

## 结合门控融合网络和残差傅里叶变换重建太阳斑点图

黄亚群, 郑培煜, 蒋慕蓉, 杨磊, 罗俊

### 引用本文

黄亚群, 郑培煜, 蒋慕蓉, 杨磊, 罗俊. 结合门控融合网络和残差傅里叶变换重建太阳斑点图[J]. 计算机科学, 2023, 50(11A): 220800229-7.

HUANG Yaqun, ZHENG Peiyu, JIANG Murong, YANG Lei, LUO Jun. Reconstruction of Solar Speckle Image Combined with Gated Fusion Network and Residual Fourier Transform [J]. Computer Science, 2023, 50(11A): 220800229-7.

---

### 相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [结合多聚焦融合和DSGEF双阶段网络重建太阳斑点图](#)

Combining Multi-focus Fusion and DSGEF Two-stage Network to Reconstruct Solar Speckle Image  
计算机科学, 2023, 50(6A): 220600182-6. <https://doi.org/10.11896/jsjcx.220600182>

#### [结合稳像补帧与VIBE算法的抖动视频前景目标提取方法](#)

Using Image Stabilization and VIBE Algorithm to Extract Foreground Target from Jitter Video  
计算机科学, 2022, 49(11A): 210800195-8. <https://doi.org/10.11896/jsjcx.210800195>

#### [智能博弈对抗方法: 博弈论与强化学习综合视角对比分析](#)

Methods in Adversarial Intelligent Game: A Holistic Comparative Analysis from Perspective of Game Theory and Reinforcement Learning  
计算机科学, 2022, 49(8): 191-204. <https://doi.org/10.11896/jsjcx.220200174>

#### [即时策略博弈在线对抗规划方法综述](#)

Survey on Online Adversarial Planning for Real-time Strategy Game  
计算机科学, 2022, 49(6): 287-296. <https://doi.org/10.11896/jsjcx.210600168>

#### [基于改进Marching Tetrahedra算法的锥体气象数据三维重建](#)

Three-dimensional Reconstruction of Cone Meteorological Data Based on Improved Marching Tetrahedra Algorithm  
计算机科学, 2021, 48(11A): 644-647. <https://doi.org/10.11896/jsjcx.210200025>

# 结合门控融合网络和残差傅里叶变换重建太阳斑点图

黄亚群<sup>1</sup> 郑培煜<sup>1</sup> 蒋慕蓉<sup>1</sup> 杨磊<sup>2</sup> 罗俊<sup>1</sup>

1 云南大学信息学院 昆明 650500

2 中国科学院云南天文台 昆明 650011

(huangyq@ynu.edu.cn)

**摘要** 使用现有深度学习算法重建云南天文台拍摄的高度模糊太阳斑点图像时,出现高频信息丢失、边缘模糊、重建难度大等问题。对此,提出一种结合门控融合网络与残差傅里叶变换的太阳斑点图重建算法,其中门控融合网络由一个生成器和两个鉴别器组成,生成器包含去模糊模块、高维特征提取模块、门控模块和重建模块。去模糊模块采用基于双注意力机制的U形网络框架,获取低分辨率图像去模糊后的特征;高维特征提取模块使用残差傅里叶变换的卷积块,提取包含图像空间细节的高维特征;门控模块将上述两个特征进行融合,得到权重图,与去模糊后的特征进行加权后,再与高维特征融合,得到融合特征;重建模块采用残差傅里叶变换的卷积块和像素混洗层,将门控模块得到的融合特征图进行重建,得到高分辨率图像。利用两个鉴别器分别鉴别去模糊模块产生的去模糊图像和重建模块产生的高分辨率图像的真实性。最后,设计包含像素内容损失、感知损失和对抗损失的组合训练损失函数,指导模型训练。实验结果显示,所提方法与现有深度学习重建方法相比,高频信息的恢复能力更强,边缘轮廓更清晰,结构相似性和峰值信噪比指标更高。

**关键词:** 太阳斑点图重建;门控融合网络;残差傅里叶变换;双注意力机制

**中图法分类号** TP391.41

## Reconstruction of Solar Speckle Image Combined with Gated Fusion Network and Residual Fourier Transform

HUANG Yaquin<sup>1</sup>, ZHENG Peiyu<sup>1</sup>, JIANG Murong<sup>1</sup>, YANG Lei<sup>2</sup> and LUO Jun<sup>1</sup>

