

doi:10.3969/j.issn.1001-4616.2025.06.012

一种用于图像超分辨率重建的稠密残差高效网络

郭红建,庄名驹,李嘉豪

(南京审计大学计算机学院,江苏 南京 211815)

[摘要] 针对超分辨率模型效率低下的问题,本研究深入剖析了其核心结构并提出了一种基于稠密残差的高效网络架构.该架构在减少模型参数的同时,实现了特征的高效整合,提升了模型效能与推理速度.通过引入经过优化的残差蒸馏模块,进一步降低了模型的参数规模和计算复杂度,同时摒弃了导致运行效率下降的残差连接方式.为了增强模型对图像高频细节的捕捉能力,研究还引入了对比损失函数.最后,通过采用多阶段热启动训练策略,模型的性能得到了提升,实现了更高效、更精准的超分辨率重建.

[关键词] 深度学习,超分辨率,残差

[中图分类号] TP391 [文献标志码] A [文章编号] 1001-4616(2025)06-0111-10

An Efficient Dense Residual Network for Image Super-Resolution Reconstruction

Guo Hongjian, Zhuang Mingju, Li Jiahao

(School of Computer Science, Nanjing Audit University, Nanjing 211815, China)

Abstract: To address the issue of low efficiency in super-resolution models, we analyze their core structure and propose an efficient network architecture based on dense residuals. This architecture achieves efficient integration of features while reducing model parameters, improving model performance and inference speed. By introducing an optimized residual distillation module, the parameter size and computational complexity of the model have been further reduced, while discarding the residual connection method that leads to decreased operational efficiency. In order to enhance the model's ability to capture high-frequency details in images, the study also introduces a contrastive loss function. Finally, by adopting a multi-stage hot start training strategy, the performance of the model is improved, achieving more efficient and accurate super-resolution reconstruction.

Key words: deep learning, super-resolution, residual

硬件技术的飞速跃进使得构建更深更大的神经网络以显著提升图像超分辨率效果成为可能^[1],但模型复杂度的增加与多样化应用场景对处理速度的高要求形成了矛盾,模型必须兼顾性能与效率.尤其在物联网边缘设备普及的背景下,设计适应资源受限环境的高效单幅图像超分辨率网络尤为关键.

评估效率需综合运行时间、参数量和计算复杂度等维度,研究者因此致力于减少参数量以直接提升效率,如 Shi 等^[2]的亚像素方法通过上采样避免传统插值,显著降低计算负担.为满足边缘设备实时性需求,涌现出如周等^[3]的单层架构网络,其以高效计算替代插值方法;同时,增强网络学习映射能力,设计高效激活函数或优化结构^[4],可在保效果前提下减少层数提升速度,何等^[5]的动态金字塔轻量网络即是代表,其利用金字塔分组卷积提取多尺度特征并降低参数量.稠密残差网络(DenseNet)^[6]在图像分类中的优势启发了其在超分辨率领域的应用. Zhang 等^[7]提出稠密堆叠残差网络(residual denseNet, RDN),融入密集残差块提取级联特征,显著提升超分辨率效果. Haris 等^[8]引入深度反向投影网络,融合反向投影思想及损失函数优化性能. Liu 等^[9]在此基础上提出残差特征聚合网络(residual feature aggregation network, RFANET),改进残差模块以充分利用层次特征.多分支网络因能提供更全面信息而受到重视,随之涌现了

收稿日期:2025-09-02.

基金项目:国家自然科学基金面上资助项目(62375133)、江苏省高校自然科学研究资助项目(25KJA520006)、江苏省产学研合作资助项目(BY20230589)、2024年度江苏省社科应用研究精品工程课题资助项目(24SYB-121).

通讯作者:郭红建,博士,副教授,研究方向:数据挖掘,大数据审计. E-mail:g_coolman@163.com

信息蒸馏网络 (information distillation network, IDN)^[10] 和多尺度残差网络 (multi-scale residual network, MSRN)^[11] 等模型. 为提升性能, Lim 等^[12] 提出增强深度残差网络 (enhanced deep residual network, EDRN), 通过移除 batch normalization (BN) 层有效减少伪影. 综上, 深度学习超分辨率研究的早期阶段主要聚焦于网络结构优化与效率提升, 研究者通过增加深度、融合多尺度及多层次特征增强能力, 并利用亚像素、转置卷积等技术降低复杂度, 追求高性能与高效率的双重目标.

随着研究的深入, 超分辨率模型过于庞大成为亟待解决的问题. 为了进一步优化模型, 研究者们探索了多种轻量化的方法, 包括剪枝^[13]、低秩滤波^[14]、神经网络量化^[15]、网络结构搜索^[16] 以及知识蒸馏等^[17]. 这些方法旨在减少模型的参数数量和计算量, 从而提高其运行效率.

