

基于稀疏神经网络的图像超分辨率重建算法

黎浩民,李光平

(广东工业大学 信息工程学院,广州 510000)

摘要:部分基于深度学习的图像超分辨率重建算法通过扩展网络层的深度来提高网络模型的整体特征表达能力。然而,一味过度地扩展网络的深度会造成网络模型过参数化和复杂化,并且冗余的网络参数会增加特征表达的不稳定性。在LTH剪枝算法基础上改变权重参数并使用均衡学习策略,提出一种适用于图像超分辨率重建任务的神经网络非结构化剪枝算法RLTH。在不改变网络结构和不增加计算复杂度的前提下,通过搜索原始网络模型的最优稀疏子网络排除冗余参数带来的影响,在有限的参数资源中捕获更细粒度和丰富的图像特征,进而提高网络模型的整体特征表达能力。基于Set5、Set14和BSD100测试集的实验结果表明,与原始网络模型和应用LTH剪枝算法相比,应用RLTH算法获得的重建图像PSNR和SSIM均得到提升,且具有更丰富的细节特征,整体和局部轮廓更清晰。

关键词:单帧图像超分辨率重建;神经网络;非结构化剪枝;深度学习;稀疏网络

开放科学(资源服务)标志码(OSID):



中文引用格式:黎浩民,李光平.基于稀疏神经网络的图像超分辨率重建算法[J].计算机工程,2022,48(7):247-253.

英文引用格式:LI H M, LI G P. Image super-resolution reconstruction algorithm based on sparse neural network [J].

Computer Engineering, 2022, 48(7): 247-253.

Image Super-Resolution Reconstruction Algorithm Based on Sparse Neural Network

LI Haomin, LI Guangping

(School of Information Engineering, Guangdong University of Technology, Guangzhou 510000, China)

[Abstract] Many deep learning-based image super-resolution reconstruction algorithms improve the overall feature expression ability of a network by extending the depth of the network. However, excessively extending the depth of the network causes the model to be over-parameterized and complicated. Furthermore, redundant parameters increase the instability of feature expression. To address this issue, based on the LTH pruning algorithm, the weight parameters are changed and the balanced learning strategy is used, this paper proposes a neural network unstructured pruning algorithm which is suitable for image super-resolution reconstruction tasks, called the RLTH pruning algorithm. Without changing the network structure and increasing the computational complexity, the overall feature expression ability of the network is improved by searching for an optimal yet sparse sub-network of the original network, which excludes the influence of redundant parameters and maximizes the ability of capturing fine-grained and richer features with limited parameters. The experimental results based on Set5, Set14 and BSD100 test sets show that, compared with the original network model and LTH pruning algorithm, the PSNR and SSIM of the reconstructed images obtained by RLTH algorithm are improved, and they have richer detail features and clearer overall and local contours.

[Key words] Single Image Super-Resolution (SISR) reconstruction; neural network; unstructured pruning; deep learning; sparse network

DOI: 10.19678/j.issn.1000-3428.0062364

0 概述

单帧图像超分辨率(Single Image Super-Resolution, SISR)重建是指通过特定的算法模型对丢失高频特

征信息的低分辨率图像重建出一张清晰的高分辨率图像。近年来,SISR技术被广泛应用于移动端设备的视觉成像、监控成像、遥感卫星成像、医学成像等多个领域。

基金项目:国家自然科学基金(61601130);大亚湾科技计划项目(2020010203)。

作者简介:黎浩民(1995—),男,硕士研究生,主研方向为计算机视觉、机器学习;李光平,副教授、博士。

收稿日期:2021-08-16 修回日期:2021-09-18 E-mail:lihaomin314@gmail.com

现有 SISR 重建算法主要分为基于插值和基于深度学习两类。基于插值的重建算法计算复杂度较低,重建速度较快,其依据低分辨率图像的已知特征信息和空间的维度相关性在合适的位置插入若干像素点来提高低分辨率图像的分辨率。由于此类算法主要是通过简单地评估相邻像素点之间的相关性来扩充低分辨率图像的特征信息,因此在重建的过程中难以获取真实图像的高频信息,导致高分辨率图像丢失细节特征,并且成像视觉效果较差。基于深度学习的重建算法主要通过神经网络模型学习低分辨率图像与对应高分辨率图像之间的映射关系,利用这个映射关系的先验知识将低分辨率图像映射为高质量的高分辨率图像。文献[1-3]研究表明,基于深度学习的算法比基于插值的算法具有更强大的重建性能,能够显著提高重建图像的质量。

