

基于注意力信息关注与渐进梯度约束的二值化超分辨率网络*

黄家锋, 吴丽君

(福州大学 物理与信息工程学院, 福建 福州 350108)

摘要: 基于 Transformer 的网络在图像超分辨率任务上表现优异, 但高昂的内存和计算成本限制了它在实际中的应用部署。为此, 基于 SwinIR 网络实现了一个二值化的轻量化超分辨网络 BiSR-AG。首先, 利用现有的二值方法基于 SwinIR 实现了一个二值化基线网络。进一步, 设计了一个基于注意力信息关注模块以充分匹配二值化模型的信息容量。此外, 使用了渐进梯度更新区间约束训练策略来缓解注意力机制中存在部分参数不更新的问题。实验证明, BiSR-AG 网络有效压缩了模型大小, 并保持了较好的重建效果和感知质量。

关键词: 二值化网络; 超分辨率; 计算机视觉; 注意力信息

中图分类号: TP391

文献标志码: A

DOI: 10.19358/j.issn.2097-1788.2026.02.004

中文引用格式: 黄家锋, 吴丽君. 基于注意力信息关注与渐进梯度约束的二值化超分辨率网络 [J]. 网络安全与数据治理, 2026, 45(2): 28-33.

英文引用格式: Huang Jiafeng, Wu Lijun. A binarized super-resolution network based on attention information focusing and progressive gradient constraints [J]. Cyber Security and Data Governance, 2026, 45(2): 28-33.

A binarized super-resolution network based on attention information focusing and progressive gradient constraints

Huang Jiafeng, Wu Lijun

(College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China)

Abstract: Transformer-based networks have achieved excellent performance in image super-resolution tasks, but their high memory and computational costs hinder deployment. To address this issue, this paper proposes a binarized lightweight super-resolution network called BiSR-AG, built upon the SwinIR network. First, we implement a binarized baseline network based on existing binarization methods and SwinIR. Furthermore, we design an attention information-aware module to fully match the information capacity of the binarized model. Additionally, a progressive gradient update interval constraint training strategy is developed to alleviate the problem of partial parameter non-update in the attention mechanism. The experimental results demonstrate that the BiSR-AG network effectively compresses the model size while maintaining superior reconstruction performance and perceptual quality.

Key words: binarized network; super-resolution; computer vision; attention information

0 引言

图像超分辨是计算机视觉和图像处理中的一个重要任务。它旨在从低分辨率图像中重建高分辨率图像。基于 Transformer 的图像超分辨率网络因其全局的特征提取能力能够重建恢复更真实的高分辨率图像而受到广泛关注。然而, 其庞大的参数量导致推理过程需要大量的内存使用和浮点运算, 尤其是对于涉及高分辨

率图像的超分辨率 (Super-Resolution, SR) 任务而言。这些特点阻碍了其在计算存储资源有限的边缘设备上部署。因此, 对基于 Transformer 的图像超分辨率网络模型进行压缩, 以加快推理速度并降低计算成本, 同时保持模型性能十分必要。二值化神经网络 (Binary Neural Network, BNN)^[1] 作为一种极致的模型压缩技术, 在模型轻量化方面潜力巨大, 它能将网络权重和激活值从全精量化至单比特, 并使用同或门运算和位计数来替代复杂的浮点数乘和累加运算, 从而提供

* 基金项目: 国家自然科学基金 (62271151, W2421092)

数十倍的模型压缩率和显著的计算加速，为超分辨率重建模型在资源受限边缘设备上的部署提供了极具潜力的思路。

然而，现有二值化研究的应用场景多集中于图像分类等上游视觉任务，直接将现有的二值化方法^[2-4]应用于像素密集型超分任务会导致显著的性能下降。例如，Xia 等人^[5]提出 BBCU，使用残差对齐方案来缓解二值卷积输出数值范围不匹配问题；Li 等人^[6]通过引入自适应非对称二值化方法来调整激活二值化的转换点以减小量化误差；Xin 等人^[7]在 Rectified-BSR 模型中使用多个不同阈值对激活值进行二值化并融合结果，以减轻单一阈值带来的信息损失；Zhang 等人^[8]提出的 FRBC 方法不仅对权重进行二值化，还对一阶二值化的残差也进行了二值化，二阶二值化的结果作为辅助分支补偿主干二值化网络的量化误差。上述二值化超分研究工作主要聚焦于减小激活权重的量化损失，却忽略了图像输入信息的限制。相比较于对信息损失具有更大容忍度的图像分类任务，像素敏感的超分任务对输入信息分布要求更高。