然而, 现有超分辨率模型普遍存在效率低下的问题, 尤其是在资源受限的边缘设备上. 针对这一问题, 本文深入剖析了超分辨率模型的核心结构, 提出了一种重参数化的局部残差特征网络 (reparameterized residual local feature network, RRLFN). 该架构通过引入重参数化结构、优化的残差蒸馏模块及多阶段热启动训练策略, 降低了模型参数和计算复杂度, 同时提升了模型效能与推理速度, 实现了高效、精准的超分辨率重建. 重参数化方法使网络在训练阶段能够享受多尺度加成的优势, 而多阶段热启动训练则使模型在每个阶段都能利用之前所有阶段的权重, 获得更好的结果, 并有助于模型跳出局部最优解. 此外, 在训练过程中引入对比损失, 以帮助模型更好地捕获图像的纹理细节, 进一步提升超分辨率的效果.

1 基于重参数化的高效超分辨率网络设计

1.1 基于重参数化的高效超分辨率网络

正基于重参数化的高效超分辨率网络主要围绕局部残差模块 (residual local feature blocks, RLFB) 进行了改进^[18], 整体结构由三个部分组成: 浅层特征提取模块, 主要负责从输入的低分辨率图像中提取初步的浅层特征. 堆叠重参数残差模块 (reparameterized residual local feature blocks, RRLFB), 该模块是 RRLFN 模型的核心部分, 通过堆叠多个重参数化的局部残差块来实现特征的高效整合和提取. 每个 RRLFB 模块包含 1×1 和 3×3 的卷积以及 ReLU 激活函数, 用于局部特征提取. 在训练阶段, RRLFB 模块通过多分支结构提升性能; 在推理阶段, 则通过合并分支保持高效. 上采样模块, 主要负责将提取的特征图放大到目标分辨率, 生成最终的超分辨率图像. 网络整体架构如图 1 所示, 网络执行超分辨率任务的整体流程可表达为式(1)所示:

$$\begin{aligned} F_{in} &= h_{ext}(I_{LR}), \\ F_n &= RRLFB_n = (RRLFB_{n-1}(\dots RRLFB_0 * (F_{in}))), \\ I_{SR} &= Upsample(Conv3(F_n) + F_0) \end{aligned} \tag{1}$$

其中, h_{ext} 表示浅层特征提取层, F_{in} 表示中间特征, $RRLFB_i$ 表示第 i 个特征提取模块, 每个 $RRLFB$ 模块包含 1×1 和 3×3 的卷积和 ReLU 激活函数用域局部特征提取, 对于给定的特征 F_{in} , 其整体过程可以表示如式(2)所示:

$$\begin{aligned} F_{refined1} &= RM_1(F_{in}), \\ F_{refined2} &= RM_2(F_{refined1}), \\ F_{refined3} &= RM_3(F_{refined2}) \end{aligned} \tag{2}$$

其中, RM_i 表示第 i 个优化模块, $F_{refinedi}$ 表示第 i 个细化特征, 经过多个局部特征细化步骤后, 最后的细化特




图 1 重参数化的高效超分辨率网络框架

Fig. 1 Framework of the efficient super-resolution network with reparameterization

征通过残差连接相加后,输入到 1×1 的卷积层和 *ESA* 模块中得到 *RRLFB* 模块的最终输出,其过程表示如式(3)所示:

$$\begin{aligned} F_{refined} &= F_{in} + F_{refined3}, \\ F_{out} &= ESA(Convl(F_{refined})). \end{aligned} \quad (3)$$

1.2 重参数化的局部残差块

由于超分辨率任务的独特性,低分辨率图像中蕴含着丰富的低频信息,这些信息能够被有效保留并直接映射到最终的高分辨率输出中. 因此,在深度学习的领域中,残差网络和稠密网络的设计理念在各类超分辨率模型中一直扮演着重要角色. 在这样的背景下,稠密残差模块应运而生,其结构如图 2 所示.




图 2 稠密残差结构图

Fig. 2 Diagram of the dense residual structure

稠密残差模块通过密集的卷积层连接,有效地提取图像中丰富的局部特征,并充分利用了所有卷积层的信息. 同时,该模块采用跳跃连接机制^[19],将前一个块的状态直接传递到当前块,构建了一个连续的内存机制,从而显著加速了推理过程. 在充分提取每个块内的局部特征后,模块通过 *Concat* 操作将多个块的特征图拼接起来,并随后利用 1×1 卷积对拼接后的特征进行整合,实现了自适应的全局特征学习. 这种设计方式不仅提高了模型的特征提取能力,还进一步提升了超分辨率的性能.