在基于深度学习的重建算法中,特征表达能力强的网络层能够更有效地学习图像的特征表示,捕获更细粒度和丰富的细节特征。部分基于深度学习的 SISR 重建算法^[3-4]通过使用更深的网络层和更复杂的连接方式来提高网络模型的整体特征表达能力,进而提升重建性能。虽然在一定程度上通过扩大网络层的深度和复杂的连接方式能够增强网络层的整体特征表达能力,但是过度依赖于这种方式会导致网络模型中的参数量和计算复杂度急剧上升。在神经网络中,参数量代表了网络模型的规模,而计算复杂度代表了网络模型前向推理的效率。从实际应用的意义来说,网络模型的规模和超分辨率图像的重建速度会限制 SISR 网络模型在现实场景中的应用。文献[5]指出,舍弃深度网络层中冗余的参数不仅能够减小网络模型过参数化所带来的消极影响,而且还能提高特征表达的稳定性。

神经网络的剪枝算法通过舍弃部分参数的方式来减少网络模型的参数量。现有剪枝算法主要可分为结构化剪枝算法和非结构化剪枝算法两大类。结构化剪枝算法通过舍弃网络层中部分的通道达到减少参数量的效果。由于这种方式是在网络结构上做出的调整,因此原来的网络结构会发生改变。非结构化剪枝算法通过将网络层中部分参数归零的方式来舍弃部分参数,因此,不会改变原来的网络结构。文献[6-7]将结构化剪枝算法应用到图像超分辨率网络模型中,在确保重建性能的情况下,最大化地轻量化网络模型的规模,以部署到实际应用场景中。

文献[8]提出神经网络的非结构化剪枝算法 LTH。算法的设计思想是将一个复杂的神经网络视作一个奖池,而中奖彩票则是一组权重参数所对应的稀疏子网络。实验结果表明,LTH 算法通过搜索最优的稀疏子网络,在图像分类任务上取得了显著的效果,但应用在图像超分辨率任务上却效果较差。

LTH 算法采用非均衡的特征学习策略,只注重于网络模型的稀疏程度,而忽视了特征表达的多样

性。为进一步提高图像重建性能,本文结合图像超分辨率重建任务的特点,在 LTH 算法的基础上提出一种基于均衡学习策略的动态非结构化剪枝算法 RLTH。该算法在保证网络模型稀疏性的同时还注重权重参数学习的多样性,能够解决图像超分辨率重建任务中网络模型过参数化导致重建性能下降的问题,并在不改变网络结构和不增加计算复杂度的前提下提高重建超分辨率图像的质量。

1 相关工作

1.1 基于深度学习的单帧图像超分辨率重建算法

文献[9]提出 SRCNN 模型,通过三层 CNN 分别实现低分辨率图像的特征提取、特征的非线性映射和高分辨率图像的重建过程。相对于传统基于插值的图像超分辨率重建算法, SRCNN 重建的高分辨率图像具有更丰富的细节特征,且图像的轮廓清晰可见。文献[10]提出 DRN 网络模型,通过训练低分辨率图像与高分辨率图像之间的对偶映射关系,并利用闭环的映射关系来降低低分辨率图像对高分辨率图像的依赖性,进而解决真实样本的超分辨率问题。文献[11]提出 RFANet 网络模型,利用残差模块和增强空间注意力模块的有效特征提取能力,将它们整合为残差特征聚合框架,从而提高超分辨率图像的质量。文献[12]提出的 TTSR 网络模型是一种可学习的纹理提取器,其通过训练来获取最适合超分辨率重建的纹理信息,为纹理迁移和纹理合成提供丰富的纹理基础信息,最终生成高质量的超分辨率图像。

现有的 SISR 重建算法中大部分通过设计较深的网络结构和使用复杂的网络连接策略来增强特征提取能力,以利用有效的特征提取能力从低分辨率图像中学习和捕获丰富的纹理特征,进而获得高质量的超分辨率图像。但是,这种过量扩大网络深度和使用复杂的连接方式会导致网络模型的大小和计算复杂度急剧上升。

