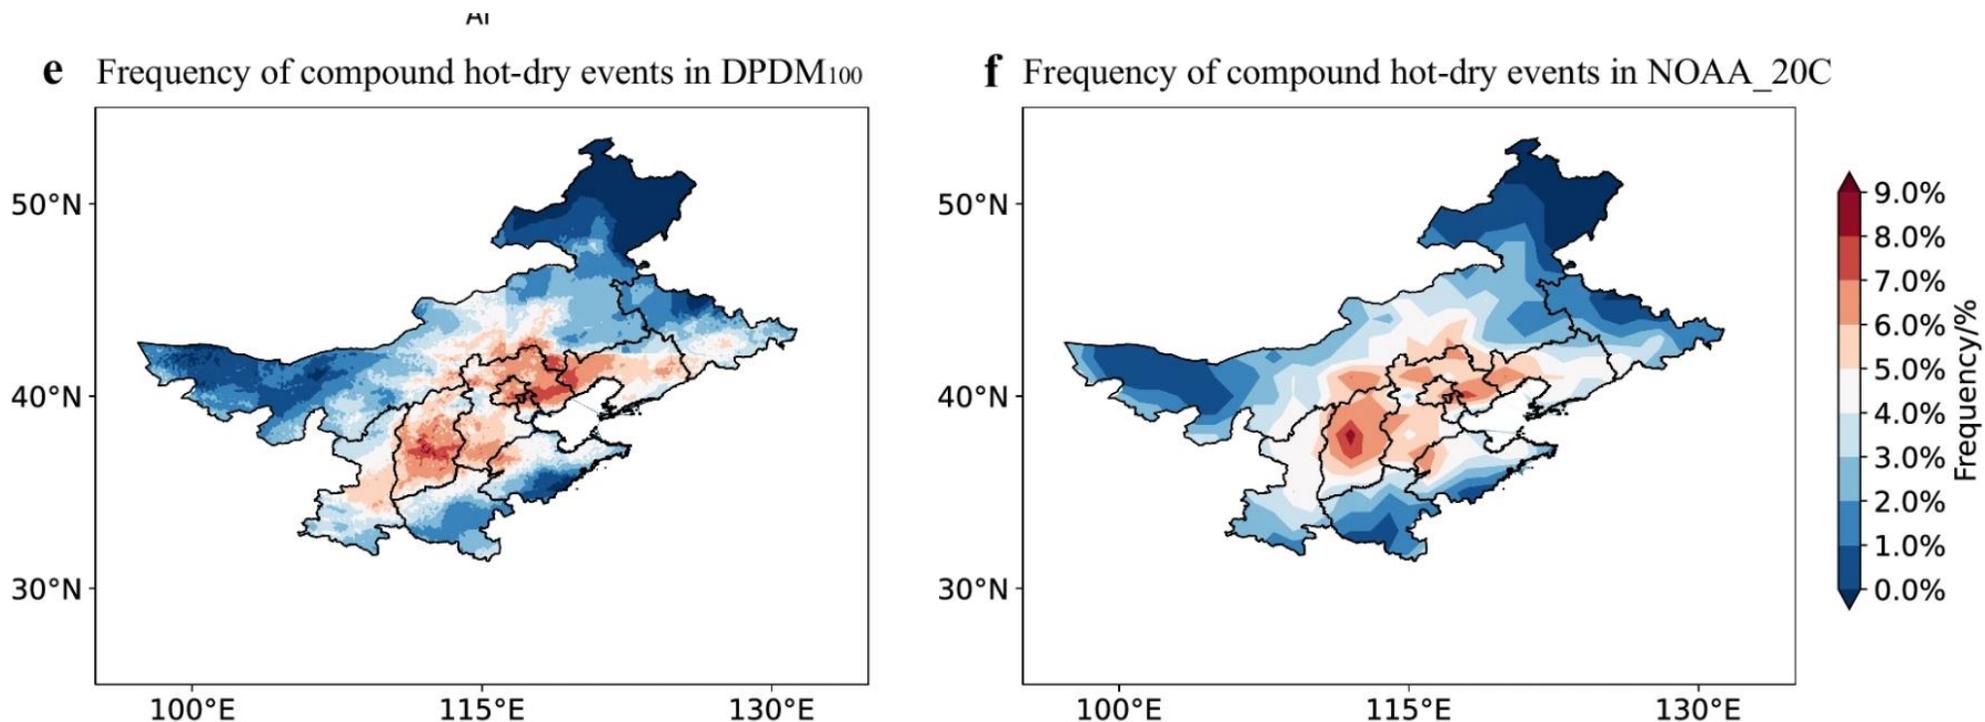
$\sigma_t \mathbf{z}$ 增加图像生成过程中的随机性

论文提出扩散概率降尺度模型（DPDM），将扩散模型应用于气象降尺度，以解决计算要求高的区域动力学模型或统计降尺度框架容易受到降尺度不确定性影响的问题

论文创新点：

