

基于残差注意力与动态上采样的气象超分算法

朱笑言, 胡 靖

(成都信息工程大学 计算机学院, 四川 成都 610225)

摘要: 气象图像分辨率对于研究气候现象至关重要。虽然基于深度学习的气象超分方法取得了快速发展, 且在学习低分辨率图像特征方面能力不断加强, 但是当前的上采样方法主要基于反卷积、插值和亚像素卷积, 都会在一定程度上产生伪影, 且在上采样过程中容易丢失特征, 从而导致最终的重建效果不佳。为了在上采样过程中更好地利用低分辨率特征以提升上采样质量, 提出一种基于残差注意力和动态上采样的气象超分算法 RANSR, 其框架由低分辨率特征提取模块、动态上采样模块以及高分辨率特征融合模块三部分构成。其中, 低分辨率特征提取模块基于深度残差注意力网络强化特征学习; 动态上采样模块通过内容感知的重组机制生成更准确的上采样特征, 同时增强模型泛化能力; 高分辨率特征融合模块则融合了包括高程和气候态辅助输入, 进一步增强最终重建效果。在降雨4倍、降雨10倍、2 m 气温4倍和2 m 气温10倍超分实验中, 本方法在5个对比方法中表现最佳: 相较于性能第二的方法, 其MSE分别降低了32.0%、21.4%、27.3%和55.9%; PSNR分别提升了4.2%、3.3%、4.2%和12.1%。

关键词: 超分辨率; 深度学习; 上采样; 注意力机制; 降雨

DOI: 10.11907/rjtk.251313

扫描二维码阅读全文: 

中图分类号: TP389.1

文献标识码: A

文章编号: 1672-7800(2026)007-0161-08

Meteorological Supersampling Algorithm Based on Residual Attention and Dynamic Upsampling

ZHU Xiaoyan, HU Jing

(College of Computer, Chengdu University of Information Engineering, Chengdu 610225, China)

Abstract: Meteorological image resolution is crucial for studying climate phenomena. Although meteorological over-sampling methods based on deep learning have made rapid development, and the ability to learn low-resolution image features has been continuously strengthened. However, the up-sampling of current methods is mainly based on inverse convolution, interpolation and sub-pixel convolution; all three methods cause certain artifacts, and features are lost during up-sampling resulting in poor reconstruction results. In order to better utilize the low-resolution features in upsampling and thus improve the quality of upsampling, this paper proposes a meteorological supersampling algorithm based on residual attention and dynamic upsampling - RANSR, including a low-resolution feature extraction module, a dynamic upsampling module and a high-resolution feature fusion module. Among them, the low-resolution feature extraction module strengthens feature learning based on deep residual attention network, the dynamic up-sampling module generates more accurate up-sampled features and enhances the model generalization ability through the content-aware restructuring mechanism, and the high-resolution feature fusion module fuses the auxiliary inputs including elevation and climate state to enhance the final reconstruction effect. In the rainfall 4-fold, rainfall 10-fold, 2m temperature 4-fold, and 2m temperature 10-fold supersampling experiments, comparing the five meteorological supersampling methods, the MSE is reduced by 32.0%, 21.4%, 27.3%, and 55.9%, respectively, and PSNR is improved by 4.2%, 3.3%, 4.2%, and 12.1%, respectively, compared with the method with the second best performance.

Key Words: super-resolution; deep learning; up-sampling; attentional mechanisms; precipitation

收稿日期: 2025-05-23

基金项目: 国家自然科学基金项目(42375148); 国家重点研发计划项目(2020YFA0608000); 四川省科技计划项目(2024NSFTD0043, 2024ZDZX0020); 四川省科技成果转化示范项目(2024ZHCG0176, 2024ZHCG0190)

作者简介: 朱笑言(1998-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为智慧气象; 胡靖(1986-), 女, 博士, 成都信息工程大学计算机学院教授、硕士生导师, 研究方向为图像处理与模式识别、强化学习与应用、智慧气象。本文通讯作者: 胡靖。

0 引言

气候变化与人类日常生活息息相关,气象研究中图像分辨率至关重要。近年来,随着计算机技术的高速发展,基于机器学习和深度学习的图像超分算法陆续应用到气象研究中^[1-4]。自SRCNN^[5]提出以来,Vandal等^[6]提出了一种堆叠的SRCNN架构——DeepSD,是最早基于深度学习的气象超分模型;Kolukula等^[7]基于SRCNN的变体研究了印度风场的超分辨率重建。此后,基于卷积神经网络的图像超分算法成为了主流,在SRCNN基础上Dong等^[8]提出了FSRCNN,进一步优化了SRCNN的性能;Passarella等^[9]提出了FSRCNN-esm,并在FSRCNN反卷积后增加了一个额外的卷积层,增强了高分辨率重建特征的精确度。但是,基于SRCNN和FSRCNN的气象超分辨率方法,使用反卷积作为上采样,不仅会出现过拟合,而且计算量较大。Odena等^[10]提出反卷积会导致“棋盘伪影”,影响高分辨率重建性能。