网络模型在训练时候的“输入信息”是指输入图像中包含的全部信息 I_x ，包括目标信息 I_d 和冗余信息。其中，目标信息即输入图像中与任务相关的关键信息，其余的与任务无关的信息则为冗余信息。一个网络模型的训练目标是从输入中尽可能地提取相关信息以满足特定任务的需要。通常，一个全精度网络的模型信息容量 I_m 是可以充分表征这些相关信息的，且又能容纳冗余信息，如图 1 (a) 所示。神经网络训练通过损失函数反向传播进行参数更新优化，是尽量让模型信息容量 I_m 包含目标信息 I_d 的过程。但是将网络模型进行二值化过后，二值化模型信息容量 I_m^* 就变得很小，导致难以匹配目标信息，如图 1 (b) 所示。如何让模型快速关注到与任务有关的相关信息，排除冗余信息对于像素敏感的超分任务显得至关重要。为此，本文设计了一个注意力信息关注模块，通过将注意力关注区域与输入信息进行掩码操作来滤除冗余信息，生成注意力关注输入信息，引入先验知识来更好地将目标信息 I_d 匹配到二值化模型信息容量 I_m^* 上。

同时，由于注意力机制的特殊性，二值化注意力层部分参数会出现梯度消失现象从而增加模型训练难度，导致模型性能下降，Bi-ViT^[9]引入了一个可学习的缩放因子重新激活消失的梯度，但是也引入了额外的浮点数计算。为此，在不增加计算量的前提下，本

文提出了一个简单有效的渐进梯度更新区间约束策略来扩大梯度更新区间，使得更多的参数参与更新优化。

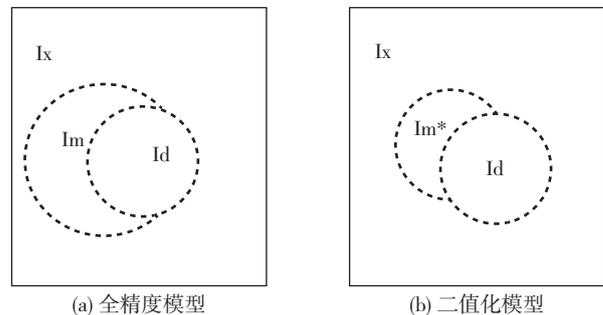


图 1 模型信息容量示意图

综上所述，本文提出了基于注意力信息关注和渐进梯度更新区间约束策略的二值化超分网络 BiSR-AG，本文研究框架如下：

(1) 基于全精度超分网络 SwinIR^[10] 利用 XNOR-Net^[11] 与 GSB^[12] 二值化方法实现了一个二值基线网络。

(2) 在基线网络基础，针对二值化模型信息容量较小难以匹配目标信息，设计了一个注意力信息关注模块 IA，获取模型关注区域的目标信息，抑制冗余特征输入，更好匹配二值化模型。

(3) 为解决二值化注意力层部分参数会出现不更新问题，提出了渐进梯度更新区间约束策略 GC。该策略在训练初期设置较宽的直通估计器 (Straight-Through Estimator, STE) 梯度更新区间，确保注意力模块参数获得充足的梯度更新空间。随着训练轮次的增加，逐步缩小梯度更新区间至标准范围，实现了平滑过渡，提升了注意力模块参数的优化效率，进而提高模型精度。

1 BiSR-AG 基础网络结构介绍

本文提出的二值超分辨率重建网络 BiSR-AG 整体结构如图 2 所示。首先选择在经典的基于 Transformer 的图像超分辨率网络 SwinIR 上利用 XNOR-Net 和 GSB 的二值方法来实现一个二值基线网络，包含由一个全精度卷积层组成的浅层特征提取模块、由多个二值 BiRSTB 基础模块堆叠组成的深层特征提取模块，以及二值卷积 + pixelshuffle 上采样组成的轻量化二值高质量重建图像模块。其中，对于网络中权重激活参数的二值化方法采用了 XNOR-Net 中的二值化方法，使用 sign 函数作为二值函数，如式 (1) 所示。二值化残差 Swin Transformer 块 (BiRSTB) 以多个二值化 Swin