- 1.采用了一种“补丁策略”，增强了训练数据的多样性并降低了训练复杂性，提高了模型的训练泛化能力
- 2.通过从概率分布中采样来生成多个集成成员，提高降尺度结果

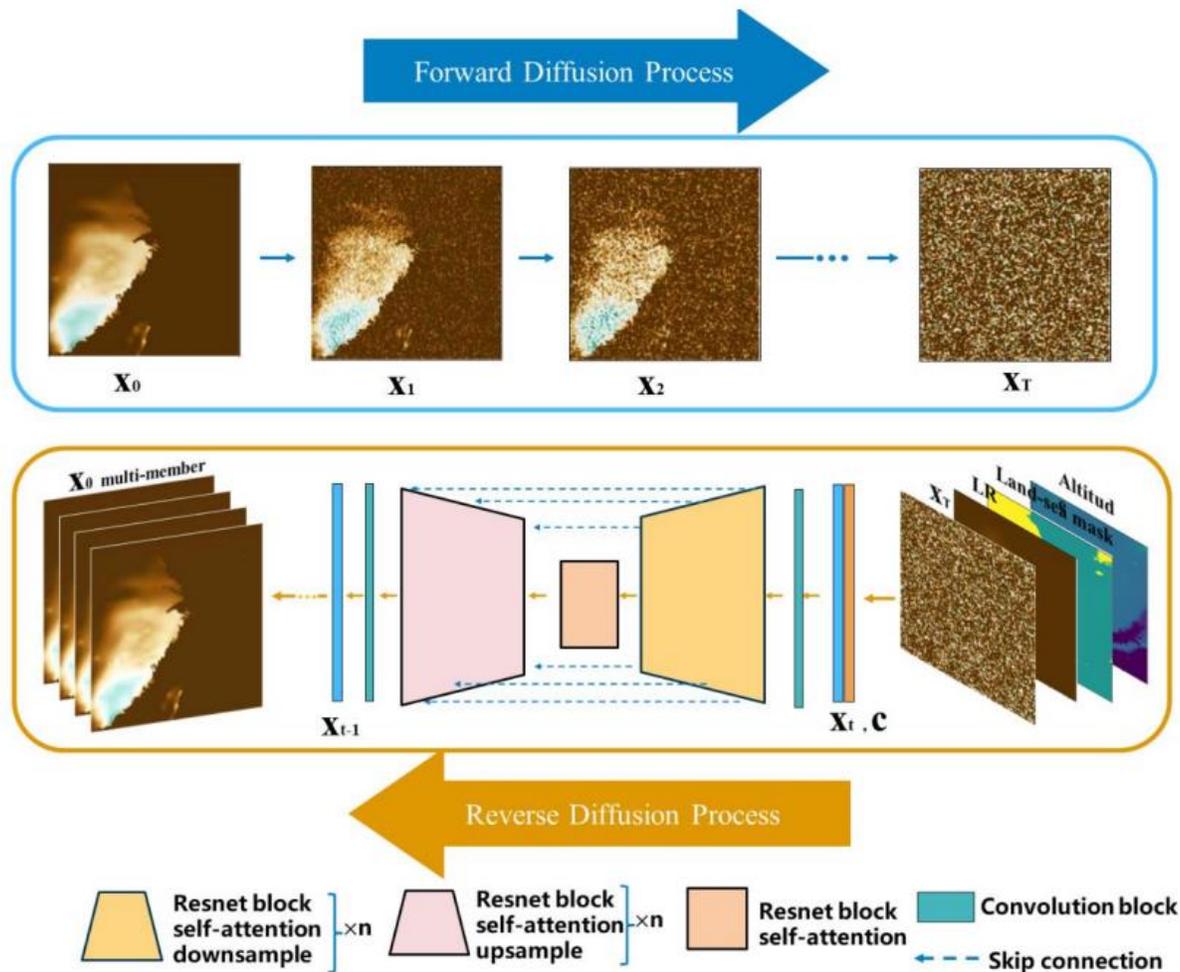
应用该模型生成了
东亚 1836 年到
2015 年近180 年月
度地表变量数据集