1.2 神经网络的非结构化剪枝算法

神经网络的非结构化剪枝算法^[13-15]通过将某些参数归零的方式来获得稀疏子网络,一般地,神经网络的稀疏性可以提高特征选择和泛化的能力。一方面,一些研究者通过探索有效的非结构剪枝方式去获得稀疏子网络,如利用不同的正则化技术或设计可行的剪枝策略。文献[13-14, 16]所提出的方法是通过利用 L2 正则化技术优化基于卷积神经网络(Convolutional Neural Network, CNN)的模型来获得稀疏子网络。文献[15]通过 L0 正则化技术来获得稀疏子网络。文献[17]通过联合正则化技术和参数的敏感度评估来实现剪枝的过程。不同于上述利用正则化技术的方法,文献[8]通过迭代的动态剪枝过程将不重要的参数归零来搜索最优的稀疏子网络。另一方面,一些研究者把注意力放在了非结构化剪

枝方法所带来的效率问题上,并探索如何将这种效率落实到硬件设备上。文献[18]探索了在CNN模型中找到平衡的稀疏度并在硬件设备上加速神经网络的推理过程。文献[19]通过对网络参数的评估来实现参数的剪枝和复原过程,并尝试最大化地压缩基于密集神经网络(Dense Neural Network, DNN)或CNN的模型来加速训练的过程。此外,文献[13]将稀疏网络部署到单独设计的硬件设备上,获得了非常高的加速效率。

2 均衡学习的动态非结构化剪枝算法

2.1 LTH剪枝算法

神经网络的非结构化剪枝算法处理的对象是网络层中的权重参数,其目的是剪掉网络层中冗余的或者对网络模型最终输出结果几乎不产生影响的权重参数。因此,这种剪枝算法只是在网络层的权重参数层面进行处理,而不会影响整个网络模型的具体结构。LTH算法通过迭代训练的方式在每轮迭代中将无意义的权重参数归零来实现剪枝的过程,从而进一步搜索最优的稀疏子网络。具体地,LTH算法是通过比较权重参数和阈值的大小关系来判断网络层中的一个权重参数是否具有意义的。当权重参数的值小于阈值,则认为该权重参数是无意义或者冗余的,否则认为该权重参数是具有学习潜力和有意义的。阈值 λ 是一个动态的值,其计算公式为:

$$\lambda = F[f_{\text{rank}}(\mathbf{W}^t) | p] \quad (1)$$

其中: \mathbf{W}^t 表示经过 t 次迭代后任意一层网络层中的权重参数; f_{rank} 是一个将 \mathbf{W}^t 进行递增排序的函数; F 是一个计算有序权重参数的第 p 百分位数的函数。对于将权重参数归零的剪枝过程,LTH算法通过使用掩码 \mathbf{m} 与相应的 \mathbf{W}^t 对应位置上的元素相乘来实现。掩码 \mathbf{m} 的定义可以表示为:

$$\begin{cases} m_{(i,j,k)}^t = 0, |W_{(i,j,k)}^t| < \lambda \\ m_{(i,j,k)}^t = 1, |W_{(i,j,k)}^t| \geq \lambda \end{cases} \quad (2)$$

其中: i, j 和 k 表示一个张量中的元素索引。从式(2)中可以看出,当 $|W_{(i,j,k)}^t|$ 低于动态阈值 λ 时,在掩码 \mathbf{m} 对应的索引位置上将元素的值设置为0,否则将元素的值设置为1。通过这种方式,在每轮的迭代剪枝中舍弃无意义的权重参数,而保留具有潜力的权重参数去学习数据的特征表示。网络层中权重参数的归零处理可以被表示为:

$$\mathbf{W}^t = \mathbf{W}_0 \odot \mathbf{m}^t \quad (3)$$

其中: \mathbf{W}_0 是网络层进行随机初始化时的权重参数; \odot 运算符表示2个张量之间相同位置上的元素相乘。通过式(3),在每轮迭代剪枝中使用网络层初始化时的权重参数 \mathbf{W}_0 来初始化本次迭代的权重参数,并将其作为模型微调的初始状态。虽然LTH算法在图像分类任务上通过搜索最优的稀疏子网络获得了突出的性能表现,但是在图像超分辨率重建任务上却不