1 School of Information Science and Engineering, Yunnan University, Kunming 650500, China

2 Yunnan Observatories, Chinese Academy of Sciences, Kunming 650011, China

**Abstract** When using the existing deep learning algorithm to reconstruct the highly blurred solar speckle image taken by the Yunnan Observatory, there are problems such as loss of high-frequency information, blurred edges, and difficulty in reconstruction. This paper proposed a solar speckle image reconstruction algorithm combining gated fusion network and residual Fourier transform. The gated fusion network consists of a generator and two discriminators. The generator contains a deblurring module, a high-dimensional feature extraction module, a gating module and a reconstruction module. The deblurring module adopts the U-shaped network framework based on the double attention mechanism to obtain the deblurred features of the low-resolution image; the high-dimensional feature extraction module uses the convolution block of the residual Fourier transform to extract high-dimensional features containing image spatial details; the gating module fuses the above two features to obtain a weight map, the weight map weighted with the deblurred features, and then fused with high-dimensional features to obtain fused features; the reconstruction module uses the residual Fourier transform convolution block and pixel shuffling layer to reconstruct the fusion feature map obtained by the gating module to obtain a high-resolution image. Two discriminators are used to identify the authenticity of the deblurred image produced by the deblurring module and the high-resolution image produced by the reconstruction module, respectively. Finally, a combined training loss function including pixel content loss, perceptual loss and adversarial loss is designed to guide model training. Experimental results show that compared with existing deep learning reconstruction methods, the proposed method has stronger recovery ability of high-frequency information, clearer edge contours, higher structural similarity and peak signal-to-noise ratio indicators.

**Keywords** Solar speckle image reconstruction, Gated fusion network, Residual Fourier transform, Dual attention mechanism

基金项目:国家自然科学基金(11773073);云南省高校科技创新团队支持项目(IRTSTYN);云南大学专业学位研究生教学案例库建设项目(2022XJALK02)

This work was supported by the National Natural Science Foundation of China(11773073), Science and Technology Innovation Team Support Project of Yunnan Province(IRTSTYN) and Construction Project of Teaching Case Base for Professional Degree Graduates of Yunnan University(2022XJALK02).

通信作者:郑培煜(zhengpy@mail.ynu.edu.cn)

## 1 引言

太阳对人类生活有着很大的影响。通过地基光学望远镜观测太阳活动的变化情况并实施空间预警,可以降低太阳活动对人类的影响。但是由于地球大气的干扰,获得的太阳活动观测图像是严重模糊的,需要采用图像重建方法对模糊太阳斑点图进行高分辨率重建。对低分辨率太阳斑点图像进行高分辨率重建的经典方法有基于消息传递接口的选帧位移叠加(Level1+)<sup>[1]</sup>、多帧盲反卷积<sup>[2]</sup>、斑点掩膜法<sup>[3]</sup>、斑点相位差法<sup>[4]</sup>等,这些方法需要较多的先验知识和图像帧数,存在计算量大、无法恢复部分高频信息等问题。近年来,深度学习技术发展迅速,已广泛应用于图像处理领域。如何将深度学习方法应用于太阳斑点图像的重建,是天文图像处理的研究热点之一。

基于深度学习的图像重建算法,如 Deblur-GANv2<sup>[5]</sup>、NBNet<sup>[6]</sup>、DRN-L<sup>[7]</sup>和 Cycle-GAN<sup>[8]</sup>等,对具有较大信息量和明显特征的低分辨率图像有较好的重建效果。Deblur-GANv2<sup>[5]</sup>是具有双尺度鉴别器的生成对抗网络,将特征金字塔网络引入去模糊中,作为其生成器的核心构件,能够处理较复杂的真实模糊,生成的图像具有较好的视觉效果。NBNet<sup>[6]</sup>提出在特征空间中学习一组重构基来训练一个能够分离信号和噪声的网络,从而实现图像去噪。Guo 等<sup>[7]</sup>在 DRN-L 中设计了一种对偶回归结构来约束低分辨率到高分辨率之间的映射,以此增强 SR 的性能。Ren 等<sup>[8]</sup>在 Cycle-GAN 模型中引入感知损失函数,通过 VGG19 提取重建图像特征和参考图像特征计算内容损失,增强对图像高频信息的恢复能力,改善重建图像的细节。在图像去模糊网络中,经常使用 ResBlock<sup>[9]</sup>学习模糊图像和清晰图像之间的差异,捕获更多的图像高频信息。但 Wang 等<sup>[10]</sup>发现,ResBlock 对低频

信息建模缺乏强大的表示能力。然而,太阳斑点图具有单一特性、较多噪声和模糊的局部细节。利用上述深度学习网络模型对太阳斑点图进行重建,容易出现部分高频信息难以恢复及平滑等问题。