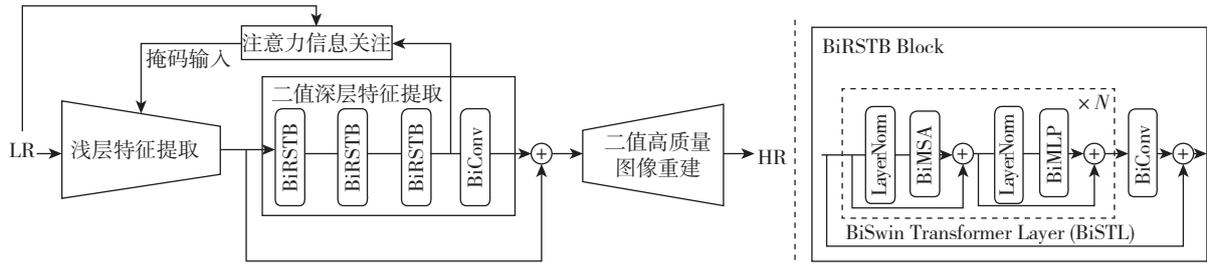


图2 BiSR-AG 基础网络架构图

Transformer 层与二值化卷积层为核心组件构建，其具体结构如图 2 右侧子图所示。针对二值化 Swin Transformer 层 (BiSTL) 中的二值化多头自注意力 (BiMSA) 机制，考虑到注意力分数的取值范围限定于 $[0, 1]$ 且呈现长尾分布的特性，本文采用 GSB 二值方法对其进行二值化处理。具体流程为：首先通过式 (2) 所示的二值化函数，将全精度注意力分数 A_{rel} 映射为二值注意力分数 A_{bin} ，但此时 A_{bin} 的分布仍无法匹配注意力分数的长尾特性，因此进一步利用式 (3) 定义的 GSB 方法，以 0.7 和 0.9 为阈值生成两个掩码矩阵 M_1 与 M_2 ，通过对不同二值化注意力子组的线性组合，来更好地近似实值注意力矩阵的值分布。在反向传播过程中，采用了 STE 来计算二值化激活权重的梯度。

$$\text{Binary}(-1, 1, x) = \text{sign}(x) = \begin{cases} -1, & x < 0 \\ +1, & x \geq 0 \end{cases} \quad (1)$$

其中， sign 函数以 0 为判别进行二值化， x 代表经过归一化操作后的权重或激活。

$$A_{bin} = \text{clip}(\text{round}(A_{rel}), 0, 1) \quad (2)$$

其中， A_{bin} 代表二值后的注意力分数， A_{rel} 代表二值化前的全精度浮点数注意力分数， $\text{clip}(A_{rel}, 0, 1)$ 是指将输入值 A_{rel} 缩放到区间 $[0, 1]$ 中， round 函数能将输入值取整到最近的整数。

$$A_{bin}^{GSB} = \alpha_0 A_{bin} + \sum_{i=1}^2 \alpha_i M_i \quad (3)$$

其中， α 代表的是可学习参数。

本文在基线网络基础上设计了注意力信息关注模块，基于深层特征提取模块的最后一层 BiRSTB 注意力输出特征图对模型关注区域进行评估，分析网络模型对于当前输入图像的关注区域，进行对输入信息的掩码输入，丢弃一些不关注的冗余信息，从而减少输入信息量以匹配二值网络有限的模型容量。并针对注意力机制参数出现的梯度消失现象设计了渐进梯度更新区间约束训练策略，通过逐步渐

进地限制 STE 梯度函数的更新区间，使其在训练初期注意力机制中的参数能够更多得到更新，有效提升了在训练阶段模型的拟合能力。与其他二值化网络一样，BiSR-AG 选择对占据了网络绝大部分计算量和参数量的深层特征提取模块和图像重构模块进行二值化处理，最大限度降低网络复杂度的同时保证网络性能。