训练输入：将低分辨率图像裁剪为 128×128 的补丁，得到相应的高分辨率数据进行训练

图像的生成输入：噪声数据，条件数据
条件数据包括 Lerp 对低分辨率数据、地形和陆海掩码信息进行插值的插值结果。通过 Concatenation 将条件数据添加到模型中

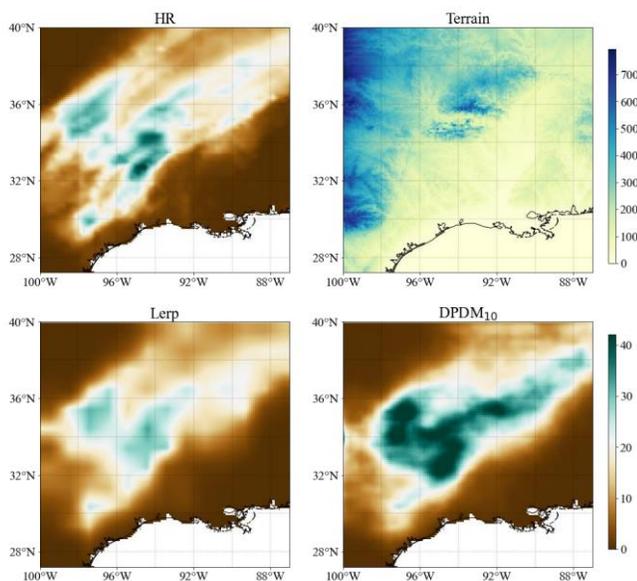
在图像的生成概率分布中采样出多个成员进行多成员均值集成



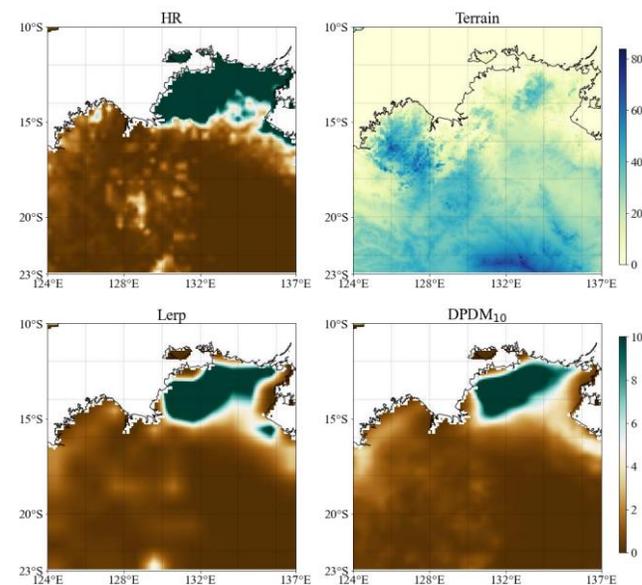
在将输入图像分成不同的补丁后，对补丁单独处理，将结果组合（引入了重叠确保边界的连续性）起来得到最终输出。

缺点：在补丁的边界处仍然存在一些质量下降，增加重叠量或采用高级技术进行边界恢复可以产生更一致的结果

优点：模型可以在没有训练的情况下获取目标区域之外的高分辨率结果



Supplementary Figure 16. The DPDM inference results with 10 members on Gulf Coast.