能获得较好的效果。

2.2 RLTH剪枝算法

本文在LTH算法的基础上改变权重参数的非均衡学习策略,提出一个基于均衡学习策略的非结构化剪枝算法RLTH。通过在训练的过程中监听网络层权重参数的变化过程,将参数值落入局部小范围内的权重参数加入到冻结队列中。权重参数一旦加入到冻结队列,将在本次迭代中保持当前的值,不再对参数进行更新。换言之,当权重参数在训练的过程中变成一个极小的值,则其对输出特征图所产生的影响是微乎其微的。因此,对于这类权重参数,可以选择不再对其进行参数的更新,而将特征学习的侧重点放在有潜力的权重参数上。在具体实现时,本文通过控制权重参数在训练过程中所产生的梯度来实现,其中梯度的控制可以表示为:

$$\begin{cases} \mathbf{g}_{(i,j,k)}^t = \frac{\partial L_{\text{loss}}(\mathbf{W}_{(i,j,k)}^t)}{\partial \mathbf{W}_{(i,j,k)}^t}, |\mathbf{W}_{(i,j,k)}^t| \geq \text{EPS} \\ \mathbf{g}_{(i,j,k)}^t = 0, |\mathbf{W}_{(i,j,k)}^t| < \text{EPS} \end{cases} \quad (4)$$

其中: L_{loss} 是损失函数; $\mathbf{g}_{(i,j,k)}^t$ 是网络层中相应索引位置上权重参数的梯度值;EPS是一个固定的正数阈值。在训练的过程中,本文将绝对值大小在阈值范围内的权重参数的梯度归零,限制它们在微调训练的过程中学习特征的表达。最终, \mathbf{W}^t 的参数优化过程可以表示为:

$$\mathbf{W}_{(i,j,k)}^t = \mathbf{W}_{(i,j,k)}^{t-1} - \alpha \mathbf{g}_{(i,j,k)}^t \quad (5)$$

其中: α 是参数优化的学习率。通过这种均衡的学习方式,本文所提出的RLTH算法在满足特征多样性的前提下使网络层的权重参数能够最大化地学习到图像的特征信息。相对而言,虽然LTH算法通过非均衡的学习策略能够实现网络层最大化的稀疏程度,但其忽略了负数阶的权重参数在特征多样性的学习中所占的比重。对于图像超分辨率重建任务而言,特征多样性的学习扮演了最重要的角色。算法1描述了RLTH算法的过程,其中: T 表示迭代剪枝的次数; E 表示训练的迭代次数; D 表示训练数据集。

算法1 RLTH算法

输入 随机初始化的神经网络模型 $\mathbf{M} = f(\mathbf{W}_0)$,掩码 $\mathbf{m} = \{0, 1\}^m$

1. for $t = 1$ in T do
2. if $t > 1$ then
3. 计算 $\{|\mathbf{W}^{t-1}| \neq 0\}$ 的第 p 百分位数 λ
4. if $|\mathbf{W}_{(i,j,k)}^{t-1}| < \lambda$ then
5. $\mathbf{m}_{(i,j,k)}^t = 0$
6. end if
7. 重新初始化网络参数: $\mathbf{W}^t = \mathbf{W}_0 \odot \mathbf{m}^t$
8. end if
9. for $e = 1$ in E do
10. for d in D do
11. 前向传播: $f(d, \mathbf{W}^t)$
12. 计算梯度: $\mathbf{g}^t = \frac{\partial L}{\partial \mathbf{W}^t}$

```

13.if  $|W_{(i,j,k)}^t| < \text{EPS}$  then
14.  $g_{(i,j,k)}^t = 0$ 
15.end if
16.更新权重参数:  $W^t \leftarrow (W^t, g^t)$ 
17.end for
18.end for
19.end for

```

2.3 基于RLTH剪枝算法的MSRResNet网络模型

本文所使用的网络模型MSRResNet^[6]整体框架如图1所示。




图1 MSRResNet网络模型框架

Fig.1 Framework of MSRResNet network model

低分辨率图像 I_{LR} 作为该端到端网络模型的输入, 首先经过卷积层的特征提取过程, 可以表示为:

$$I_{fea} = C_{extract}(I_{LR}) \quad (6)$$

其中: $C_{extract}$ 是实现特征提取的卷积神经网络; I_{fea} 是卷积神经网络对低分辨率图像 I_{LR} 所提取到的特征图。然后, 特征图 I_{fea} 经过深度网络模块的非线性映射过程, 可以表示为:

$$I_{deep} = C_{deep}(I_{fea}) \quad (7)$$

其中: C_{deep} 是实现特征的非线性映射的卷积神经网络; I_{deep} 是特征图 I_{fea} 经过深度网络模块的非线性映射后得到的深度特征图。最后, I_{deep} 在经过上采样和特征融合过程后重建为超分辨率图像, 该过程可以表示为:

$$I_{HR} = C_{merge}(C_{up}(I_{deep})) \quad (8)$$

其中: C_{up} 是实现上采样的卷积神经网络; C_{merge} 是实

现特征融合的卷积神经网络; I_{HR} 是最终重建的超分辨率图像。

图1所示的网络层可以分为两类, 一类是由独立的卷积层作为特征学习的模块, 另一类是由多层深度的卷积层通过复杂的连接策略所构成的Basic Block网络模块。其中, Basic Block网络模块是一个可扩展和替换的特征学习网络模块。值得注意的是, 本文只是对网络模型中参数量占主导地位的Basic Block网络模块应用RLTH算法, 利用该算法的迭代剪枝方式和均衡的学习策略去搜索最优的稀疏子网络, 具体流程如图2所示。通过这种方式, 可以舍弃Basic Block网络模块中冗余的参数, 把特征学习的侧重点放在有潜力的权重参数上, 避免冗余的参数所带来的消极影响。

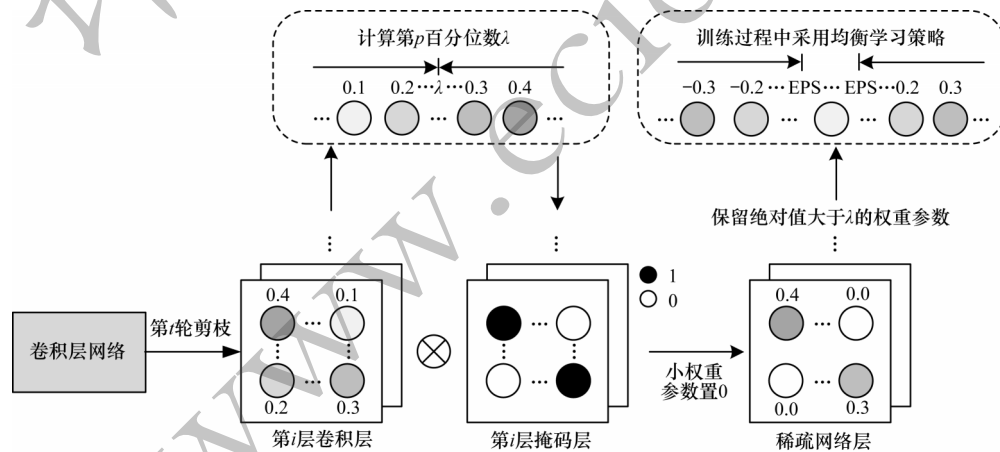


图2 RLTH算法搜索稀疏子网络的过程

Fig.2 The process of RLTH algorithm searching for sparse sub-networks

3 实验结果与分析

3.1 数据集与实验参数

为了与之前的SISR研究工作保持一致, 本文采用DIV2K^[20]的800幅训练图像进行训练。在开始训练之前, 对训练数据集进行旋转和翻转的数据增强预处理。值得注意的是, 输入模型的训练图像是从一张高分辨率图像上随机裁剪得到的96×96×3大小

的子图像。为保证测试的可靠性, 本文选择Set5^[21]、Set14^[22]和BSD100^[23]测试数据集进行实验。同时, 使用MSRA^[24]对网络的参数进行初始化, 采用Adam^[25]优化器进行优化, 初始学习率设置为10⁻⁴。Adam优化器的初始参数为: $\beta_1=0.9, \beta_2=0.999, \epsilon=10^{-9}$ 。此外, 用于优化网络模型采用的是均方误差(Mean Square Error, MSE)损失函数。

3.2 结果分析

本文在不同的测试集上对分别应用 LTH 算法和 RLTH 算法的 MSRResNet^[6] 网络模型进行性能比较。为了保证比较的公平性,对比模型采用作者提供的官网代码,并在实验中使用作者设定的默认参数。对于图像质量的客观评估标准,本文采用峰值信噪比(Peak Signal to Noise Ratio, PSNR)和结构相似度指数(Structural Similarity, SSIM)评估重建的超分辨率图像质量。在实验中,分析通过 LTH 算法和 RLTH 算法的剪枝过程后网络模型在不同稀疏百分比情况下的重建性能,并进一步分析 RLTH 算法在不同的剪枝率条件下的重建性能。除此之外,还比较重建超分辨率图像的运行时间和模型的大小,以及超分辨率图像的视觉效果。