2 本文优化方法

2.1 IA 注意力信息关注方法

现有二值化超分方法多关注于如何减小二值化误差，很少注意到超分任务细节重建依赖任务相关特征，这类方法在特征提取过程中容易引入大量背景冗余信息，导致有限的模型容量被无效占用，最终影响细节恢复精度。针对这一不足，本文设计注意力信息关注模块，引导模型快速聚焦任务相关的关键信息，实现冗余特征的有效过滤。

注意力信息关注方法基于深层特征提取模块的最后一层注意力机制输出特征图对模型关注区域进行评估，分析网络对于当前输入的关注区域，丢弃一些不关注的冗余信息来降低输入的总信息量，以匹配二值网络有限的模型容量。将网络所提取的信息尽可能地约束在深度特征提取模块关注区域内，从而迫使模型容量有限的二值网络提取更多的任务相关信息，以实现改善二值网络任务性能的目的，从而减少输入信息量以匹配二值网络有限的模型容量。

具体地，如图 3 所示，首先将输入图像输入网络模型，经过浅层特征提取层之后，再基于深层特征提取模块的最后一层注意力机制输出特征图，并进行双线性上采样到与输入信息矩阵相同大小，利用二值函数进行生成注意力掩码，最后与输入信息矩阵内积生成注意力关注的输入信息。

在此过程中由于注意力掩码的生成需要深层特征提取模块的输出，而获取该先验知识需要额外的计算开销，但是注意力信息关注方法仅应用于网络训练阶

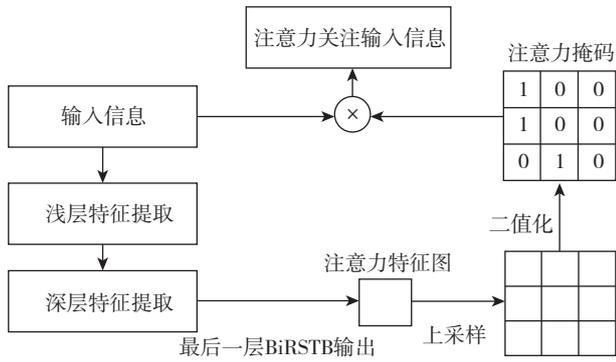


图3 注意力信息关注模块图

段，不影响最终网络推理性能。在网络训练过程中，首先将原始图像传入网络，根据损失函数计算得出原始损失值 $Loss_1$ ，并根据图3的方式计算得出注意力关注输入信息，并再次传入网络计算得出损失值 $Loss_2$ 。网络最终的损失计算如下：

$$Loss_{total} = uLoss_1 + (1 - u) Loss_2 \quad (4)$$

其中， $u \in [0, 1]$ 为平衡因子，用于平衡上述两种损失。在本文实验中 u 设置为 0.5。

2.2 GC 渐进梯度更新区间约束训练策略

现有二值化方法的梯度优化策略多通过重构近似

二值函数来解决反向传播中梯度更新困难问题，但不能很好解决注意力层中部分参数梯度消失的问题，导致模型训练停滞或性能下降。为解决该问题，本文提出简单有效的渐进梯度约束训练策略，通过动态调整梯度更新步长区间，扩大有效梯度的覆盖范围，确保二值化注意力层的参数能够稳定参与迭代优化。

二值化方法函数是一个离散的方程，其不连续的特性导致传统微分运算无法直接适用，导致了基于梯度下降的神经网络训练的反向传播梯度缺失，如图4(a)、(b)所示，分别代表二值化方法函数将全精度参数二值化为 $[-1, 1]$ 或 $[0, 1]$ 。为解决这一问题，研究者提出了 STE 作为梯度近似策略，来解决网络在训练过程中的反向传播问题，如图4(c)所示。STE 能够解决 sign 函数训练过程中梯度为 0 的问题，但由于 STE 直接将参数的更新区间限制在 $[-1, 1]$ 之间，参数梯度值在此区间外的为 0，导致参数优化陷入停滞。Bi-ViT 在推导了关于注意力值的梯度后，发现有很大一部分参数梯度值大于 1，导致了注意力机制层中的 q, k 等参数不更新，这种梯度不匹配降低了二值网络的性能。