针对上述问题,本文提出一种结合门控融合网络和残差傅里叶变换的太阳斑点图重建算法。首先,在门控融合网络中,利用去模糊模块得到清晰的低分辨率图像及其特征,高维特征提取模块得到包含图像空间细节的高维特征,通过门控模块融合这两个特征,融合后的特征经过图像重建模块,重建出高分辨率的清晰图像。同时,将残差傅里叶变换卷积块<sup>[11]</sup>(Res FT-Conv Block)引入门控融合网络,增强 ResBlock 对低频信息建模的表示能力。最后,使用两个鉴别器分别鉴别重建模块与去模糊模块的输出图像的真实性,利用由感知损失、像素内容损失、对抗损失组成的总损失函数,保证网络的准确性和重建效果。实验结果表明,相对于现有深度学习重建方法,本文方法的重建效果具有更明显的高频信息、更清晰的边缘轮廓等特点。

本文第 2 节详细描述本文方法的网络整体结构、生成器结构和鉴别器;第 3 节介绍本文数据集的构建和网络训练过程,并将本文方法与其他算法分别对太阳斑点图及公开数据集的重建结果进行对比分析,验证本文方法的可行性;最后总结全文。

## 2 本文方法

### 2.1 网络整体结构

本文网络由一个生成器和两个鉴别器组成,生成器包含去模糊模块、高维特征提取模块、门控模块和重建模块 4 部分,如图 1 所示。

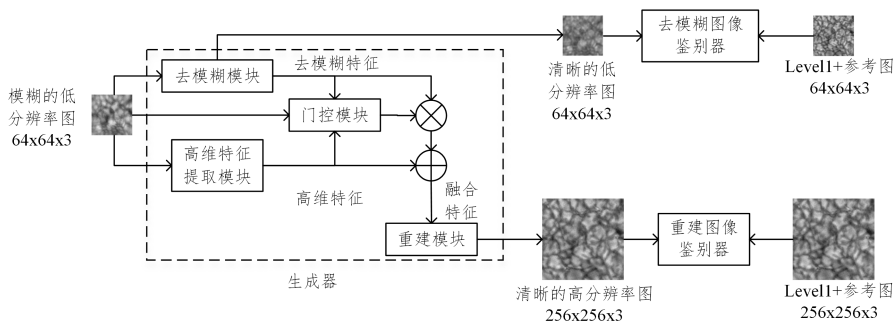


图 1 本文方法的网络框架图

Fig. 1 Network framework diagram of our method

为了恢复图像的高频信息和放大图像空间分辨率,一种方法是先进行图像去模糊处理,再进行高维特征提取及图像重建等超分辨率处理。这种单分支网络存在一些问题:一方面,第一个模型的估计误差将在第二个模型中传播和放大(即误差累积);另一方面,两个模型没有充分利用去模糊和超分辨率重建之间的相关性。为此,本文构造一种由去模糊及高维特征提取组成的双分支网络,如图 1 所示。去模糊分支用于对输入的低分辨率模糊图像进行去模糊处理,其输出特征记为去模糊特征;高维特征提取分支,提取包含图像空间细节的高维特征。本文网络的输入图像和两个分支分别提取的图像特征,经过门控模块进行融合生成权重图,再与去模糊特征进行加权处理。经过加权处理后的特征再与高维特征进行融合,得到融合特征,从而解决单分支网络的误差传播和放大的

问题,并且充分利用了在模糊区域去模糊特征和高维特征具有较高响应的相关性。最后,利用重建模块将融合特征进行重建,生成清晰的高分辨率输出图像。用两个鉴别器分别对清晰的高分辨率输出图像和清晰的低分辨率图像进行鉴别,鉴别结果产生的对抗损失都加入生成器的损失函数来寻找最优的参数。