3.2.1 客观评价标准分析

对比各个模型在 Set5、Set14 和 BSD100 测试集上的平均 PSNR 和 SSIM,如表 1 和表 2 所示,其中最优结果通过字体加粗的方式表示。表 1 列出了不同的网络模型所重建的 4 倍超分辨率图像在 RGB 通道上的平均 PSNR 和 SSIM。可以看出:应用本文所提出的 RLTH 算法在不同的测试集上的平均 PSNR 和 SSIM 都是最高的;与应用 LTH 算法相比,应用 RLTH 算法在 Set5 测试集上平均 PSNR 和 SSIM 分别提高 0.65 dB 和 0.009 7,在 Set14 测试集上分别提高 0.48 dB 和 0.011 5,而在 BSD100 测试集上分别提高 0.37 dB 和 0.011 6;与原始模型相比,应用 RLTH 算法在 Set5、Set14 和 BSD100 测试集上分别提高 0.1 dB 和 0.002 1、0.07 dB 和 0.000 7、0.08 dB 和 0.001。表 2 列出了重建的 4 倍超分辨率图像在 Y 通道上的平均 PSNR 和 SSIM。可以看出:应用 RLTH 算法的网络模型在不同的测试集上表现最好。

表 1 在 Set5、Set14 和 BSD100 测试集上的性能评估(RGB 通道)

Table 1 Performance evaluation on the Set5, Set14 and BSD100 test sets(RGB channel)

网络模型	Set5 测试集		Set14 测试集		BSD100 测试集	
	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM
MSRResNet	30.13	0.863 2	26.78	0.744 7	26.21	0.711 2
MSRResNet+LTH	29.58	0.854 4	26.37	0.733 9	25.92	0.700 6
MSRResNet+RLTH	30.23	0.865 3	26.85	0.745 4	26.29	0.712 2

表 2 在 Set5、Set14 和 BSD100 测试集上的性能评估(Y 通道)

Table 2 Performance evaluation on Set5, Set14 and BSD100 test sets(Y channel)

网络模型	Set5 测试集		Set14 测试集		BSD100 测试集	
	PSNR /dB	SSIM	PSNR /dB	SSIM	PSNR /dB	SSIM
MSRResNet	32.02	0.892 6	28.57	0.780 8	27.54	0.734 7
MSRResNet+LTH	31.43	0.884 6	28.14	0.770 3	27.25	0.724 5
MSRResNet+RLTH	32.12	0.894 3	28.64	0.781 4	27.59	0.735 4

本文在 Set5 测试集上对比通过 LTH 算法和 RLTH 算法的剪枝过程后,网络模型在不同的稀疏百分比情况下的重建性能,如图 3 所示。可以看出,应用 RLTH 算法的网络模型总体上是先逐渐上升而随后逐渐下降的,并在稀疏百分比为 7.95% 时获得了最优的平均 PSNR。虽然应用 LTH 算法的网络模型总体上与应用 RLTH 算法的趋势相似,但是由于该算法采用不平衡的学习策略而忽视了权重参数学习的多样性,导致在图像超分辨率任务上效果较差。相对而言,本文所提出的 RLTH 算法在保证网络模型的稀疏性的前提下,同时能够确保权重参数学习的多样性。因此,网络模型在应用 RLTH 算法之后,重建的性能得到了明显的提高。

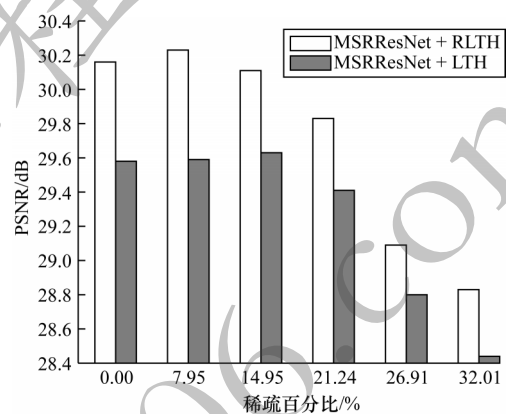


图 3 不同稀疏百分比下的 PSNR 比较

Fig.3 Comparison of PSNR under different sparsity percent

在 Set5 测试集上进一步分析剪枝率对应用 RLTH 算法的网络模型所产生的影响,如图 4 所示。可以看出,网络模型在采用较小剪枝率的条件下获得了较高的平均 PSNR,而采用较大的剪枝率反而效果较差。实验结果表明,网络模型搜索最优的稀疏子网络是一个渐进搜索和微调的过程,不能采用大范围的搜索方式。