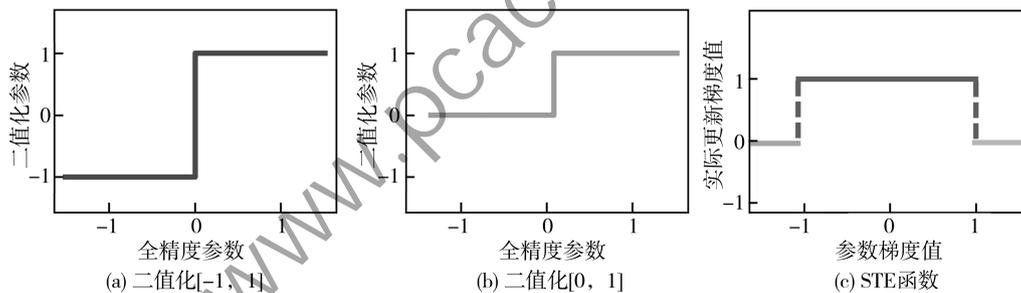


图4 二值化函数及 STE 函数图

因此本文提出一个简单有效的渐进梯度更新区间约束训练策略。在二值网络训练初期，网络参数权重波动较大，注意力机制较容易产生梯度失配，设置较大的初始更新区间 $[-R, R]$ 来让更多注意力层的参数参与更新，随着训练周期加大，网络趋于稳定，参数更新变少，逐步将更新区间减小为 STE 函数的标准区间 $[-1, 1]$ 。更新区间变化公式如下所示：

$$R = Initial_R \times \gamma^{\lfloor \frac{epoch}{step_size} \rfloor} \quad (5)$$

其中，Initial_R 代表初始区间值，本文实验设置初始值为 16； γ 代表衰减因子，设置为 0.5；epoch 代表当前训练轮次；step_size 代表衰减间隔轮次，本文实验中设置为总训练轮次的四分之一； $\lfloor \cdot \rfloor$ 代表进行向下取整。

3 实验细节

3.1 数据集、评估指标和实验设置

本文在 DIV2K 数据集上针对 $\times 2$ 重建图像质量任务进行模型训练，该数据集包含 800 张训练图像、100 张验证图像和 100 张测试图像。在五个标准测试数据集上进行了测试，包括 Set5、Set14、BSD100、Urban100 和 Manga109，它们分别包含 5、14、100、100 和 109 张图像。在评价指标上，本文选择了峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 和结构相似性指数 (Structural Similarity Index, SSIM) 作为评价指标。所有的 PSNR 和 SSIM 值均在图像 YCbCr 颜色空间的 Y 通道上计算所得。本文参考 BBCU^[5] 中的计算方法分别计算了二值运算 (Binary Operations, BOPs) 和

浮点数运算 (Floating-point Operations, FLOPs) 的计算复杂度, 即总计算复杂度为 $OPs = BOPs/64 + FLOPs$ 。为了保证比较的公平性, 将所有二值化方法 OPs 设置为相似。

网络训练所用平台为 Windows 11, 实验在单张 NVIDIA GeForce GTX4080 显卡上完成。模型参数使用 Adam 算法优化, 算法中参数设置为 β_1 为 0.9, β_2 为 0.999。在学习策略方面, 初始学习率设为 1×10^{-4} , 并以 200k 迭代次数 iterations 设为一个周期, 每经过 200k 迭代学习率重置为初始值。

3.2 消融实验

为了分析本文所提方法每个组件的有效性, 本文进行了消融实验, 在二值基线模型 Base 基础上逐步加入注意力信息关注方法 IA 和渐进梯度更新区间约束训练策略 GC, 在 Urban100 数据集评估了它们对 PSNR、SSIM 和计算复杂度的影响, 实验结果如表 1 所示。从实验结果可以看出, IA 和 GC 对 PSNR、SSIM 指标有着不同程度的提升。值得注意的是, 虽然 IA 会增加在训练时的计算复杂度 Ops, 但是对模型验证推理时没有影响, 因而本文在表中展示的 Ops 数值是代表推理时的计算复杂度。

表 1 不同组件在 Urban100 数据集消融研究

模型	PSNR	SSIM	OPs/G
SwinIR	33.81	0.942	195.6
Base	30.58	0.911	38.26
+ IA	31.62	0.925	38.26
+ IA + GC	32.26	0.932	38.26