模糊的低分辨率太阳斑点图作为本文模型的输入图像,中科院云南天文台所使用的基于消息传递接口的选帧位移叠加算法(Level1+)的重建结果图作为本文模型的参考图。

### 2.2 生成器结构

#### 2.2.1 去模糊模块

去模糊模块是将输入的模糊低分辨率图像恢复为清晰的低分辨率图像,该模块是在 U-Net<sup>[12]</sup>的基础上引入了双注意

力模块,如图 2 所示。

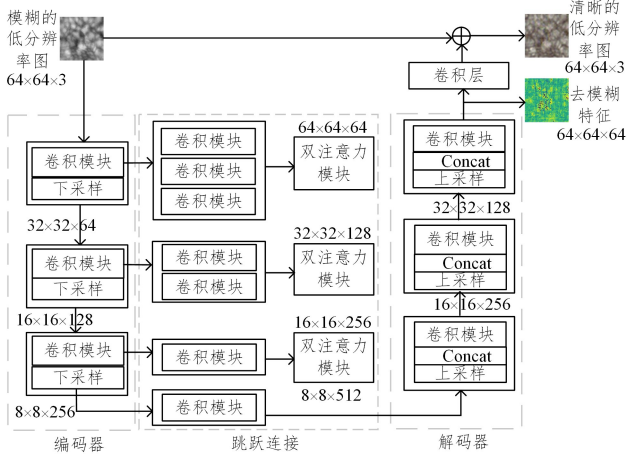


图 2 去模糊模块结构示意图

Fig. 2 Schematic diagram of the structure of deblurring module

U-Net 利用多个层次的特征映射获得丰富的多尺度上下文特征,其中编解码器之间的跳跃连接将低层的特征图从每




图 4 双注意力模块结构示意图

Fig. 4 Schematic diagram of the structure of dual attention module

### 2.2.2 高维特征提取模块

高维特征提取模块如图 5 所示,主要使用 Res FT-conv blocks(含有 8 个 Res FT-conv block)来提取包含图像空间细节的高维特征,实现图像的超分辨率。Res FT-conv block 如图 6 所示,包含两个用于残差学习的分支,一个分支通过傅里




图 5 高维特征提取模块结构示意图

Fig. 5 Schematic diagram of the structure of high-dimensional features extraction module

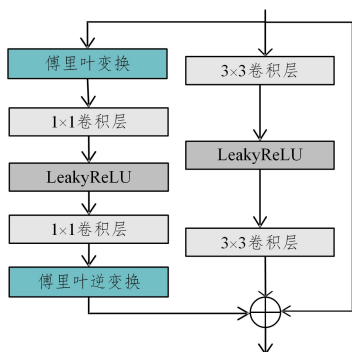


图 6 Res FT-conv block 结构示意图

Fig. 6 Schematic diagram of Res FT-conv block structure

### 2.2.3 门控模块

当高维特征提取模块得到的高维特征包含输入图像的空间细节时,去模糊模块得到的去模糊特征在模糊区域上具有很高的响应,如图 7 所示。在门结构能够发现多模态融合的

个编码器阶段传递到相应的解码器阶段,用于增强图像的去模糊过程。U-Net 中卷积模块的具体结构如图 3 所示。




图 3 卷积模块结构示意图

Fig. 3 Schematic diagram of the structure of convolution module

双注意力模块放置在每一跳跃连接中,用于抑制来自跳跃连接的底层特征图中信息量少的特征,只传递信息量多的特征。该模块的结构如图 4 所示,其特征重新校准是通过通道注意力机制<sup>[13]</sup>和空间注意力机制<sup>[14]</sup>来实现的。

去模糊模块得到的去模糊特征,一方面经过一个线性的 3×3 卷积层作为全局残差与模糊的低分辨率图相加,得到清晰的低分辨率图;另一方面送入门控模块进行特征融合。

叶变换,将空间特征图转换为频域后,使用中间具有 LeakyReLU 的两个 1×1 卷积层对频域信息进行运算,然后再应用傅里叶逆变换将频域信息变换回空间域,实现低频和高频学习;另一个分支注重局部细节,学习高频差异。高维特征提取模块输出的高维特征,被送入门控模块进行特征融合。

特征重要性的启发下<sup>[15]</sup>,本文提出使用一个能支持来自两个独立分支的局部和上下文特征融合的门控模块,选择性地融合图像的去模糊特征和高维特征。门控模块如图 8 所示,其 3 个输入分别是去模糊特征、高维特征和低分辨率模糊图像,在图像通道上融合这 3 个输入,然后经过 3×3 的卷积层、LeakyReLU 激活函数、1×1 卷积层,输出像素权重图。此像素权重图与去模糊特征逐元素相乘后,再与高维特征融合,得到融合特征。




图 7 高维特征和去模糊特征的特征响应

Fig. 7 Feature responses of high-dimensional features and deblurring features




图8 门控模块结构示意图

Fig. 8 Schematic diagram of gate control module structure

### 2.2.4 重建模块

重建模块如图9所示,由 Res FT-Conv blocks(包含8个 Res FT-Conv block)、卷积层、像素混洗层<sup>[16]</sup>和 LeakyReLU 组成。将门控模块得到的融合特征进行重建,得到清晰的高分辨率图像。

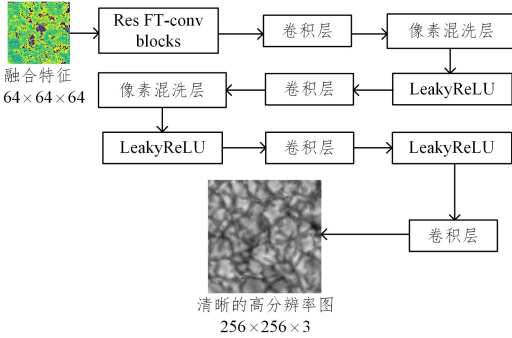


图9 重建模块结构示意图

Fig. 9 Structure diagram of reconstructed module

### 2.2.5 生成器损失函数

生成器的损失函数采用像素内容损失、感知损失和对抗损失组成的联合损失。

像素内容损失函数使用均方误差(MSE)会使重建图像的局部细节和边缘过于平滑,违背了本文的重建目标。因此,像素内容损失使用平均绝对值误差(MAE)。与重建图像的考虑相同,去模糊模块也采用 MAE 作为像素内容损失函数来引导。重建图像的像素内容损失  $L_{MAE}^{Rec}$  和去模糊模块输出结果对应的像素内容损失  $L_{MAE}^{Deb}$  的计算如式(1)、式(2)所示:

$$L_{MAE}^{Rec} = \frac{1}{n} \sum_{i=1}^n (\|G_1(I_i^{LRBlur}) - I_i^{Level1+}\|_1) \quad (1)$$

$$L_{MAE}^{Deb} = \frac{1}{n} \sum_{i=1}^n (\|G_2(I_i^{LRBlur}) - I_i^{LRLevel1+}\|_1) \quad (2)$$

正如 Johnson 等<sup>[17]</sup>所描述的,只用逐像素作差很难把重建图像恢复出原图的感知效果。鉴于此原因,需要使用感知损失。将本文网络输出的图像和 Level1+ 参考图像输入到在 ImageNet 上预训练完成的 VGG19 网络,并比较其输出结果的差异性,这会使网络输出图像的特征图与 Level1+ 图像的特征图相似,从而使得本文网络的输出图像从视觉感知上更加真实。重建图像和去模糊模块输出图像对应的感知损失的计算分别如式(3)、式(4)所示:

$$L_{Per1} = \frac{1}{n} (\|\phi(G_1(I_i^{LRBlur})) - \phi(I_i^{Level1+})\|_1) \quad (3)$$

$$L_{Per2} = \frac{1}{n} (\|\phi(G_2(I_i^{LRBlur})) - \phi(I_i^{LRLevel1+})\|_1) \quad (4)$$

为了使重建图像的质量更高,采用相对性最小二乘对抗损失<sup>[18]</sup>,因为其可以得到更加逼真的高频信息和更高质量的感知效果。相对性最小二乘对抗损失的计算如式(5)所示:

$$L_G^{GAN} = E_{z \sim p_z(z)} [(D(G(z)) - E_{x \sim p_x(x)} D(x) - 1)^2] + E_{x \sim p_x(x)} [(D(x) - E_{z \sim p_z(z)} D(G(z)) - 1)^2] \quad (5)$$

其中,  $I_i^{LRBlur}$ ,  $I_i^{Level1+}$  和  $I_i^{LRLevel1+}$  分别表示尺度为  $64 \times 64$  的第  $i$  张输入模糊图、尺度为  $256 \times 256$  的第  $i$  张 Level1+ 参考图、

$I_i^{Level1+}$  双三次下采样为尺度  $64 \times 64$  的参考图,  $G_1$  和  $G_2$  分别表示生成器和去模糊模块,  $\phi(\cdot)$  表示经过预训练的 VGG19<sup>[19]</sup> 模型,  $p_x(x)$  表示目标分布,  $p_z(z)$  表示生成分布。

生成器的损失函数通过式(1)一式(5)的各损失函数相加得到,如式(6)一式(8)所示:

$$L_{G_1} = \min_{G_1} (L_{MAE}^{Rec} + 0.006 * L_{Per1} + 0.01 * L_{G_1}^{GAN}) \quad (6)$$

$$L_{G_2} = \min_{G_2} (L_{MAE}^{Deb} + 0.006 * L_{Per2} + 0.01 * L_{G_2}^{GAN}) \quad (7)$$

$$L_G = L_{G_1} + 0.5 * L_{G_2} \quad (8)$$

其中,  $L_{G_1}^{GAN}$  表示生成器重建图像的对抗损失函数,  $L_{G_2}^{GAN}$  表示去模糊模块结果图像的对抗损失函数,  $L_{G_1}$  表示对重建模块输出的图像所做的损失函数,  $L_{G_2}$  表示对去模糊模块输出的图像所做的损失函数,  $L_G$  表示生成器的损失函数。

### 2.3 鉴别器

使用 VGG128<sup>[19]</sup> 结构作为鉴别器来辨认生成器输出结果的真假,重建模块的输出图像和去模糊模块的输出图像分别作为两个鉴别器的输入。

鉴别器使用相对性最小二乘对抗损失,如式(9)所示:

$$L_D^{GAN} = E_{z \sim p_z(z)} [(D(G(z)) - E_{x \sim p_x(x)} D(x) + 1)^2] + E_{x \sim p_x(x)} [(D(x) - E_{z \sim p_z(z)} D(G(z)) - 1)^2] \quad (9)$$