此外,He等^[11]提出残差网络(ResNet),后续科学家们利用残差提出了一系列超分算法^[12-13]。Mu等^[14]提出基于残差连接的编码器—解码器网络RedNet,并利用反卷积将低分辨率特征图上采样到目标分辨率。Liu等^[15]提出了YNet,该网络基于残差连接的编码器—解码器结构构建,在低分辨率空间中使用反卷积操作,并在反卷积之后增加了卷积层以缓解反卷积可能引起的“棋盘伪影”现象。同时,采用双线性插值方法将低分辨率特征图映射到高分辨率空间。Chandel等^[16]基于YNet提出了YNet-D和YnetDE,用于印度地区的极端降雨数据超分辨率重建。Ding等^[17]提出了UNR-Net,用于中国华北地区2 m温度的超分辨率重建。该方法基于残差连接和注意力机制,但在上采样模块中采用与YNet相似的最邻近插值加卷积的方式。然而,最邻近和双线性上采样仅通过像素点的空间位置来决定上采样核,未能充分利用特征图的语义信息,且感知域相对较小。

随着ESPCN使用亚像素卷积作为上采样,并提升了重建精度,残差网络+亚像素卷积的网络架构成为了主流^[18]。Kim等^[19]提出VDSR,这是第一个将残差模块引入到图像超分辨率任务的研究。随后,Lim等^[20]提出了EDSR,摒弃了归一化层的使用,在超分任务中大大节省了计算资源。

近年来,多位科学家基于残差学习理论提出了一系列气象超分辨率方法。Kerinch等^[21]基于EDSR在风能和太阳能数据上进行超分实验,取得了不错的效果。Jha等^[22]探讨了EDSR、VDSR和SRCNN等方法在2 m气温超分辨率上的表现,实验表明,采用残差网络的深度学习模型有更好的表现。Wang等^[23]基于深度残差的气象超分模型SRDRN,能够完全提取空间特征,因此具备良好的泛化能

力。Murukesh等^[24]基于SRDRN研究了印度地区的降雨超分辨率重建。此后,Zhang等^[25]提出密集残差网络,增强了超分模型对低分辨率特征的学习能力。Fu等^[26]基于密集残差+亚像素卷积提出了RRDBNet,用于黄河中游降水的高分辨率重建。Hsu等^[27]采用了多尺度残差网络(MS-RN)的分层架构,实现了台湾地区降雨数据的20倍超分辨率。上述网络中的亚像素卷积,通过将通道维度重新排列到空间维度来实现超分辨率重建,但在应用中受到通道数量的限制,在进行高倍数超分辨率时,会牺牲部分特征。此外,由于输出像素依赖特征图的不同通道,跨通道的信息映射会导致重建图像显得不自然,局部出现不连贯。

近年来,计算机领域在上采样的方法中取得了多项创新。Woo等^[28]提出了适用于目标检测的优秀轻量级上采样算子DLU,展现了比内容感知特征重组(CARAFE)更优秀的效果^[29]。DLU基于CARAFE,通过引入可学习的指导偏移量从内核空间对大规模内核进行采样,避免了在上采样中引入大量可训练参数。此外,Wang等^[30]提出了3DCAFU,将CARAFE应用到三维上采样工作中,取得了优异的效果。尽管这些灵活轻量的优秀上采样算子已广泛应用于图像分割和目标识别等领域,但它们在气象数据超分辨率中的应用尚未得到充分研究。

随着卷积注意力机制(CBAM)的出现,近年来科学家们开始尝试在超分方法中引入注意力机制,以此来提升超分辨率的精度^[31]。例如,Chiang等^[32]利用YNet+CBAM强化图像特征的提取,该项工作能够提高网络在低分辨率空间的特征学习能力;值得一提的是,基于注意力机制的超分方法在遥感领域也取得了显著成效^[33]。此外,吴笛凡等^[34]探索了将残差学习与注意力机制相结合的方法,进一步提升了图像超分的精度。除了注意力机制的引入,科学家们还通过优化损失函数来提升超分精度。例如,Ascenso等^[35]提出了RA-U,该方法通过复合损失函数优化,显著提升了基于U-Net的降雨超分辨率重建效果。

因此,本文基于残差注意力和动态上采样算子提出了一个适用于任意倍数的灵活气象超分算法——RANSR(Deep Residual Attention Network for Super-Resolution)。本文主要贡献如下:

(1)融合了残差学习和注意力机制的优点,在低分辨率气象图像特征提取方面表现出良好性能。该方法能够更好地在小尺度空间学习到更多有用特征,从而增强了细节表达能力。

(2)提出了一种新的动态上采样方法。该方法基于动态核预测和特征重组技术,通过引入通道注意力筛选关键信息,并采用轻度通道压缩策略以节省计算资源,是目前较为鲜有的将注意力机制引入上采样阶段的研究,成功解决了传统上采样方法中存在的问题。

(3)提出一种基于残差注意力和动态上采样的气象模型。实验表明,该方法在多个气象数据的不同倍数超分重

建中,不仅保持了最好的稳定性,还具有更高的重建质量与视觉效果。

1 网络结构

RANSR 由低分辨率特征提取模块、动态上采样模块和高分辨率特征融合模块三部分组成。由于气象数据本质上是物理量与时空信息高度关联的,因此输入为低分辨率气象数据和时空特征,这些时空特征包括时间信息、经纬度信息和海陆位置信息。输入先经过一个 3×3 的卷积层进行初步特征提取,随后进入低分辨率特征提取模块,以加强对低分辨率特征的学习。该模块由多个深层残差

注意力块连接而成。随着超分倍数的增加,残差注意力块的层数也相应增加:四倍超分为 16 层,十倍超分为 24 层。经过低分辨率特征提取模块处理后得到的特征图被输入到动态上采样模块中。动态上采样模块由两个主要部分组成:动态核生成模块和特征重组模块。其中,动态核生成模块根据特征图的不同位置自动生成多个上采样核,而特征重组模块则对特征图的不同区域应用相应的上采样核进行点积操作,从而重建出高质量的高分辨率特征图。高分辨率特征融合模块将高程数据作为辅助输入,通过额外的通道与上采样后的特征图进行拼接。最后,通过一个 3×3 的卷积层生成最终的输出图像。具体的网络结构如图 1 所示。




Fig. 1 RANSR network structure

图 1 RANSR 网络结构

1.1 低分辨率特征提取模块

低分辨率特征提取模块是一个深层网络,由多个残差注意力块串联组成。构建深层网络易导致梯度消失与特征退化,为应对这一问题,网络中引入了残差块进行缓解。此外,由于低分辨率图像可利用的特征较少,这对学习的特征质量提出了更高要求。为此,本文在残差块中引入了卷积注意力模块(CBAM),旨在增强对低分辨率特征的表

征能力。批量归一化(Batch Normalization)已被证明能够提升超分辨率任务中的性能,但当训练和测试数据集的统计数据差异很大时,往往会引入伪影,并限制泛化能力。本文在残差注意力块中使用实例归一化(Instance Normalization),该方法对每个样本单独计算均值和方差,加速模型收敛,并保持每个图像实例之间的独立,从而提高模型的稳定性和泛化能力。残差注意力块结构如图 2 所示。




Fig. 2 Residual attention block structure

图 2 残差注意力块结构

卷积注意力模块(Convolutional Block Attention Module, CBAM)和实例归一化(Instance Normalization, IN)用以增强网络对低分辨率特征的提取能力。CBAM 由通道注意力模块(Channel Attention Module, CAB)和空间注意力模块(Spatial Attention Module, SAB)组成,具体结构如图 3 所示。其中,CAB 通过平均池化和最大池化操作聚合特征图空间信息,生成两个不同的空间上下文描述符 F_{avg} 和 F_{max} 。这两个描述符被转发到多层感知器(MLP)共享网络中,并由 Sigmoid 函数得到通道注意力图。CAB

通过提高网络对通道间依赖关系的学习,自适应调整每个通道的特征相应,从而增强网络对重要特征的提取能力。SAB 沿着通道轴使用平均池化和最大池化操作,将两者合并通过一个 3×3 卷积,同时,使用 Sigmoid 函数得到空间维度注意力图。SAB 使网络能够关注图像中的重要区域,从而增强对目标区域的特征表示。

1.2 动态上采样模块

针对现有上采样手段存在的不足,本文设计了动态上采样模块,主要分为两个部分:带有通道注意力(ECA-




Fig. 3 Convolutional block attention module structure

图3 卷积注意力模块结构

Net)的动态核生成模块和特征重组模块^[36]。动态上采样模块在动态核生成模块中引入了通道注意力机制,并采用轻度通道压缩策略。在进行通道压缩前,先对输入特征施加通道注意力,以增强通道间的信息建模能力。注意力机制能够有效挖掘输入特征中关键通道的重要性分布,从而在后续压缩过程中保留更具语义代表性的特征分量。此外,该模块采用轻度压缩,保证不增加计算资源的同时,尽可能减少通道维度上的信息损失。在本文方法中,通道数由64压缩到32。经过这一策略得到的特征图表示如公式(1)所示:

$$X_c = \text{Conv}_{3 \times 3}(\text{Conv}_{1 \times 1}(A(X_u))) \quad (1)$$




Fig. 4 Dynamic upsampling structure

图4 动态上采样结构

1.3 高分辨率特征融合模块

受Liu等^[37]和Tie等^[38]的研究启发,在模型中引入了辅助输入以改进结果。在整个训练和测试过程中,该输入与目标分辨率相同,且在不同月份保持不变。辅助输入作为高程数据,通过额外的通道连接到上采样层的输出后的拼接层。