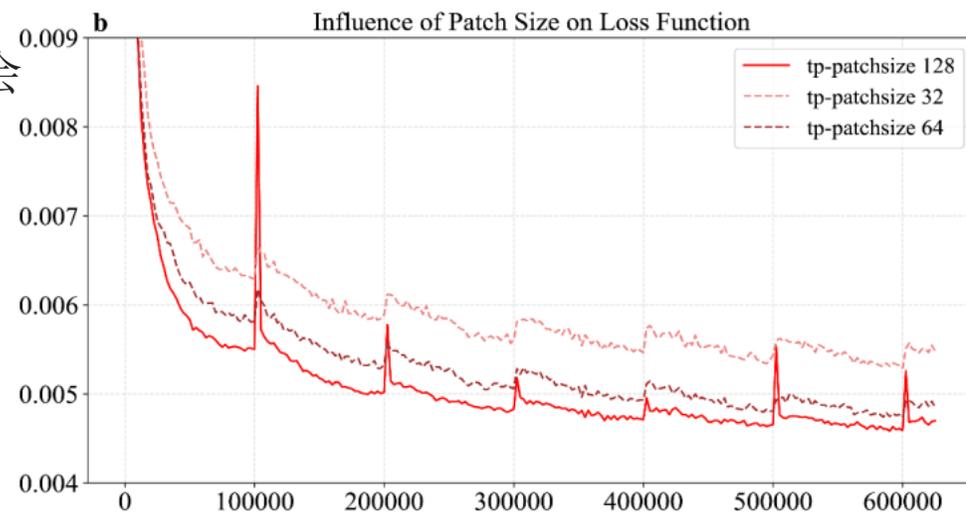
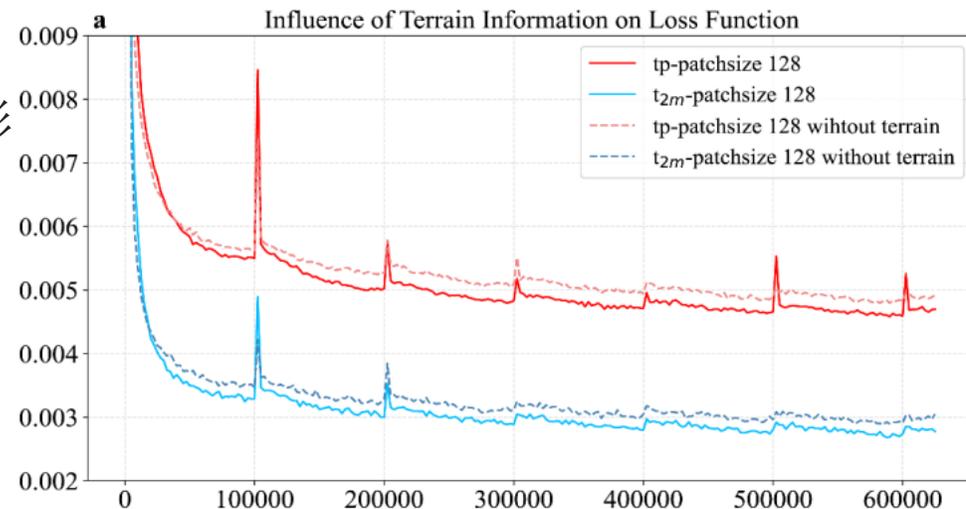


Supplementary Figure 17. The DPDM inference results with 10 members on Northern Australia.

通过消融实验研究了将地形信息添加到补丁输入的影响，并探讨了不同补丁大小（32,64,128,256）对模型性能的影响。

实验表明：

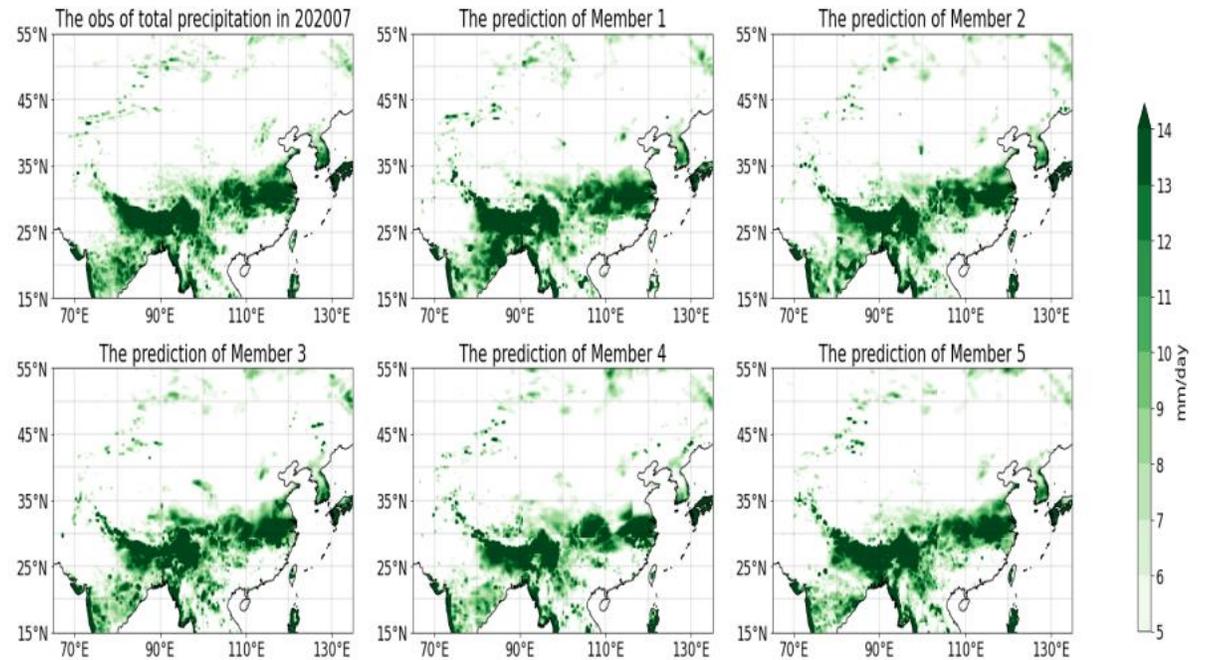
1. 结合地形信息会导致更快的损失收敛
2. 128 的补丁大小可以获得最佳性能，而 256 的补丁大小会导致非收敛的损失。