3.3 算法对比

本文将所提模型和全精度模型 SwinIR, 双三次插

值 Bicubic, 基线模型 Base, 四种经典二值神经网络模型 BNN^[1]、Bi-Real Net^[13]、IRNet^[14]、ReActNet^[15] 以及其他先进的二值化超分辨率神经网络模型 FRBC^[8]、BBCU 进行经典图像超分辨率重建任务的评估比较。表 2 给出了各类模型 $\times 2$ 重建图像质量的客观评价指标, 其中加黑数值表示最优的二值神经网络结果, 下划线数值为次优结果。

如表 2 所示, 本文所提模型展现出了明显的性能优势。在 $\times 2$ 经典图像超分辨率重建任务中, BiSR-AG 模型与其他二值神经网络模型相比, 在五个标准测试数据集上的峰值信噪比 PSNR 和结构相似度 SSIM 指标上表现最佳。BiSR-AG 在多个数据集上的表现接近全精度模型 SwinIR, 同时其计算复杂度为 38.26G OPs, 仅为 SwinIR 的 19.6%, 实现了模型有效压缩。通过对实验结果的综合分析发现, 本文所提模型在性能和效率之间实现了良好的平衡, 能以较低的计算复杂度实现高质量的图像重建效果。BiSR-AG 通过二值化激活和权重, 大幅降低了模型对内存带宽与浮点运算单元的依赖。其计算过程以位运算和同或运算为主, 无需高算力的浮点计算支持。同时, 模型计算复杂度相较 SwinIR 下降一个数量级, 使模型可加载至内存资源受限的边缘终端, 在无需额外的模型裁剪或量化操作下, 适配边缘设备的硬件架构特性。

为了更直观地观察不同二值方法的超分辨率效果, 本文提供了如图 5 所示的 $\times 2$ 经典图像超分辨率重建图像对比图。将 BiSR-AG 模型重建图像与二值化前的全精度超分模型 SwinIR 和二值化超分模型 FRBC 进行重建视觉效果比较。可以看出, BiSR-AG 比 FRBC 具有更精细、更正确的纹理和更少伪影, 展示了其强大的特征表达以及图像重建能力, 与二值化前的全精度超分模型 SwinIR 视觉效果差距较小。

表 2 在 $\times 2$ 放大倍数下本文所提模型与其他二值超分辨率模型的 PSNR、SSIM 值对比

方法	OPs/G	Set5		Set14		BSD100		Urban100		Manga109	
		PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
SwinIR	195.60	38.42	0.962	34.46	0.925	32.53	0.904	33.81	0.942	39.92	0.979
Bicubic	—	33.97	0.933	30.55	0.875	29.73	0.849	27.07	0.846	31.24	0.938
Base	38.26	37.12	0.957	32.78	0.911	31.24	0.891	30.58	0.911	36.69	0.972
BNN	37.93	32.25	0.912	29.25	0.841	28.68	0.810	25.96	0.809	29.16	0.913
Bi-Real Net	37.93	32.32	0.912	29.47	0.842	28.74	0.811	26.35	0.816	29.64	0.917
IRNet	37.93	37.27	0.958	32.92	0.912	31.76	0.894	30.63	0.912	36.77	0.972
ReActNet	37.93	37.26	0.958	32.97	0.912	31.81	0.895	30.85	0.916	36.92	0.973
BBCU-L	37.75	37.58	0.959	33.18	0.914	31.91	0.896	31.12	0.918	37.50	0.975
FRBC	38.03	37.71	0.960	33.22	0.914	31.95	0.897	31.15	0.918	37.90	0.976
BiSR-AG (本文)	38.26	37.95	0.960	33.58	0.915	32.03	0.898	32.26	0.932	38.25	0.977