模型的最后一部分是融合层,它采用通道级拼接和两层卷积来实现特征融合。具体来说,融合层由一个高分辨率特征拼接层和一个卷积核为 3×3 的卷积层组成。在融合层内部,首先将主干网络重建的高分辨率特征与辅助通道提供的高分辨率辅助输入在通道维度上进行拼接;然后,使用一个带有ReLU激活的 3×3 卷积层提取融合后的局部空间信息和通道间关系;最终,得到的结果经过一个 1×1 的卷积层进行通道压缩。这里需要注意的是,该卷积层仅将通道数调整为1用作输出,不涉及特征的学习。

1.4 训练策略与损失函数

本文实验中,采用分段训练策略。前100轮学习率为

经过通道压缩后的特征参与动态核生成。动态核生成中,首先压缩得到尺寸为 (N, C', H, W) 的特征经过 $k \times k$ 卷积输出尺寸 $(N, s^2 \times k^2, H, W)$ 特征图,随后,经过亚像素卷积将 s^2 通道变换为 (sH, sW) 的尺寸,利用softmax在每个位置上对 k^2 个卷积核权重归一化,实现动态核生成。其中, s 为超分倍数, k 为卷积核大小,本文中 $k=3$ 。最后,通过提取输入特征的领域并展开,与动态核进行矩阵乘法运算,其结果再经由亚像素卷积实现特征重组,如图4所示。该设计能最大程度利用上一模块提取特征,从而提升上采样过程中图像边缘、结构细节及局部纹理的还原效果,同时兼具强大的灵活性。

$1e-4$,选择均方差损失(Mean Square Error Loss)学习浅层特征;100轮后引入感知损失(Perceptual Loss)组成联合损失函数,用以增强纹理特征和高频信息学习,如公式(2)所示。所有模型均训练300轮,随后,每训练100轮,学习率缩小10倍。

$$L = \alpha \cdot l_{MSE} + \beta \cdot l_{Perceptual} \quad (2)$$

2 实验设计

2.1 数据准备

气温超分实验输入数据使用来自英国国家大气科学中心(CRU v4)的月平均数据。数据分辨率为 $1^\circ \times 1^\circ$ 。该数据空间范围覆盖全球,时间长度为1901年1月—2019年12月。所使用的标签数据来源于欧洲中期天气预报中心(ECMWF)的月平均再分析数据ERA5。ERA5覆盖全球,且具有 $0.25^\circ \times 0.25^\circ$ 和 $0.1^\circ \times 0.1^\circ$ 两种空间分辨率,时间范围为1940年1月至今。CRUv4和ERA5均为公开数据集。降

水超分实验中,因为 CRUv4 和 ERA5 单位不一致,故使用 ERA5 数据集,对 $0.25^{\circ}\times 0.25^{\circ}$ 和 $0.1^{\circ}\times 0.1^{\circ}$ 的 ERA5 数据下采样到 $1^{\circ}\times 1^{\circ}$ 作为输入。

数字高程数据作为辅助输入,该数据来自中国时空三极环境大数据平台公开数据集——1 km 分辨率数字高程数据。因其分辨率与标签不一致,在实验前通过平均最近相邻位置来对齐它们。

本文 4 倍超分实验数据选取经度为 $70.5\text{E}\text{--}135.5\text{E}$,纬度为 $14.5\text{N}\text{--}56.5\text{N}$ 网格。该网格包含整个中国大陆区域,输入数据尺寸为 42×65 ,标签尺寸为 168×260 。10 倍超分实验中,选取数据经度为 $105.5\text{E}\text{--}125.5\text{E}$,纬度为 $16.5^{\circ}\text{N}\text{--}36.5^{\circ}\text{N}$ 网格。该网格包含中国东南沿海区域,输入数据尺寸为 20×20 ,标签尺寸为 200×200 。为排除海洋数据干扰,使用海陆掩码将海洋区域值设为 0。海陆掩码来自 ECMWF。实验结果图像中的地图边界和区划来自标准地图库 china-shapefiles。