多采样集成

随着成员数量的增加，DPDM 捕获真实细节的能力在各个方面都有所提高 (Weigel, A. P., Liniger, M. A. & Appenzeller, C. Can multi-model combination really enhance the prediction skill of probabilistic ensemble forecasts? *Q. J. Roy. Meteor. Soc.* **134**, 241–260 (2008).)

从 30 个成员缩减到 100 个成员的改进相对较小原因是大约 30 个成员足以表示大多数高分辨率细节，并覆盖缩小中的不确定性空间。



Supplementary Figure 9. The total precipitation in different members of DPDM.

对极端降雨事件进行评估

2020 年 7 月，东亚长江流域发生严重洪涝，华南地区发生干旱

在两种极端情况下，我们发现通过多成员均值集成方案获得的结果总是比 Lerp 和单成员结果更接近真实值

论文认为多成员结果的分布非常接近正态分布。正态分布可能能够更好地测量确定局部细节条件的大气过程中的不确定性

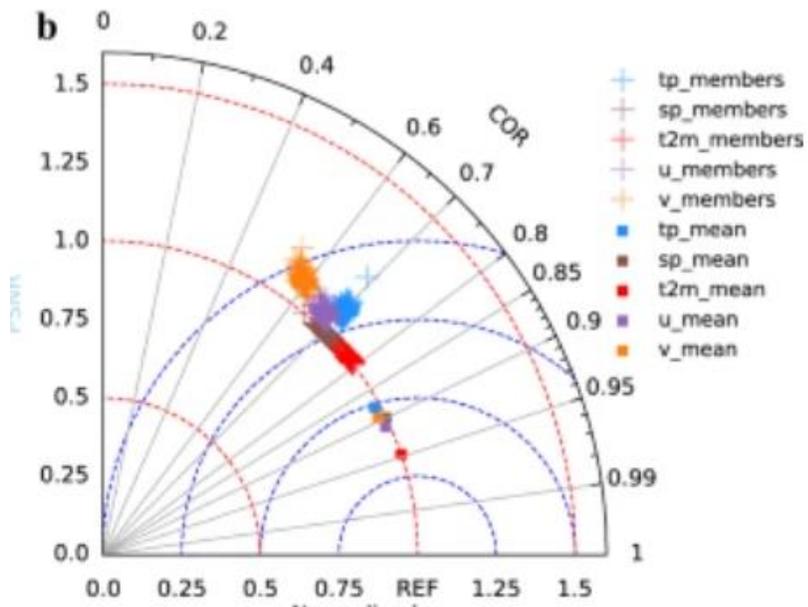


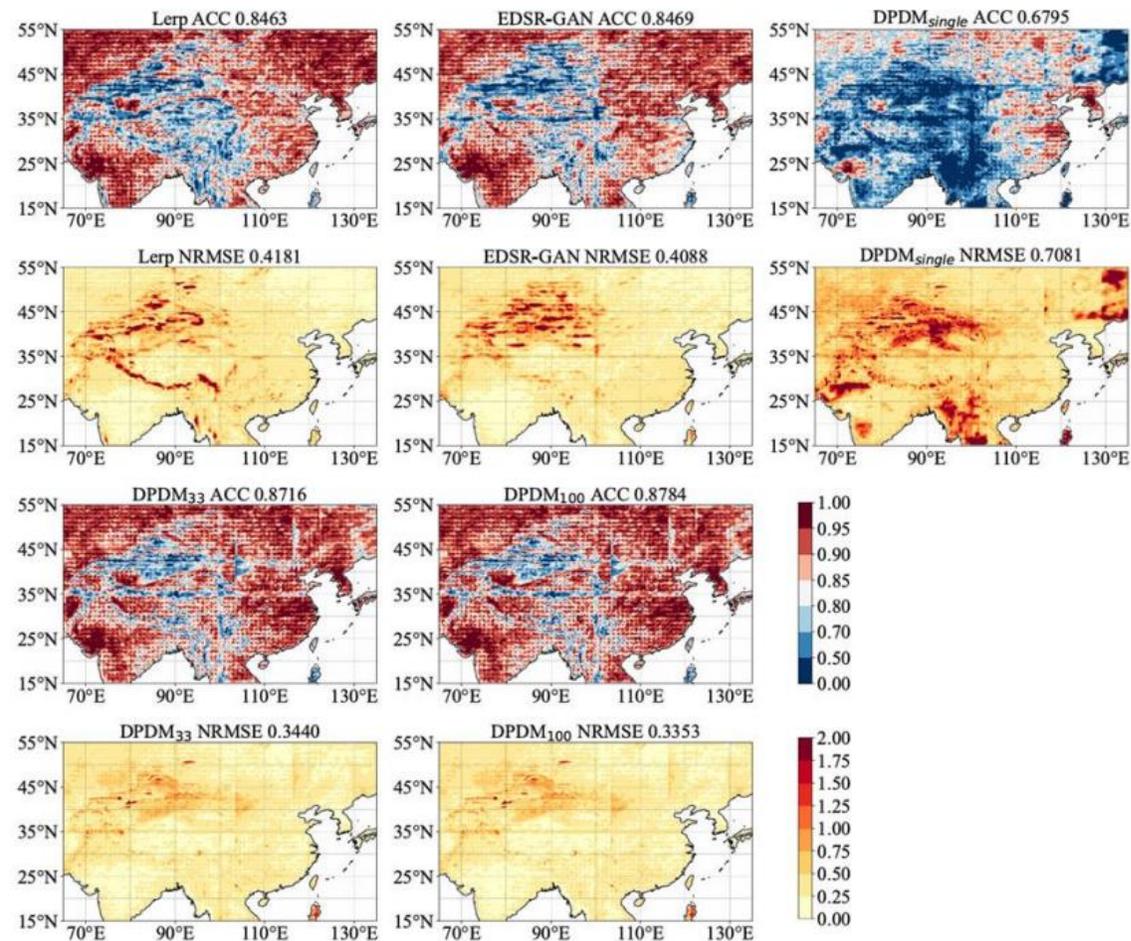
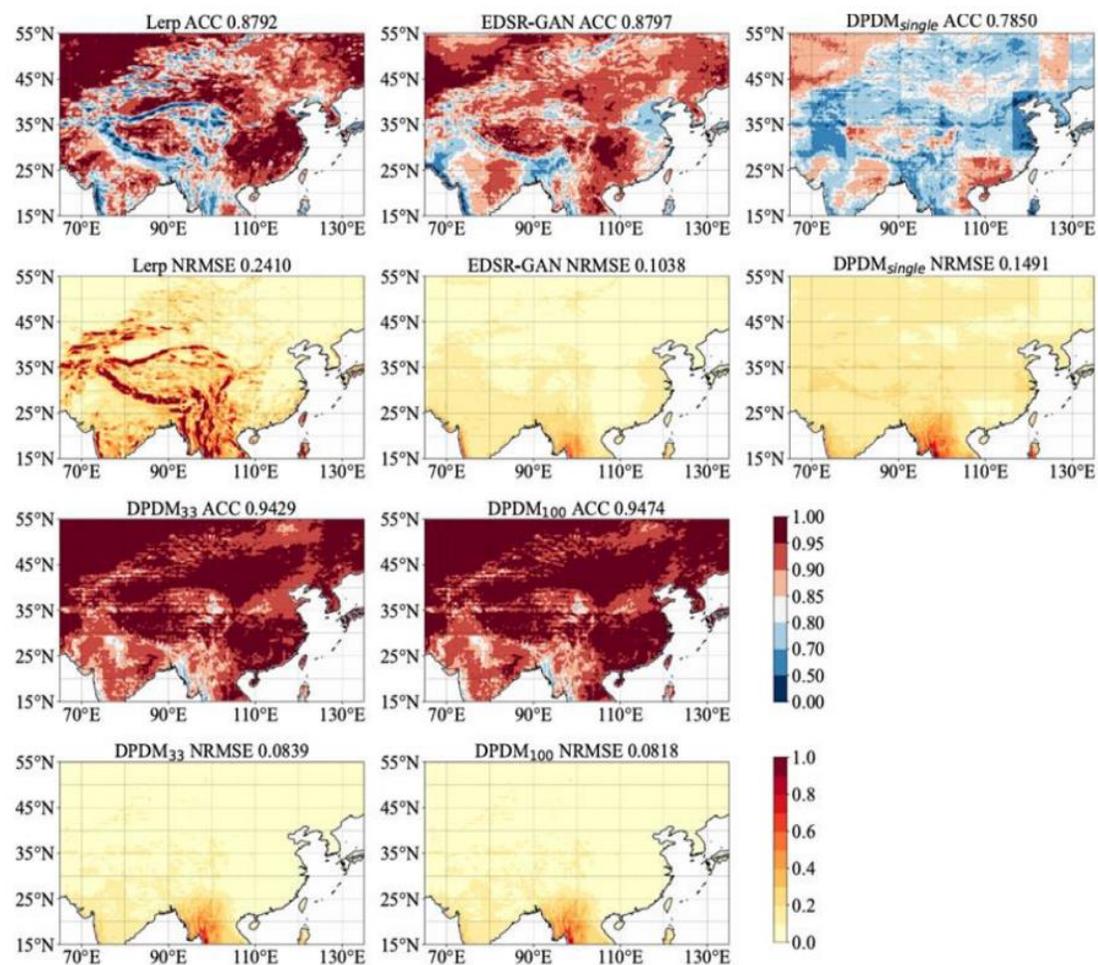
Table 1 | Evaluation of the downscaling performance of five surface variables from 2016 to 2021 using Root Mean Square Error (RMSE), Anomaly Correlation Coefficient (ACC), Structure Similarity Index Measure (SSIM) and Peak Signal-to-Noise Ratio (PSNR) based on three different downscaling methods, including linear interpolation (Lerp), deterministic model (EDSR-GAN) and Diffusion Probabilistic Downscaling Model (DPDM) with different numbers of members