然而,稠密残差模块在处理通道间信息时存在局限性,且模型的中间处理过程相对臃肿. 为了满足高效超分辨率的需求,我们对稠密残差块进行了改进,引入了通道分离的方式. 如图 3 所示,这种改进后的网络结构能够在降低运算量的同时,依然保持特征提取能力的稳定.




图 3 信息多蒸馏模块结构

Fig. 3 Structure of the information multi-distillation module

通过通道分离,每次仅提取一部分有用特征,而剩余特征则继续输入到网络,通过卷积层进一步提取. 最终,所有特征通过 *Concat* 操作和 1×1 卷积在通道维度上进行整合,从而确保信息的有效利用. 这种方式不仅优化了模型的计算效率,还保持了其在特征提取方面的优势,为高效超分辨率任务提供了有力的支持.

这种利用通道分离实现信息蒸馏的模型,能每次提取一部分有用特征,其余特征继续输入到网络中通过卷积继续提取,最终将所有的特征通过 *Concat* 和 1×1 的卷积在通道维度上对特征做计算,其计算流程如式(4)所示:

$$\begin{aligned}
 F_{refubed1}, F_{coarse1} &= split(CL_1(F_{in})), \\
 F_{refubed2}, F_{coarse2} &= split(CL_2(F_{coarse1})), \\
 F_{refubed3}, F_{coarse3} &= split(CL_3(F_{coarse3})), \\
 F_{refubed4} &= CL_4(F_{coarse3}), \\
 F_{distilled} &= Concat(F_{refined1}, F_{refined2}, F_{refined3}, F_{refubed1})
 \end{aligned}
 \tag{4}$$

但通道分离方式不够灵活,无法有效利用恒等连接.为解决多重信息蒸馏模块中的问题,将通道分离操作转换成两个单独的卷积可以更灵活的添加组件,而不是单纯的通过通道分离来分割,其结构如图 4 所示.在增加网络容量的同时,让模型变得对内存更友好,减少推理时间.这种局部残差模块同时在主干网络的卷积之间添加了激活函数,组合成浅层残差模块(shallow residual block, SRB),能在不引入额外参数的情况下,从残差学习中受益.

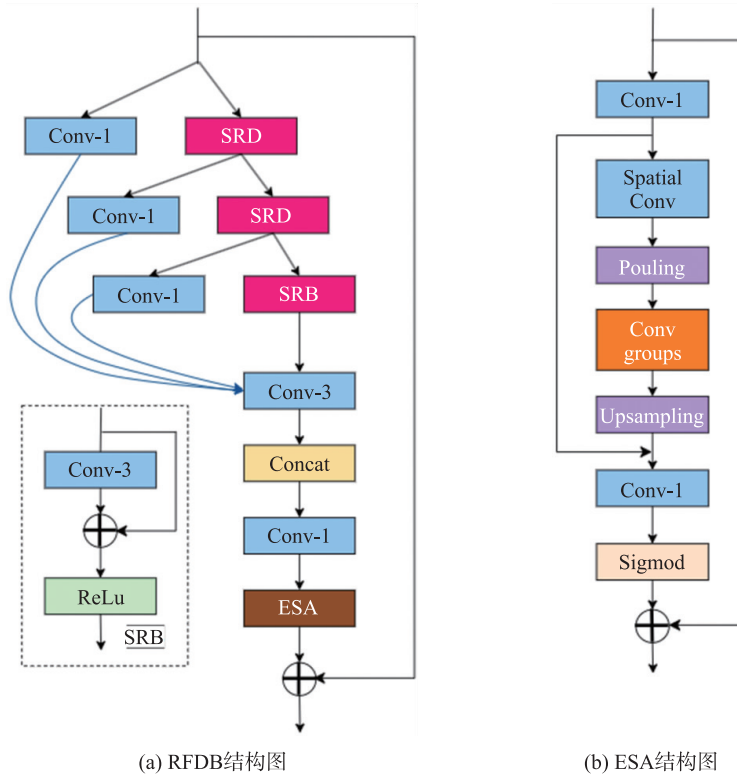


图 4 残差特征蒸馏模块结构图

Fig. 4 Diagram of the residual feature distillation module

随后,在残差蒸馏模块引入增强空间注意力(enhanced spatial attention, ESA)模块,其结构如图 4(b)所示,ESA 被放到 Concat 方法后,考虑到通道连接后的特征包含了图像在空间尺度上丰富的信息,所以 ESA 模块被置于最后用于聚合空间信息.在 ESA 模块中,首先通过跨步卷积扩大模块的感受视野,提取图像特征;然后利用全局池化层操作将突出的特征集中在一起,使得网络在空间尺度上自适应地重新缩放以提取重要的特征,得到一个更有代表性的特征,增强网络在空间尺度上的学习能力;此外,ESA 模块具有比普通空间注意力模块更少的计算量和更好的性能;局部残差蒸馏模块的整体计算过程如式(5)所示:

$$\begin{aligned}
 F_{refubed1} &= SRB(F_{in}), \\
 F_{coarse1} &= Conv1(F_{in}), \\
 F_{coarsei-1} &= SRB(F_{coarsei-1}), \\
 F_{refubedi} &= Conv1(F_{coarsei-1}), \\
 F_{refubedn} &= SRB(F_{coarsen-1}), i = 1, 2, \dots, n \\
 F_{distilled} &= Concat(F_{refubed1}, F_{refubed2}, \dots, F_{refubedn}), \\
 F_{SR} &= ESA(Conv1(F_{distilled}))
 \end{aligned}
 \tag{5}$$

为进一步提高模型的效率,在RFLB的基础上添加了重参数化模块,RRLFB的网络结构如图5所示。




图5 重参数化的局部残差块结构

Fig. 5 Structure of the reparameterized local residual block

在原始RFDB架构中,为高效地实现特征蒸馏与融合,引入 1×1 卷积来精简特征连接,这一设计显著削减参数量并增强了图像恢复效果。然而,它也大幅牺牲了推理速度。鉴于此,在RRLFB中摒弃特征分离步骤。为弥补由此带来的性能下滑,不仅增加了中间特征的通道数量,还创新性地引入重参数卷积技术,在训练阶段助力网络更深入地捕捉图像特征。具体来说,每个重参数卷积模块在训练时融合了一个 3×3 卷积核、一个 1×1 卷积以及ReLU激活函数,而在推理阶段则巧妙地合并为一个 3×3 卷积加ReLU激活,从而大幅提升了推理速度。

重参数化作为一种高度灵活的模型压缩策略,使得模型能够在训练阶段通过多分支结构提升性能,而在推理时则通过合并分支保持高效,同时不对网络施加任何额外约束^[20]。在训练过程中,重参数化技术在原始卷积结构的基础上引入额外的分支卷积,以残差形式叠加到原始卷积输出上。值得注意的是,在合并分支时,一个 1×1 卷积可以等价转换为一个 3×3 卷积,得益于并行卷积操作的线性可加性,这一卷积合并过程可以如公式(6)所示描述:

$$\begin{aligned} Conv_1(x) &= W_1x + b_1, \\ Conv_2(x) &= W_2x + b_2, \\ Conv_{Fuse}(x) &= Conv_1(x) + Conv_2(x) = (W_1 + W_2)x + b_1 + b_2, \end{aligned} \quad (6)$$

其中, $Conv_i$ 代表第*i*个卷积操作, W_i 代表第*i*个卷积权重,在并行卷积合并过程中,可直接将两个并行的卷积输出结果相加。对于存在BN层的卷积可简化如式(7)所示:

$$\begin{aligned} Conv(x) &= W(x) + b, \\ BN(x) &= \gamma * \frac{(x - mean)}{\sqrt{var}} + \beta, \\ BN(Conv(x)) &= \gamma * \frac{W(x) + b - mean}{\sqrt{var}} + \beta = \frac{\gamma}{\sqrt{var}} W(x) + \left(\frac{b - mean}{\sqrt{var}} + \beta \right). \end{aligned} \quad (7)$$

在此情况下,将卷积层权重和偏置(bias)视作已经与批归一化(BN)层参数合并计算后的结果。这样,经过合并与简化后的最终融合表达式如式(8)所示,该式体现了卷积与BN层整合后的综合效果。

$$\begin{aligned} W_{fused} &= \frac{\gamma * W}{\sqrt{var}}, \\ B_{fused} &= \frac{\gamma * (b - mean)}{\sqrt{var}} + \beta, \\ BN(Conv(x)) &= W_{fused}(x) + B_{fused}. \end{aligned} \quad (8)$$

1.3 对比损失

对比损失在自监督学习领域的突出表现已广受瞩目,其基本思想在于潜空间内对正样本与锚点进行拉近,同时对负样本与锚点进行推远^[21]。对比损失函数的具体如式(9)所示:

$$CL = \sum_{i=1}^n \lambda_i \frac{d(\varphi_i(Y_{anchor}), \varphi_i(Y_{pos}))}{d(\varphi_i(Y_{anchor}), \varphi_i(Y_{neg}))}, \quad (9)$$

其中, φ_i 代表第*i*层的中间特征, $d(x, y)$ 则衡量了*x*与*y*之间的 L_1 距离,而 λ_i 作为调节权重的系数。相较于传统的 L_1 损失函数,对比损失能促使模型在学习过程中更加聚焦于图像纹理的精细生成。

尽管 visual geometry group(VGG)网络常被用作特征提取器来选取中间特征 φ ,但其深层特征在富含高级语义信息的同时,往往损失了图像的关键细节^[22].虽然浅层特征能较好地保留这些细节信息,但 VGG 中采用的 ReLU 激活函数在正值区间无上界,可能导致生成的特征图过于稀疏,引发信息丢失问题.这种信息缺失使得当对比损失函数作为监督信号时,其提供的监督作用可能变得相对薄弱.