实验中,所有数据集和标签均采用 1950 年 1 月—2009 年 12 月期间共 720 个月的月平均 2 m 气温和降雨数据。其中,前 624 个月(1950 年 1 月—2001 年 12 月)作为训练集;随后的 48 个月(2002 年 1 月—2005 年 12 月)作为验证集;最后 48 个月(2006 年 1 月—2009 年 12 月)作为测试集。

输入共有 7 个通道:低分辨率数据(2 m 气温或降水)、年、月、纬度、sin 方向经度、cos 方向经度和掩码。其中,两个方向的经度特征属于特征增强方法。多通道输入的依据参考如表 1 所示,该表显示有 5 个通道与气象要素具有一定相关性。

Table 1 Correlation between climate elements and corridors

表 1 要素与各通道间的相关性

通道	年	月	纬度	经度	掩码
气温	0.20	0.25	-0.48	-0.90	0.29
降水	0.22	0.37	0.28	0.33	0.32

2.2 实验设置

所有实验均在配置 Intel Xeon Platinum(2.90 GHz, 32 核)、72 GB 内存和 NVIDIA GeForce RTX 3090(24 GB)显卡的服务器上进行,操作系统为 Ubuntu22.04,python 版本 3.12,pytorch 版本 2.5.1。实验迭代次数(epoch)为 300,初始学习率设置为 0.000 1,采用分阶段训练策略,并使用 StepLR 阶梯学习率调整策略。每 100epoch 学习率衰减一次,衰减系数(gamma)设为 0.1,选择 Adam(Adaptive Moment Estimation)作为更新模型参数的优化函数。实验采取批处理方式,图像批量大小(batchsize)为 64,设置固定随机种子值为 123,以保证实验条件一致性。

2.3 实验评估指标

峰值信噪比(PSNR)是图像领域中常用度量,其值越大表示结果越好。均方误差 MSE 常用来衡量重建结果与真值之间的误差,计算公式如公式(3)所示。

MSE = \frac{1}{m} \sum_{i=1}^m (y_p^{(i)} - y_t^{(i)})^2

其中, y_p 为重建结果, y_t 为真值, MSE 越低表示误差越小。结构相似性指数 SSIM 也是图像领域常用度量,用来比较重建图像和真值图像间相似程度,计算公式如公式(4)所示。

SSIM(x, y) = [l(x, y)^{\alpha} \cdot c(x, y)^{\beta} \cdot s(x, y)^{\gamma}]

其中, $l(x, y)^{\alpha}$ 、 $c(x, y)^{\beta}$ 和 $s(x, y)^{\gamma}$ 分别代表图像亮度、对比度和结构, SSIM 越高表示重建图像与真值越相似。此外,本文引入了 R^2 用来评价模型的拟合效果,计算公式如公式(5)所示:

R^2 = 1 - \frac{\sum_i (y_p^{(i)} - y_t^{(i)})^2}{\sum_i (\bar{y} - y_t^{(i)})^2}

其中, y_p 代表重建结果, y_t 代表真值, $\bar{y}$ 代表样本均值。 R^2 值越接近 1,表明模型拟合效果越好;越接近 0,表明模型拟合效果越差。

为了衡量模型的效率,本文在实验中还引入了时间和参数量,分别用于衡量模型在时间和空间上的效率。

2.4 实验结果与分析

本文对月平均 2 m 气温与月降水量分别进行了 4 倍、10 倍的超分实验,同时比较了 5 种气象超分方法(FSRCNN-esm、SRDRN、YNet-CBAM、DeepRU、RRDBNet)的性能,实验结果如表 2 和表 3 所示。实验表明,RANSR 取得了最佳表现,训练用时仅次于 FSRCNN-ESM,参数量仅高于 FSRCNN-ESM 和 YNet-CBAM。

Table 2 Results of 4-fold and 10-fold super-resolution experiments on monthly precipitation

表 2 月降水 4 倍、10 倍超分实验结果

超分倍数	模型名称	MSE	PSNR	SSIM	R ²	时间/s	参数量
×4	SRDRN	0.000 22	36.54	0.89	0.86	1 771	4 432 384
	FSRCNN-ESM	0.000 58	32.36	0.87	0.64	1 039	308 421
	DeepRU	0.000 35	34.59	0.86	0.78	3 013	21 389 441
	YNet-CBAM	0.000 29	35.75	0.88	0.85	1 679	1 827 272
	RRDBNet	0.000 23	36.45	0.89	0.86	1 736	4 911 168
	RANSR	0.000 15	38.07	0.92	0.93	1 638	3 204 647
×10	SRDRN	0.001 4	28.30	0.86	0.85	2 130	4 455 314
	FSRCNN-ESM	0.001 7	27.57	0.85	0.82	1 121	373 682
	DeepRU	0.003 0	25.29	0.75	0.70	3 369	27 139 213
	YNet-CBAM	0.002 0	26.28	0.84	0.77	1 691	1 827 272
	RRDBNet	0.001 8	26.97	0.83	0.81	1 763	4 907 520
	RANSR	0.001 1	29.24	0.88	0.88	1 686	3 380 231