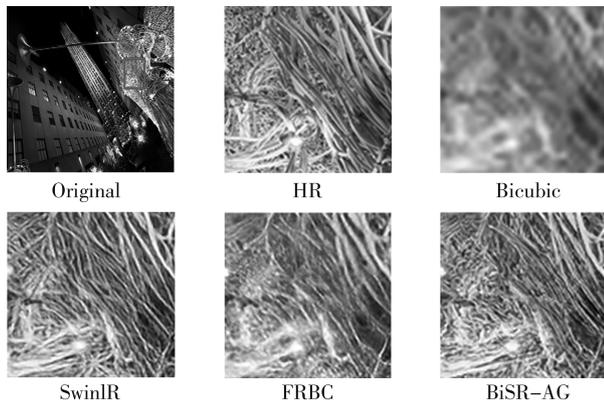


图5 重建图像对比图

4 结论

针对基于 Transformer 的超分辨率网络模型因模型普遍存在参数量大、计算复杂度高而难以实际应用问题, 本文提出了一个轻量化二值化的超分网络 BiSR-AG。通过设计注意力信息关注模块和渐进梯度约束训练策略, 有效提升了二值化网络模型的性能。BiSR-AG 有效压缩了模型大小, 同时在重建效果和感知质量上也有着较好的表现, 为资源受限的边缘计算部署超分辨率网络提供了一种解决方案。但本文研究仍存在若干局限性需后续进行优化: (1) 将实验场景扩展至多倍率超分任务, 验证模型在不同尺度下的泛化能力; (2) 优化注意力信息聚焦模块的结构设计, 降低模型的训练开销; (3) 开展真实硬件平台的部署测试, 量化分析模型在边缘设备上的实际运行效率与性能表现。

参考文献

- [1] HUBARA I, SOUDRY D, YANIV R E. Binarized neural networks [J]. arXiv: 1602.02505, 2016.
- [2] QIN H, DING Y, ZHANG M, et al. BIBERT: accurate fully binarized BERT [J]. arXiv preprint arXiv: 2203.06390, 2022.
- [3] LIU Z, OGUZ B, PAPPU A, et al. BIT: robustly binarized multi-distilled transformer [J]. Advances in Neural Information Processing Systems, 2022, 35: 14303–14316.
- [4] HE Y, LOU Z, ZHANG L, et al. BiViT: extremely compressed binary vision transformers [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV), 2023: 5628–5640.
- [5] XIA B, ZHANG Y, WANG Y, et al. Basic binary convolution unit for binarized image restoration network [J]. arXiv: 2210.00405, 2022.
- [6] LI X, CHAO F. Binarizing super-resolution neural network without batch normalization [C]//Chinese Conference on Pattern Recognition and Computer Vision (PRCV). Singapore: Springer, 2023: 65–76.
- [7] XIN J, WANG N, JIANG X, et al. Rectified binary network for single-image super-resolution [J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36 (5): 9341–9355.
- [8] ZHANG Y, QIN H, ZHAO Z, et al. Flexible residual binarization for image super-resolution [C]// Proceedings of the 41st International Conference on Machine Learning, 2024: 1–10.
- [9] LI Y, XU S, LIN M, et al. Bi-ViT: pushing the limit of vision transformer quantization [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2024, 38 (4): 3243–3251.
- [10] LIANG J, CAO J, SUN G, et al. SwinIR: image restoration using Swin Transformer [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 1833–1844.
- [11] RASTEGARI M, ORDONEZ V, REDMON J, et al. XNOR-Net: Imagenet classification using binary convolutional neural networks [C]//European Conference on Computer Vision. Cham: Springer International Publishing, 2016: 525–542.
- [12] GAO T, XU C Z, ZHANG L, et al. GSB: group superposition binarization for vision transformer with limited training samples [J]. Neural Networks, 2024, 172: 106133.
- [13] LIU Z, WU B, LUO W, et al. Bi-Real Net: enhancing the performance of 1-bit CNNs with improved representational capability and advanced training algorithm [C]// Computer Vision—ECCV 2018. Cham: Springer, 2018: 722–737.
- [14] QIN H, GONG R, LIU X, et al. Forward and backward information retention for accurate binary neural networks [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2020: 2250–2259.
- [15] LIU Z, SHEN Z, SAVVIDES M, et al. ReActNet: towards precise binary neural network with generalized activation functions [C]// Computer Vision—ECCV 2020. Cham: Springer, 2020: 143–159.

(收稿日期: 2025-11-28)

作者简介:

黄家锋 (2000-), 男, 硕士研究生, 主要研究方向: 计算机视觉。

吴丽君 (1984-), 通信作者, 女, 博士, 副教授, 主要研究方向: 计算机视觉。E-mail: lijun.wu@fzu.edu.cn。

版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部

www.pcachina.com