两个鉴别器的损失函数如式(10)和式(11)所示:

$$L_{D_1} = \min_{D_1} L_{G_1}^{GAN} \quad (10)$$

$$L_{D_2} = \min_{D_2} L_{G_2}^{GAN} \quad (11)$$

其中,  $L_{D_1}^{GAN}$  和  $L_{D_2}^{GAN}$  分别表示重建模块和去模糊模块的输出图像鉴别器的对抗损失函数。

在训练过程中,鉴别器  $D_1$  和  $D_2$  与生成器  $G$  进行对抗<sup>[20]</sup>,使得生成器生成高质量的重建图像和去模糊后的图像。

## 3 实验及结果分析

### 3.1 数据集

Level1+ 算法重建过程中,使用 200 帧拍摄的模糊图像重建出 1 帧,导致很多模糊图像没有对应的清晰参照图像。但 Jia 等<sup>[21]</sup>通过实验发现,深度学习网络只需要使用波长相同的模糊图和其对应的少量清晰参照图,就能进行模型的学习和恢复出该波长下很多的模糊图像<sup>[22]</sup>。根据这个结论,本文采用来自中科院云南天文台提供的模糊图像  $I^{Blur}$  与使用 Level1+ 算法得到对应的少量重建图像  $I^{Level1+}$  作为数据集 ( $I^{Blur}$ ,  $I^{Level1+}$ ),同时采用与 Jia 等相同的方式设计数据集,将挑选出的模糊图像及其对应的 Level1+ 参考图像分别进行分块操作,得到本文实际训练的数据集 ( $I_{256 \times 256}^{Blur}$ ,  $I_{256 \times 256}^{Level1+}$ ),其中包含 2 万多张尺度为  $256 \times 256$  的图像子块。本文的数据集具有一定的特殊性,模糊图  $I^{Blur}$  的模糊因子构成不同于常规的运动模糊、失焦模糊,其特征难辨认,细节获取难度大。

### 3.2 训练过程

本文网络模型使用单张 NVIDIA 1080Ti GPU 卡训练。将数据集 ( $I_{256 \times 256}^{Blur}$ ,  $I_{256 \times 256}^{Level1+}$ ) 双三次下采样为 ( $I_{64 \times 64}^{Blur}$ ,  $I_{64 \times 64}^{Level1+}$ ),为了能在训练时更快地找到最优解,采用归一化的方式把数据集 ( $I_{256 \times 256}^{Blur}$ ,  $I_{256 \times 256}^{Level1+}$ ) 和数据集 ( $I_{64 \times 64}^{Blur}$ ,  $I_{64 \times 64}^{Level1+}$ ) 固定在  $[-1, 1]$  的范围内。

本文采用两个阶段进行训练。刚开始训练时,由于网络提取到的图像特征不明显,因此在第一阶段训练时,不使用门控模块,网络训练迭代 90 次,初始学习率为 0.0001,每 30 次迭代,其数值乘以 0.1。第一阶段训练结束后,本文网络的

参数得到优化,去模糊模块和高维特征提取模块能更有效地提取输入图像的去模糊特征和高维特征,此时使用第二阶段(包含门控模块)进行网络训练,门控模块融合这两个特征,可得到较好的融合特征。第二阶段网络迭代训练 75 次,设置学习率为 0.00005,每 25 次迭代,其数值乘以 0.1。由于第一阶段没有使用门控模块,节省了网络的训练时间。本文的梯度下降算法的参数优化器是 $\beta_1$ 为 0.9、 $\beta_2$ 为 0.999 的 Adam<sup>[23]</sup>,用于优化网络。

### 3.3 重建结果对比分析

本文方法与 DeblurGANv2<sup>[5]</sup>、NBNet<sup>[6]</sup> 去模糊方法、DRN-L 超分辨率方法<sup>[7]</sup> 和 Cycle-GAN 高清恢复太阳斑点重建方法<sup>[8]</sup> 等几种算法进行对比分析,各种方法的重建结果如图 10、图 11 所示。




图 10 不同方法的重建结果图

Fig. 10 Plots of reconstruction results of different methods




图 11 不同方法的重建结果细节对比

Fig. 11 Detailed comparison of reconstruction results of different methods

图 10 中,本文方法清晰地还原了图像的整体轮廓特征;图 11 的局部放大结果中,本文方法重建出的局部高频信息与 Level1+ 图像更接近,而 Cycle-GAN 虽然可以有效地重建出边缘信息,但出现了一些细节特征的丢失。因此,本文方法重建图像的视觉效果更接近目标 Level1+。

本文使用峰值信噪比(PSNR)与结构相似度(SSIM)两种评价指标对重建图像质量进行分析,各种方法的评价指标及模型参数量如表 1 所列。

表 1 不同方法的定量评估结果

Table 1 Quantitative evaluation results of different methods

方法	PSNR/dB	SSIM	参数量/( $\times 10^6$ )
DeblurGANv2	22.632	0.629	60.9
NBNet	24.154	0.653	13.3
DRN-L	24.042	0.643	10.0
Cycle-GAN	26.871	0.798	105.2
本文方法	27.924	0.874	14.3