在降雨 4 倍降尺度实验中,RANSR 在四项评估指标中均展现出最优性能。其中,MSE 较第二名的 SRDRN 模型降低了 32.0%,PSNR 提升了 4.2%,SSIM 提高了 0.03, R^2 增加了 0.07。在降雨 10 倍降尺度的实验中,RANSR 同样在 4 个评估指标中取得了最优成绩。具体而言,MSE 较第二名

Table 3 Results of 4x and 10x super-resolution experiments on monthly 2m temperatures

表 3 月 2m 气温 4 倍、10 倍超分结果

超分 倍数	模型名称	MSE	PSNR	SSIM	R ²	时间/s	参数量
×4	SRDRN	0.000 66	31.78	0.96	0.98	1 897	2 770 611
	FSRCNN-ESM	0.008 7	20.56	0.73	0.81	1 126	640 312
	DeepRU	0.001 4	28.40	0.91	0.97	3 109	18 999 926
	YNet-CBAM	0.001 2	27.89	0.96	0.96	1 791	1 833 605
	RRDBNet	0.001 1	27.96	0.88	0.95	1 872	2 695 680
	RANSR	0.000 48	33.13	0.96	0.99	1 734	2 460 787
	SRDRN	0.000 96	29.67	0.92	0.94	2 006	3 455 314
	FSRCNN-ESM	0.002 6	25.77	0.80	0.87	1 209	673 156
×10	DeepRU	0.003 7	24.29	0.92	0.82	3 452	22 435 793
	YNet-CBAM	0.000 60	31.54	0.97	0.95	1 816	1 833 605
	RRDBNet	0.000 43	33.21	0.93	0.97	1 893	4 087 168
	RANSR	0.000 19	37.22	0.98	0.99	1 805	3 314 267

的 SRDRN 降低了 21.4%, PSNR 提升了 3.3%, SSIM 提高了 0.02, R² 增加了 0.03。

RANSR 在 2 m 气温 4 倍降尺度实验中, 在 4 个指标上均取得了最优性能。其中, MSE 比第二名的 SRDRN 模型降低了 27.3%, PSNR 提高了 4.2%。在 2 m 气温 10 倍降尺度实验中, RANSR 同样在 4 个指标上表现最优。其中, MSE 比第二名的 RRDBNet 降低了 55.8%, PSNR 提高了 12.1%; SSIM 比第二名的 YNet 提升了 0.01, R² 则比第二名的 RRDBNet 增加了 0.02。

如图 5 和图 6 所示, 在 4 倍超分的实验中, RANSR 与其他 5 种方法进行了对比, 基于 2006 年 1 月—2009 年 12 月的降水和 2 m 气温 MSE 数据。由于 RANSR 引入了时空特征及 CBAM+IN 模块, 其在 MSE 方面表现出最优性能, 同时保持了最好的稳定性。此外, 降雨数据展示出显著的周期性, 这导致在春冬月份的预测结果优于夏秋月份。




Fig. 5 MSE of precipitation 4x super-resolution during January 2006–December 2009

图 5 2006 年 1 月—2009 年 12 月降水 4 倍超分辨率 MSE




Fig. 6 MSE of 2m air temperature 4x super-resolution

图 6 2m 气温 4 倍超分辨率 MSE

2.5 消融实验

为了验证各模块对模型性能的贡献, 本文设计了一系列消融实验, 实验结果如表 4 所示。通过逐步添加模型中的关键组件, 分析它们对最终性能的影响。这些组件包括动态上采样模块、CBAM 和高分辨率融合模块。在相同的数据集和超参数设置下, 进行了 10 倍 2 m 气温降尺度实验, 基准模型为不含任何模块的网络, 最终模型 (Final) 为

RANSR。

加入高分辨率融合模块后, 模型的性能得到了显著提升, MSE 降低了 53.6%, PSNR 提高了 21.6%, SSIM 提升了 0.11, R² 提升了 0.04。实验结果表明, 该模块对模型性能提升的贡献最大; 通过引入 CBAM, 模型的性能得到了明显提升, 这得益于 CBAM 显著提高了模型的特征提取能力。动态上采样模块的性能提升较为均衡, 这表明该模

块对模型性能的改进具有重要作用。

Table 4 Results of ablation experiments

表 4 消融实验结果

模型名称	MSE	PSNR	SSIM	R ²
基准模型	0.001 10	29.55	0.84	0.93
基准模型+CBAM	0.000 55	35.56	0.89	0.96
基准模型+动态上采样	0.000 67	33.23	0.89	0.95
基准模型+高分辨率融合	0.000 51	35.92	0.95	0.97
RANSR	0.000 19	37.22	0.98	0.99