图 4 不同剪枝率下的 PSNR 比较

Fig.4 Comparison of PSNR under different pruning percent

3.2.2 主观评价标准分析

对重建的 4 倍超分辨率图像进行视觉效果比较,如图 5 和图 6 所示,相关 PSNR 和 SSIM 指标如表 3 所示。可以看出,应用 RLTH 算法的网络模型所

重建的超分辨率图像拥有更丰富的细节特征,并且内容的轮廓更清晰。在图5中,应用RLTH算法的模型所重建的 Butterfly 图像在翅膀上的斑点更清晰,并且拥有更多的细节特征。在图6中,应用RLTH算法的模型所重建的 Woman 图像在整体和局部的轮廓上更清晰,而原始模型所重建的图像在局部细节上相对比较模糊。

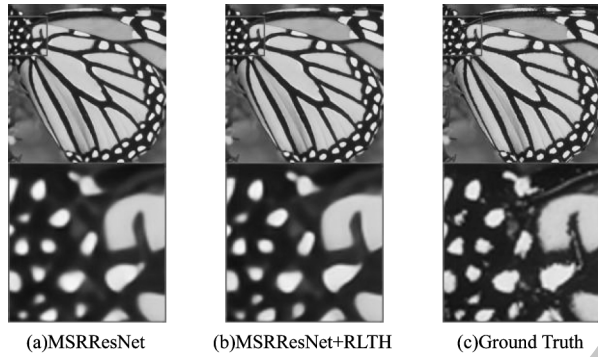


图5 Butterfly重建图像的视觉效果比较

Fig.5 Comparison of visual quality of the reconstructed Butterfly image



图6 Woman重建图像的视觉效果比较

Fig.6 Comparison of visual quality of the reconstructed Woman image

表3 Butterfly与Woman重建图像性能指标

Table 3 Performance index for reconstructed Butterfly and Woman images

算法	Butterfly 重建图像		Woman 重建图像	
	PSNR/dB	SSIM	PSNR/dB	SSIM
MSRResNet	26.90	0.902 5	28.91	0.900 0
MSRResNet+RLTH	27.10	0.906 5	29.17	0.903 5

3.2.3 运行效率分析

在Set5测试集上比较重建4倍超分辨率图像所消耗的时间,如表4所示。为了保证比较的公平性,本文在同一个平台环境(Inter Core i5 10600+NVIDIA GTX2060 Super)中对网络模型进行测试。可以看出,应用RLTH算法的网络模型与原始模型在重建超分辨率图像时所消耗的时间基本一致。同时,网络模型的大小也是保持一致的。由于RLTH

算法的剪枝过程只是在训练阶段通过剪枝评估策略对权重参数进行评估,并将被评估为冗余的权重参数置为零,因此这种非结构化的剪枝方式仅仅改变的是网络层中权重参数的大小,并不会改变网络模型的整体结构。此外,RLTH算法在训练阶段实则是起到一个指导训练的作用,而非是一个具体的网络层模块。因此,应用RLTH算法的模型与原始模型的大小是一致的,并不会增加网络模型的参数量,模型大小均为5.8 MB。

表4 重建高分辨率图像所消耗的时间

Table 4 Time consuming for high-resolution images

图像	reconstruction		ms
	MSRResNet	MSRResNet+RLTH	
Baby	3.989 7	3.988 5	
Bird	2.992 2	2.991 7	
Butterfly	3.961 1	3.991 8	
Head	4.988 0	3.989 5	
Woman	3.989 2	3.959 7	

4 结束语

本文基于LTH算法提出适用于图像超分辨率重建任务的动态非结构化剪枝算法RLTH,在保证网络模型稀疏性的同时,通过均衡的学习策略来确保权重参数学习特征的多样性。实验结果表明,在不改变网络结构和不增加计算复杂度的前提下,RLTH剪枝算法应用在SISR网络模型上能够明显提高重建的超分辨率图像质量。后续将在图像超分辨率重建任务中应用神经网络的结构化剪枝算法,使图像质量和效率得到进一步提升。

参考文献

- [1] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2016; 1646-1654.
- [2] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2017; 105-114.
- [3] LIM B, SON S, KIM H. Enhanced deep residual networks for single image super-resolution[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2017; 1132-1140.
- [4] WANG X T, YU K, WU S X. ESRGAN: enhanced super-resolution generative adversarial networks[C]//Proceedings of 2018 European Conference on Computer Vision. Berlin, Germany; Springer, 2018; 63-79.
- [5] LIU Z, SUN M J, ZHOU T H, et al. Rethinking the value of network pruning[EB/OL]. [2021-08-09]. <https://arxiv.org/abs/1810.05270>.