近期研究指出,随机初始化的网络同样具备捕捉图像细节的能力.因此,借鉴文[23]的方法,采用了一个随机初始化的 Convk3s1-Tanh-Convk3s1 结构作为特征提取器,将此结构与 VGG 模型所提取的特征图进行对比,结果如图 6 所示.

从图中可以清晰地看到,与经过训练的 VGG 网络相比,随机初始化的网络在提取图像纹理细节方面展现出了更为优越的性能.




图 6 随机初始化的卷积与 VGG 模型提取的特征图对比

Fig. 6 Comparison of feature maps extracted by randomly initialized convolution and VGG model

2 实验设计与结果分析

2.1 实验数据

本实验选用特定数据集作为原始训练素材,所有训练图像均通过 Bicubic 下采样技术调整至目标分辨率,作为低分辨率输入.模型针对 RGB 通道进行训练,且在高分辨率图像预处理阶段,随机裁剪至统一尺寸以适应训练需求.训练过程中,采用固定批次大小进行处理.为增强数据的多样性和模型的泛化能力,引入随机旋转和通道洗牌等数据增强策略.为全面评估模型性能,选用 Set5、Set14、BSD100、Urban100 等标准测试集,并重点参考了峰值信噪比(peak signal-to-noise ratio, PSNR)^[24]和结构相似性指数(structure similarity index measure, SSIM)^[25]两项关键指标.值得注意的是,鉴于人眼对亮度变化的敏感性,所有评价指标均在 YCbCr 颜色空间的 Y 通道下计算得出.

2.2 实验参数

为确保实验对比的公正性,我们遵循了业界主流的网络参数配置.训练过程分为三个阶段:在初始阶段,从头开始训练一个放大 2 倍的超分辨率模型,为后续步骤奠定基础.紧接着,对于放大 4 倍的超分辨率模型,利用了先前 2 倍模型训练好的权重作为起点,即将其作为预训练权重进行加载,以加速训练并提升性能.

在训练过程中,设定学习速率为 $5e^{-4}$,这是一个经过调试的数值,旨在平衡模型的收敛速度和稳定性.为进一步优化训练效果,采用学习率衰减策略:每隔 2×10^5 次迭代,学习速率将减半,这有助于模型在训练后期更加精细地调整参数.

优化器方面,选择 Adam 算法^[26],其凭借出色的优化性能和广泛的适用性,在深度学习领域备受青睐,并遵循常规设定,将 Adam 的超参数 β_1 设置为 0.9, β_2 设置为 0.999,以确保优化过程的稳定性和效率.

在第一阶段训练中,专注于最小化损失函数,以快速引导模型向最优解逼近.进入第二阶段,采取一种策略性的做法,即读取前一阶段的训练权重作为新的起点,并重新启动训练过程.这一步骤旨在帮助模

型摆脱可能陷入的局部最优解,通过多次(共3次)的重复训练,进一步挖掘模型的潜力.最后,在训练收尾阶段,引入对比损失函数,这一创新之举旨在进一步提升模型的性能指标.通过对比不同样本之间的差异,模型能够更加精准地捕捉图像细节,从而在超分辨率重建任务中取得更加出色的表现.

综上所述,训练策略不仅严谨而科学,更通过巧妙的权重继承和损失函数设计,实现了模型性能与训练效率的双重提升.

2.3 实验结果与分析

为定量评估 RRLFN 模型的性能,我们将其与多种轻量级超分辨率模型在标准测试集(Set5, Set14, BSD100, Urban100)上进行了对比实验,重点评估了 $\times 2$ 和 $\times 4$ 放大倍率下的表现.评估指标涵盖图像重建质量:峰值信噪比(PSNR)与结构相似性指数(SSIM)、参数量(Params)以及推理时间(Runtime).实验结果整理于表1和表2,其中本文提出的 RRLFN 模型的实验结果已被加粗.