3 结语

本文提出了一个具有深度残差注意力模块的方法 RANSR, 用于多个气象要素的超分任务。该方法使用残差学习+注意力机制强化低分辨率特征学习。通过采用动态上采样模块, RANSR 显著提升了模型对特征的利用率和泛化能力, 从而提高了高分辨率重建的质量, 并成功避免了“棋盘伪影”现象。高分辨率融合层通过融合辅助输入, 进一步增强了高分辨率重建的效果。RANSR 在不同超分倍数的实验中均表现出优越的性能。本文与其他 5 种方法对比, 在以 MSE、PSNR、SSIM 和 R² 作为评估指标的实验中, RANSR 在所有指标上均取得了最优成绩。在连续月份的超分实验中, 实验结果证明了 RANSR 的稳定性。此外, 设计了消融实验, 进一步探究了各模块对模型性能的具体影响。

尽管当今深度学习技术的迅速发展为气象超分提供了更多更先进的方法, 但仍需关注气象数据之间的差异性, 并致力于提高气象超分模型在不同场景下的泛化能力。以计算机技术为基础, 融合气象专业知识将是该领域未来发展的关键重点。

参考文献:

[1] SUN X, LI X G, LI J F, et al. Research progress on image super-resolution restoration based on deep learning[J]. Journal of Automation, 2017, 43(5): 697-709.
孙旭, 李晓光, 李嘉峰, 等. 基于深度学习的图像超分辨率复原研究进展[J]. 自动化学报, 2017, 43(5): 697-709.

[2] LI Y K, WANG X J, MA Y F, et al. AMSR-2 surface temperature downscaling study based on machine learning algorithm[J]. Remote Sensing Technology and Applications, 2022, 37(2): 474-487.
李永康, 王新军, 马燕飞, 等. 基于机器学习算法的 AMSR-2 地表温度降尺度研究[J]. 遥感技术与应用, 2022, 37(2): 474-487.

[3] LI X F, YUAN Z G, DENG W H, et al. A spatial downscaling method for 2 m air temperature by integrating multiple machine learning models[J]. Remote Sensing for Natural Resources, 2023, 35(1): 57-65.
李显凤, 袁正国, 邓卫华, 等. 融合多种机器学习模型的 2 m 气温空间降尺度方法[J]. 自然资源遥感, 2023, 35(1): 57-65.

[4] XIE M, YANG C L, GU M J, et al. Super-resolution reconstruction of Fengyun-4 satellite images based on deep learning[J]. Infrared, 2023, 44(7): 46-52.

谢梦, 杨春蕾, 顾明剑, 等. 基于深度学习的风云四号卫星图像超分辨率重建[J]. 红外, 2023, 44(7): 46-52.

[5] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 38(2): 295-307.

[6] VANDAL T, KODRA E, GANGULY S, et al. DeepSD: generating high resolution climate change projections through single image super-resolution[C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2017: 1663-1672.

[7] KOLUKULA S S, MURTY P L N, BADURU B, et al. Downscaling of wind fields on the east coast of India using deep convolutional neural networks and their applications in storm surge computations[J]. Journal of Water and Climate Change, 2024, 15(4): 1612-1628.

[8] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network[C]//Computer Vision-ECCV 2016: 14th European Conference, 2016: 391-407.

[9] PASSARELLA L S, MAHAJAN S, PAL A, et al. Reconstructing high resolution ESM data through a novel fast super resolution convolutional neural network (FSRCNN)[J]. Geophysical Research Letters, 2022, 49(4): e2021GL097571.

[10] ODENA A, DUMOULIN V, OLAH C. Deconvolution and checkerboard artifacts[J]. Distill, 2016, 1(10): e3.

[11] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

[12] BAI H, BAI T Z. A super-resolution reconstruction algorithm for infrared images based on deep residual neural network[J]. Infrared Technology, 2024, 46(2): 176-182.
白皓, 白廷柱. 基于深度残差神经网络的红外图像超分辨率重构算法[J]. 红外技术, 2024, 46(2): 176-182.

[13] ZHONG M Y, JIANG L, LI C. Super-resolution image reconstruction algorithm with multi-scale feature extraction residual network[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2024, 36(1): 76-85.
钟梦圆, 姜麟, 李超. 多尺度特征提取残差网络的超分辨率图像重建算法[J]. 重庆邮电大学学报(自然科学版), 2024, 36(1): 76-85.

[14] MU B, QIN B, YUAN S, et al. A climate downscaling deep learning model considering the multiscale spatial correlations and chaos of meteorological events[J]. Mathematical Problems in Engineering, 2020(1): 7897824.