RMSE/ACC/ SSIM/ PSNR	U_{10m} (m/s)	V_{10m} (m/s)	T_{2m} (°C)	SP (Pa)	TP (mm/day)
Lerp	0.452/0.890/0.903/31.04	0.432/0.528/0.918/31.16	2.524/0.879/0.885/29.35	3191.654/0.822/0.876/24.998	1.197/0.8460/0.925/34.087
EDSR-GAN	0.203/0.864/0.981/39.011	0.199/0.842/0.980/39.247	0.867/0.880/0.987/29.698	106.178/0.887/0.99968/53.448	0.970/0.847/0.729//34.912
DPDM _{single}	0.398/0.692/0.941/33.156	0.457/0.601/0.905/28.083	1.295/0.785/0.936/32.585	159.406/0.726/0.99943/51.070	2.670/0.679/0.569/26.242
DPDM ₃₃	0.185/0.901/0.983/34.37	0.193/0.877/0.981/34.234	0.677/0.943/0.992/38.268	108.225/0.892/0.99969/52.073	0.915/0.872/0.948/37.075
DPDM ₁₀₀	0.175//0.911/0.984/33.322	0.181/0.895/0.984/37.085	0.657/ 0.947/0.994/39.256	106.706/0.899/0.99969/51.065	0.886/0.878/0.948/37.095

All differences are statistically significant at the 95% confidence level. Bold font highlights the best performance metrics.

各种气象数据的一致结果表明，DPDM 在关键指标方面优于其他模型，包括异常相关系数（ACC）、峰值信噪比（PSNR）、结构相似性指数测量（SSIM）和均方根误差（RMSE）。

结果比较



Supplementary Figure 4. Comparison of total precipitation downscaling results



泛在计算与智能系统研究中心
Research Center of Ubiquitous Computing and Intelligent Systems



哈爾濱工業大學
Harbin Institute of Technology

THANKS