由表 1 可知,本文方法在 PSNR 和 SSIM 上都具有较高值,表明本文方法的重建结果具有良好的视觉效果,同时保留了模糊图像中的高频信息和轮廓结构,并且具有较小的模型参数量。虽然 NBNet 和 DRN-L 的参数量比本文方法少,但这两种方法都不能很好地重建太阳斑点图像。

### 3.4 消融实验

利用门控模块能支持来自两个独立分支的局部和上下文特征融合的特点,选择性地融合图像的去模糊特征和高维特征,从而解决单分支网络的误差传播和放大的问题,并且充分利用了在模糊区域去模糊特征和高维特征具有较高响应的相关性。通过残差傅里叶变换对模糊图像和清晰图像之间的高频和低频差异进行建模。为了验证门控模块和残差傅里叶变换对整个模型的影响,对不含门控模块的模型、不含残差傅里叶变换的模型与本文方法进行测试,评价结果及重建结果如表 2 与图 12 所示。加入门控模块后,PSNR 与 SSIM 分别提高 1.089 dB 和 0.088;加入残差傅里叶变换后,PSNR 和 SSIM 分别提高 1.598 dB 和 0.099。结果表明,门控模块和残差傅里叶变换确实能提高整个模型的性能。

表 2 不含门控模块或不含残差傅里叶变换的定量评估结果

Table 2 Quantitative evaluation results without gating module or without residual Fourier transform

方法	PSNR/dB	SSIM
不含门控模块(FG)	26.835	0.786
不含残差傅里叶变换(FT)	26.326	0.775
本文方法	27.924	0.874




图 12 不含门控模块或不含残差傅里叶变换的重建结果比较图

Fig. 12 Comparison plot of reconstruction results without gating module or without residual Fourier transform

### 3.5 公开数据集对比结果

通过与 DeblurGANv2<sup>[5]</sup>、Li<sup>[22]</sup>、SRN<sup>[24]</sup>、Gao<sup>[25]</sup>、DBGAN<sup>[26]</sup> 算法在公开数据集 GoPro<sup>[27]</sup> 上进行比较,检验本文模型是否适用于常规的模糊图像。

Li<sup>[22]</sup> 方法首先采用特征金字塔网络(FPN)框架来获取图像多尺度特征,再将这些特征分层输入梯度分支,以梯度图的形式捕获更小的局部特征;其次,联合梯度分支结果与 FPN 结果共同重建出具有高频信息的图像;然后,在常规对抗鉴别器的基础上,增加一个鉴别器用于保证由梯度分支产生的梯度图更加真实;最后,联合训练多种损失函数来引导模型进行图像高分辨率重建。

SRN<sup>[24]</sup> 构造 3 个不同尺度的编码器-解码器结构,将模糊图分成 3 个不同尺度大小的图像,逐级输入编码器-解码器当中;然后,通过上采样连接不同尺度的特征图像,得到最终的重建结果。

Gao<sup>[25]</sup> 提出通用且有效的选择性共享方案来发展约束去模糊网络结构的一般原则。在每个尺度的子网络中,其为非线性变换模块提出了一个嵌套的跳跃连接结构,以替换堆叠的卷积层或残差块。

DBGAN<sup>[26]</sup> 提出一种结合两种 GAN 模型的新方法,即学

习模糊 GAN(BGAN)和学习去模糊 GAN(DBGAN)。第一个模型 BGAN 学习如何用不成对的清晰和模糊图像集模糊清晰的图像,然后指导第二个模型 DBGAN 学习如何正确地去模糊这些图像。该方法利用相对模糊损失减少了真实模糊和合成模糊之间的差异。

表 3 的定量评估结果和图 13 的定性评估结果表明,本文模型在公开数据集上也有不错的表现,能够对图像的局部细节进行有效的恢复。



模糊图



图 13 不同算法在公开数据集 GoPro 上的去模糊结果

Fig. 13 Deblurring results of different algorithms on public dataset GoPro

**结束语** 本文提出的基于门控融合网络和残差傅里叶变换的太阳斑点图重建方法,从模糊的低分辨率输入图像中恢复出清晰的高分辨率图像,能够对模糊的太阳斑点图进行有效重建。本文方法采用双分支结构有效地提取图像去模糊特征和高维特征,并利用门控模块对提取的特征进行融合,重建模块将融合后的特征进行重建,输出清晰的高分辨率图像。在损失函数方面,使用平均绝对值误差和相对性最小二乘对抗损失,分别对局部细节进行重建和获取高质量感知图像。