表1 在 $\times 2$ 倍率下不同模型在测试数据集下参数

Table 1 Comparison of parameters, running time, and performance of different models at $\times 2$ magnification on test datasets

Scale	Model	Params (K)	Runtime ms	Set14 PSNR/SSIM	BSD100 PSNR/SSIM	Urban100 PSNR/SSIM
$\times 2$	SRCNN	24	6.92	32.42/0.906 3	31.36/0.887 9	29.50/0.894 6
	FSRCNN	12	9.02	32.62/0.908 7	31.50/0.890 4	29.85/0.900 9
	VDSR	666	35.37	33.05/0.912 7	31.90/0.896 0	30.77/0.914 1
	DRCN	1 774	716.45	33.04/0.911 8	31.85/0.894 2	30.75/0.913 3
	LapSRN	251	53.98	32.99/0.912 4	31.80/0.895 2	30.41/0.910 3
	CARN	1 592	159.10	33.52/0.916 6	32.09/0.897 8	31.92/0.925 6
	IMDN	694	77.34	33.63/0.917 7	32.19/0.899 6	32.17/0.928 3
	RFDN	534	74.51	33.68/0.918 4	32.16/0.899 4	32.12/0.927 8
	MAFFSRN	402	152.91	33.49/0.917 0	32.14/0.899 4	31.96/0.926 8
	ECBSR	596	39.96	33.34/0.917 8	32.10/0.901 8	31.71/0.925 0
	RRLFN	454	60.39	33.66/0.917 2	32.17/0.899 5	32.17/0.928 5

表2 在 $\times 4$ 倍率下不同模型在测试数据集下参数

Table 2 Comparison of parameters, running time, and performance of different models at $\times 4$ magnification on test datasets

Scale	Model	Params (K)	Runtime ms	Set14 PSNR/SSIM	BSD100 PSNR/SSIM	Urban100 PSNR/SSIM
$\times 4$	SRCNN	57	1.90	27.49/0.750 3	26.90/0.710 1	24.52/0.722 1
	FSRCNN	13	2.22	27.61/0.755 0	26.98/0.715 0	24.62/0.728 0
	VDSR	666	8.95	28.01/0.767 4	27.29/0.725 1	25.18/0.752 4
	DRCN	1 774	176.59	28.02/0.767 0	27.23/0.723 3	25.14/0.751 0
	LapSRN	502	66.81	28.09/0.770 0	27.32/0.727 5	25.21/0.756 2
	CARN	1 592	39.96	28.60/0.780 6	27.58/0.734 9	26.07/0.783 7
	IMDN	715	20.56	28.58/0.781 1	27.56/0.735 3	26.04/0.783 8
	RFDN	550	20.40	28.61/0.781 9	27.57/0.736 0	26.11/0.785 8
	MAFFSRN	441	39.69	28.58/0.781 2	27.57/0.736 1	26.04/0.784 8
	ECBSR	603	10.21	28.34/0.781 7	27.48/0.739 3	25.81/0.777 3
	RRLFN	470	16.41	28.61/0.781 8	27.58/0.735 8	26.15/0.787 0

PSNR 是一种用于衡量图像质量的客观指标,它通过计算原始图像与重建图像之间的均方误差,并将其转换为以分贝(dB)为单位的数值来表示. PSNR 值越高,表示重建图像与原始图像之间的差异越小,图像质量越好. SSIM 是一种从亮度、对比度和结构三个方面来衡量两幅图像相似性的指标. SSIM 的取值范围在 0 到 1 之间,值越接近 1,表示两幅图像在结构上越相似,图像质量越高.

分析表1和表2的数据可知,相较于其他先进模型,本文提出的 RRLFN 方法在多个测试集上的 PSNR 和 SSIM 指标表现优异,展示了其较强的图像重建能力.

同时, RRLFN 在图像重建能力和参数量、推理时间之间实现了更优的平衡. 具体而言, RRLFN 模型降低模型参数量并提升推理速度. 例如,在 $\times 2$ 倍率下, RRLFN 仅需 454 K 参数,低于传统模型如 VDSR (666 K) 和 DRCN (1 774 K); 在 $\times 4$ 倍率下,其参数量(470 K)也远低于 CARN (1 592 K) 等模型. 在 $\times 2$ 倍率下, RRLFN 的推理速度(60.39 ms)远快于参数量相近的 MAFFSRN (152.91 ms); 在 $\times 4$ 倍率下,其速度(16.41 ms)也快于除 ECBSR (10.21 ms) 之外的多数对比模型,如 IMDN (20.56 ms)、RFDN (20.40 ms) 和 MAFFSRN (39.69 ms). 重要的是,这种效率的提升并未牺牲重建质量. 相反, RRLFN 在多个测试集上的表

现达到或超越了当前表现优异的轻量级模型. 最突出的例子体现在 Urban100 数据集×4 倍率下, RRLFN 取得了最高的 PSNR(26.15 dB)和 SSIM(0.7870), 优于运行稍快的 ECBSR(25.81 dB/0.777 3), 同时也优于或持平于 IMDN(26.04 dB/0.783 8)和 RFDN(26.11 dB/0.785 8).