- [6] WEI D Y, WANG Z W. Multi-scale channel network based on filter pruning for image super-resolution[J]. *Optik*, 2021, 236: 1-10.
- [7] CHEN S, HUANG K, LI B W, et al. Adaptive hybrid composition based super-resolution network via fine-grained channel pruning [C]//Proceedings of 2020 European Conference on Computer Vision. Berlin, Germany: Springer, 2020: 119-135.
- [8] FRANKLE J, CARBIN M. The lottery ticket hypothesis: finding sparse, trainable neural networks[EB/OL]. [2021-08-09]. <https://arxiv.org/abs/1803.03635>.
- [9] DONG C, LOY C C, HE K M, et al. Image super-resolution using deep convolutional networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.
- [10] GUO Y, CHEN J, WANG J D, et al. Closed-loop matters: dual regression networks for single image super-resolution [C]//Proceedings of 2020 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2020: 5406-5415.
- [11] LIU J, ZHANG W J, TANG Y T, et al. Residual feature aggregation network for image super-resolution [C]//Proceedings of 2020 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2020: 2356-2365.
- [12] YANG F Z, YANG H, FU J L, et al. Learning texture transformer network for image super-resolution [C]//Proceedings of 2020 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2020: 5790-5799.
- [13] HAN S, LIU X Y, MAO H Z, et al. EIE: efficient inference engine on compressed deep neural network [J]. *ACM SIGARCH Computer Architecture News*, 2016, 44(3): 243-254.
- [14] HAN S, POOL J, TRAN J, et al. Learning both weights and connections for efficient neural networks[EB/OL]. [2021-08-09]. <https://arxiv.org/pdf/1506.02626.pdf>.
- [15] LOUZOS C, WELLING M, KINGMA D P. Learning sparse neural networks through L0 regularization[EB/OL]. [2021-08-09]. <https://arxiv.org/abs/1712.01312>.
- [16] HAN S, MAO H Z, DALLY W J. Deep compression: compressing deep neural network with pruning, trained quantization and huffman coding[EB/OL]. [2021-08-09]. <https://arxiv.org/pdf/1510.00149.pdf>.
- [17] TARTAGLIONE E, LEPSØY S, FIANDROTTI A, et al. Learning sparse neural networks via sensitivity-driven regularization[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Cambridge, USA: MIT Press, 2018: 3882-3892.
- [18] MAO H Z, HAN S, POOL J, et al. Exploring the regularity of sparse structure in convolutional neural networks[EB/OL]. [2021-08-09]. <https://arxiv.org/pdf/1705.08922.pdf>.
- [19] GUO Y W, YAO A B, CHEN Y R. Dynamic network surgery for efficient DNNs[EB/OL]. [2021-08-09]. <https://arxiv.org/pdf/1608.04493.pdf>.
- [20] LUGMAYR A, DANELLJAN M, TIMOFTE R. NTIRE 2020 challenge on real-world image super-resolution: methods and results [C]//Proceedings of 2020 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2020: 2058-2076.
- [21] BEVILACQUA M, ROUMY A, GUILLEMOT C, et al. Low-complexity single-image super-resolution based on nonnegative neighbor embedding [C]//Proceedings of British Machine Vision Conference. Berlin, Germany: Springer, 2012: 135.
- [22] ZEYDE R, ELAD M, PROTTER M. On single image scale-up using sparse-representations [C]//Proceedings of International Conference on Curves and Surfaces. Berlin, Germany: Springer, 2012: 711-730.
- [23] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C]//Proceedings of 2001 IEEE International Conference on Computer Vision. Washington D. C., USA: IEEE Press, 2001: 416-423.
- [24] HE K M, ZHANG X Y, REN S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C]//Proceedings of 2015 IEEE International Conference on Computer Vision. Washington D. C., USA: IEEE Press, 2015: 1026-1034.
- [25] KINGMA D, BA J. Adam: a method for stochastic optimization[EB/OL]. [2021-08-09]. <https://arxiv.org/pdf/1412.6980.pdf>.