实验结果表明,本文方法对特征单一的模糊太阳斑点图具有较强的恢复能力,相较于其他深度学习模型,本文方法具有更好的视觉效果和更高的评估指标。

## 参考文献

- [1] XIANG Y Y. Research on high speed high resolution solar reconstruction algorithm [D]. Beijing: University of Chinese Academy of Science, 2016:19-22.
- [2] SCHULZ T J. Multiframe blind deconvolution of astronomical images[J]. Journal of the Optical Society of America A, 1993, 10(5):1064-1073.
- [3] LIU Z. Research on high-resolution image reconstruction and spatial characteristics of astronomical images[D]. Beijing: University of Chinese Academy of Science, 2003:25-39.
- [4] GONSALVES R A, CHIDLAW R. Wavefront sensing by phase retrieval[C] // Applications of Digital Image Processing III. SPIE, 1979:32-39.
- [5] KUPYN O, MARTYNIUK T, WU J, et al. Deblurgan-v2: Deblurring (orders-of-magnitude) faster and better[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019:8878-8887.
- [6] CHENG S, WANG Y, HUANG H, et al. Nbnnet: Noise basis learning for image denoising with subspace projection[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021:4896-4906.
- [7] GUO Y, CHEN J, WANG J, et al. Closed-loop matters: Dual regression networks for single image super-resolution[C] // Pro-

表 3 不同算法在 GoPro 数据集上的定量评估结果

Table 3 Quantitative evaluation results of different algorithms on


GoPro dataset

方法	PSNR/dB	SSIM
DeblurGANv2	29.551	0.933
Li	28.922	0.923
SRN	30.262	0.934
Gao	30.904	0.935
DBGAN	31.103	0.941
本文方法	31.151	0.944

ceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:5407-5416.

- [8] REN Y, JIANG M, FU Z, et al. Reconstruction of single-frame solar speckle image with cycle consistency loss and perceptual loss[C] // 2019 6th International Conference on Information Science and Control Engineering (ICISCE). IEEE, 2019:439-443.
- [9] 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.
- [10] WANG H, WU X, HUANG Z, et al. High-frequency component helps explain the generalization of convolutional neural networks[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:8684-8694.
- [11] MAO X, LIU Y, SHEN W, et al. Deep Residual Fourier Transformation for Single Image Deblurring[J]. Computer Science-Computer Vision and Pattern Recognition. arXiv:2111.11745, 2021.
- [12] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C] // International Conference on Medical Image Computing and Computer-assisted Intervention. Cham: Springer, 2015:234-241.
- [13] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:7132-7141.
- [14] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C] // Proceedings of the European Conference on Computer Vision. 2018:3-19.
- [15] REN W, MA L, ZHANG J, et al. Gated fusion network for single image dehazing[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:3253-3261.
- [16] SHI W, CABALLERO J, HUSZAR 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.
- [17] JOHNSON J, ALAHI A, LI F F. Perceptual losses for real-time

- style transfer and super-resolution[C]// European Conference on Computer Vision. Cham:Springer,2016:694-711.
- [18] MAO X,LI Q,XIE H,et al. Least squares generative adversarial networks[C]// Proceedings of the IEEE International Conference on Computer Vision. 2017:2794-2802.
- [19] SIMONYAN K,ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science-Computer Vision and Pattern Recognition. arXiv: 1409. 1556, 2014.
- [20] CRESWELL A,WHITE T,DUMOULIN V,et al. Generative adversarial networks; An overview[J]. IEEE Signal Processing Magazine,2018,35(1):53-65.
- [21] JIA P,HUANG Y,CAI B,et al. Solar image restoration with the CycleGAN based on multi-fractal properties of texture features[J]. The Astrophysical Journal Letters, 2019, 881 (2): L30.
- [22] LI F H,J M R,Y L,et al. Solar speckle image deblurring method with gradient guidance based on generative adversarial network [J]. Computer Applications,2021,41(11):3345-3352.
- [23] KINGMA D P,BA J. Adam; A method for stochastic optimization [J]. Computer Science-Machine Learning. arXiv: 1412. 6980,2014.
- [24] TAO X,GAO H,SHEN X,et al. Scale-recurrent network for deep image deblurring[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018;8174-8182.
- [25] GAO H,TAO X,SHEN X,et al. Dynamic scene deblurring with parameter selective sharing and nested skip connections[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019;3848-3856.
- [26] ZHANG K,LUO W,ZHONG Y,et al. Deblurring by realistic blurring[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020;2737-2746.
- [27] NAH S,HYUN KIM T,MU LEE K. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017;3883-3891.



**HUANG Yaqun**, born in 1971, associate professor, is a member of China Computer Federation. Her main research interests include image reconstruction and intelligent data analysis.



**ZHENG Peiyu**, born in 1997, postgraduate. His main research interests include deep learning and image reconstruction.