为更直观地展示本文方法在参数量、推理时间和图像重建能力之间所做出的权衡, 我们进一步绘制了模型之间的对比图, 如图 7 所示. 在该图中, 横轴的值是以 DRCN 作为基准进行归一化的, 而越靠近左上方的模型则代表其相对性能越好. 从图中可以清晰地看到, 我们的模型相较于其他方法更靠近左上方, 这充分证明了本文方法在图像重建能力、参数量和推理时间之间取得了更为出色的平衡.




图 7 不同模型的 PSNR 和参数量以及推理时间的坐标图

Fig. 7 Coordinate graph of PSNR, parameter quantity, and inference time of different models

2.4 消融实验与分析

为深入理解 RRLFN 模型的关键组件及其对网络性能的影响, 进行一系列消融实验, 以下是针对热启动有效性和对比损失函数两个方面的详细分析.

(1) 热启动有效性消融实验

为验证热启动策略的有效性, 设计了对照实验并比较了在不同训练策略下 RRLFN 模型的性能表现. 以 RRLFN_ws_1 作为基准模型, 其中“ws”代表热启动(Warm-start)策略. 为了全面评估, 引入两种变体模型进行对比: RRLFN_160W 和 RRLFN_80w2t_cls.

RRLFN_160W: 该模型经历了总共 160 万次迭代, 其训练参数与 2.2 节中描述的第一阶段保持一致.

RRLFN_80w2t_cls: 此模型采用循环学习率策略, 学习率设置与 2.2 节第一阶段相同, 但不同的是, 在训练过程中不会重置优化器参数. 实验结果如下表 3 所示.

表 3 热启动消融实验结果

Table 3 Results of warm-start ablation experiment

Model	Set5	Set14	BSD100	Urban100
	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
RRLFN_160W	32.18/0.895 1	28.59/0.781 4	27.57/0.735 3	26.09/0.785 0
RRLFN_80w2t_cls	32.19/0.895 7	28.60/0.781 8	27.55/0.735 7	26.13/0.786 5
RRLFN_ws_1	32.22/0.895 6	28.61/0.781 8	27.58/0.735 7	26.14/0.786 7

结果表明, 热启动策略相比于其他训练方法取得了最好的结果, 这说明热启动策略有助于在优化过程中帮助网络跳出局部最小值, 从而提高整体性能.

(2) 对比损失函数消融实验

接下来, 我们探究了对比损失函数在网络训练中的作用. 为此, 在热启动第二阶段, 以 RRLFN_ws_2_CL 作为基线方法, 并设计一个对照实验: 去除对比损失, 仅使用 L1 损失进行训练, 并在标准数据集上进行测试以评估性能, 实验结果如表 4 所示.

通过对比可看出, 在引入对比损失后, 模型在 4 个基准数据集上指标均获得提升. 这一提升虽然看似微小, 但意义重大, 因为它表明对比损失确实能够促使网络更加关注图像的纹理细节和低频信息. 这种专

注于纹理生成的学习策略,有助于模型在训练过程中捕捉到更多的图像特征,从而取得更高的性能指标。

综上所述,通过消融实验的分析,进一步确认热启动策略和对比损失函数在 RRLFN 模型中的重要作用,这些发现不仅加深对模型工作原理的理解,也为后续的研究和优化提供了有力的依据。

表 4 对比损失函数消融实验结果

Table 4 Results of contrastive loss ablation experiment

Model	Set5 PSNR/SSIM	Set14 PSNR/SSIM	BSD100 PSNR/SSIM	Urban100 PSNR/SSIM
RRLFN_ws_2	32.22/0.896 0	28.60/0.781 8	27.57/0.735 9	26.13/0.786 5
RRLFN_ws_2_CL	32.23/0.896 2	28.61/0.781 8	27.59/0.735 9	26.15/0.787 0

3 结论

本研究聚焦超分辨率模型的效率瓶颈,深入探索网络核心机制,并据此精心设计了一种重参数化的局部残差高效单幅图像超分辨率网络. 通过融入改良的残差蒸馏模块,我们不仅大幅降低了模型参数与计算复杂度,还果断摒弃了影响运行效率的残差连接,从而实现了模型的高效化. 此网络通过结构优化实现了约 30% 的参数缩减,同时推理速度得到提升,而性能依然卓越. 为进一步平衡图像重建能力和参数量、推理时间,我们创新性地采用了多阶段训练策略,确保模型在轻量化的基础上依然保持出色的图像重建能力. 这一系列创新举措成功地在图像质量与推理速度之间找到了理想的平衡点,为超分辨率技术的实际应用奠定了坚实的基础,展现了广阔的应用前景。