[15] LIU Y, GANGULY A R, DY J. Climate downscaling using YNet: a deep convolutional network with skip connections and fusion[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2020: 3145-3153.

[16] CHANDEL V S, BANERJEE B, KARMAKAR S, et al. Deep learning based statistical downscaling for enhanced representation of indian monsoon rainfall with subseasonal variability and extremes[J]. JGR Atmospheres, 2025, 130(19): e2025JD044167.

[17] DING S, ZHI X, LYU Y, et al. Deep learning for daily 2-m temperature downscaling[J]. Earth and Space Science, 2024, 11(2): e2023EA003227.

[18] SHI W, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1874-1883.

[19] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very

- deep convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646–1654.
- [20] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017: 136–144.
- [21] KURINCHI-VENDHAN R, LÜTJENS B, GUPTA R, et al. Wisosuper: benchmarking super-resolution methods on wind and solar data[DB/OL]. <https://arxiv.org/abs/2109.08770>.
- [22] JHA S K, GUPTA V. Deep learning super-resolution for temperature data downscaling: a comprehensive study using residual networks[J]. *Frontiers in Climate*, 2025, 7: 1572428.
- [23] WANG F, TIAN D, LOWE L, et al. Deep learning for daily precipitation and temperature downscaling[J]. *Water Resources Research*, 2021, 57(4): e2020WR029308.
- [24] MURUKESH M, KUMAR P. Downscaling and reconstruction of high-resolution precipitation fields using a deep residual neural network: an assessment over Indian subcontinent[C]//EGU General Assembly Conference Abstracts, 2024: 2552.
- [25] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 2472–2481.
- [26] FU H, GUO J, DENG C, et al. Deep-learning-based downscaling of precipitation in the middle reaches of the Yellow River using residual-based CNNs[J]. *Quarterly Journal of the Royal Meteorological Society*, 2024, 150(760): 3290–3304.
- [27] HSU L H, CHIANG C C, LIN K L, et al. Downscaling Taiwan precipitation with a residual deep learning approach[J]. *Geoscience Letters*, 2024, 11(1): 23.
- [28] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3–19.
- [29] FU R, HU Q, DONG X, et al. Lighten CARAFE: dynamic lightweight upsampling with guided reassemble kernels[C]//International Conference on Pattern Recognition, 2024: 383–399.
- [30] WANG J, CHEN K, XU R, et al. Carafe: content-aware reassembly of features[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3007–3016.
- [31] SONG Y, FU R, HU Q, et al. Content-aware feature upsampling for voxel-based 3D semantic segmentation[C]//International Conference on Pattern Recognition, 2025: 411–426.
- [32] CHIANG C H. Climate downscaling: a deep-learning based super-resolution model of precipitation data with attention block and skip connections[D]. Taiwan: Taiwan Normal University, 2023.
- [33] WEI X Y, MENG G, ZHANG H P, et al. Arbitrary-scale super-resolution reconstruction of remote sensing images based on meta-learning and dense residual attention[J]. *Journal of Remote Sensing*, 2024, 28(7): 1735–1745.
- 魏小源, 孟钢, 张浩鹏, 等. 基于元学习和密集残差注意力的遥感图像任意尺度超分辨率重建[J]. *遥感学报*, 2024, 28(7): 1735–1745.
- [34] WU D F, ZHANG X D. Residual learning combined with layer attention for lightweight image super-resolution[J]. *Chinese Journal of Liquid Crystal and Display*, 2024, 39(10): 1391–1401.
- 吴笛凡, 张选德. 残差学习与层注意力相结合的轻量级图像超分辨率[J]. *中国液晶与显示杂志*, 2024, 39(10): 1391–1401.
- [35] ASCENSO G, FICCHÌ A, GIULIANI M, et al. Downscaling, bias correction, and spatial adjustment of extreme tropical cyclone rainfall in ERA5 using deep learning[J]. *Weather and Climate Extremes*, 2024, 46: 100724.
- [36] GUO Z, MA D, LUO X. A lightweight semantic segmentation algorithm integrating CA and ECA-Net modules[J]. *Optoelectronics Letters*, 2024, 20(9): 568–576.
- [37] LIU J, SUN Y, REN K, et al. A spatial downscaling approach for wind-sat satellite sea surface wind based on generative adversarial networks and dual learning scheme[J]. *Remote Sensing*, 2022, 14(3): 769.
- [38] TIE R, SHI C, WAN G, et al. CLDASSD: reconstructing fine textures of the temperature field using super-resolution technology[J]. *Advances in Atmospheric Sciences*, 2022, 39(1): 117–130.

(责任编辑:陈维捷)