[参考文献]

- [1] 钟梦圆,姜麟. 超分辨率图像重建算法综述[J]. 计算机科学与探索,2022,16(05):972-990.
- [2] 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]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las, Vegas, NV, USA, 2016:1874-1883.
- [3] 周登文,李文斌,李金新,等. 一种轻量级的多尺度通道注意图像超分辨率重建网络[J]. 电子学报,2022,50(10):2336-2346.
- [4] LIU J, TANG J, WU G. Residual feature distillation network for lightweight image super-resolution[C]//ECCV Workshops. Glasgow, UK, 2020.
- [5] 何鹏浩,余映,徐超越. 基于动态金字塔和子空间注意力的图像超分辨率重建网络[J]. 计算机科学,2022,49(S2):423-430.
- [6] HUANG G, LIU Z, WEINBERGER K Q. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA, 2016:2261-2269.
- [7] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image super-resolution[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA, 2018:2472-2481.
- [8] HARIS M, SHAKHAROVICH G, UKITA N. Deep back-projection networks for super-resolution[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA, 2018:1664-1673.
- [9] LIU J, ZHANG W, TANG Y, et al. Residual feature aggregation network for image super-resolution[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA, 2020:2356-2365.
- [10] HUI Z, WANG X, GAO X. Fast and accurate single image super-resolution via information distillation network[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA, 2018:723-731.
- [11] LI J, FANG F, MEI K, et al. Multi-scale residual network for image super-resolution[C]//European Conference on Computer Vision. Munich, Germany, 2018.
- [12] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition workshops (CVPRW). Honolulu, HI, USA, 2017:1132-1140.
- [13] 叶汉民,李志波,程小辉,等. 基于注意力机制的稀疏化剪枝方法[J]. 计算机工程与设计,2023,44(12):3642-3648. DOI:10.16208/j.issn1000-7024.2023.12.017.
- [14] SUMIT K, KUMAR R S. Robust denoising technique for ultrasound images by splicing of low rank filter and principal

- component analysis[J]. *Biomedical research*,2018,29(18):3444–3455.
- [15] WEI L,MA Z,YANG C,et al. Advances in the neural network quantization;a comprehensive review[J]. *Applied sciences*,2024,14(17):7445–7445.
- [16] 杨木润,曹润柘,杜权,等. 神经网络结构搜索前沿综述[J]. *中文信息学报*,2023,37(10):1–15.
- [17] 顿家乐,王骏,彭汉琛,等. 面向自闭症辅助诊断的知识蒸馏混合域适应方法[J]. *智能系统学报*,1–10[2025-02-22]. <http://kns.cnki.net/kcms/detail/23.1538.TP.20250126.1344.004.html>.
- [18] JUNWEI L, MUJIAN Y, XIAOLIN Y, et al. Binary image steganalysis based on symmetrical local residual patterns [J]. *Chinese journal of electronics*,2022,31(4):752–763.
- [19] ZHANG Q, MIN B, HANG Y, et al. A full-scale lung image segmentation algorithm based on hybrid skip connection and attention mechanism[J]. *Scientific reports*,2024,14(1):23233–23233.
- [20] IBARRA D H O, SARGSYAN K, NAJM N H. Surrogate construction via weight parameterization of residual neural networks [J]. *Computer methods in applied mechanics and engineering*,2025,433(PA):117468–117468.
- [21] YE H, HUANG X, ZHU H, et al. An enhanced network with parallel graph node diffusion and node similarity contrastive loss for hyperspectral image classification[J]. *Digital signal processing*,2025,158:104965.
- [22] 张建华,孔繁涛,吴建寨,等. 基于改进 VGG 卷积神经网络的棉花病害识别模型[J]. *中国农业大学学报*,2018,23(11):161–171.
- [23] KONG F, LI M, LIU S, et al. Residual Local Feature Network for Efficient Super-Resolution[M]. *arXiv*,2022.
- [24] ZHANG B, ZHANG Y, WANG B, et al. Denoising swin transformer and perceptual peak signal-to-noise ratio for low-dose ct image denoising[J]. *Measurement*,2024,227:114303.
- [25] ILLYA B, MARCO B, RAIMONDO S, et al. Structural similarity index(ssim) revisited;a data-driven approach[J]. *Expert systems with applications*,2022,189:116087.
- [26] SIAN C, YAJUAN Z, RUI W. RETRACTED: An optimal framework for natural english translate processing; on the application of artificial neural network and adam optimization algorithm [J]. *Journal of intelligent & fuzzy systems*,2024,47(5–6, Supplement 1):205–219.

[责任编辑:陆炳新]