

NVST 高分辨率图像中太阳小尺度结构的精细放大

王笑笑¹, 尚振宏^{1,3*}, 强振平²

¹昆明理工大学信息工程与自动化学院, 云南 昆明 650500;

²西南林业大学大数据与智能工程学院, 云南 昆明 650224;

³昆明理工大学云南省人工智能重点实验室, 云南 昆明 650500

摘要 将基于深度学习的放大方法应用于天文图像的研究中,根据新真空太阳望远镜(NVST)图像中的结构特征,提出一种有效的天文图像放大方法。首先使用 Binning 技术对数据进行降采样处理,获得对应的低分辨率图像;其次通过改进的残差稠密网络充分提取和利用低分辨率图像多级特征,重建出高分辨率的太阳图像;最后通过残差分析、相关性分析及功率谱分析对太阳图像的重建误差进行定量评估。实验结果表明,相对传统插值法,所提方法能够对太阳图像中的小尺度结构进行精细放大,且在放大图像的同时有效提高图像的信噪比。

关键词 图像处理; NVST 图像; 精细放大; Binning; 残差分析; 相关性分析; 功率谱分析

中图分类号 P182.4+1

文献标志码 A

doi: 10.3788/AOS202040.0910002

Fine Magnification of Solar Small-Scale Structures in NVST High-Resolution Images

Wang Xiaoxiao¹, Shang Zhenhong^{1,3*}, Qiang Zhenping²

¹Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming, Yunnan 650500, China;

²College of Big Data and Intelligent Engineering, Southwest Forestry University, Kunming, Yunnan 650224, China;

³Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming, Yunnan 650500, China

Abstract In this paper, a magnification method based on deep learning was used for the study of astronomical images. An effective astronomical image magnification method was proposed based on the structural characteristics of the new vacuum solar telescope (NVST) images. First, the Binning technology was used to down-sample the data to obtain the corresponding low-resolution images. Second, an improved residual dense network was used to fully extract and utilize the multi-level features of low-resolution images, and thus to enable the reconstruction of high-resolution solar images. Finally, the residual, correlation, and power spectrum analysis methods were used to quantitatively evaluate the reconstruction errors in solar images. The experimental results show that compared with the conventional interpolation method, the proposed method can finely magnify the small-scale structures and effectively improve the signal-to-noise ratio in solar images.

Key words image processing; NVST image; fine magnification; Binning; residual analysis; correlation analysis; power spectrum analysis

OCIS codes 100.2960; 120.1880; 350.1270; 100.2980

1 引 言

随着光学自适应技术^[1]和天文图像斑点重建技术^[2]的发展,通过地面太阳观测可以获得接近望远镜衍射极限的观测数据。利用高分辨率(HR)图像

可以实现对太阳上各种小尺度精细结构的研究,比如色球微暗条、微耀斑、纳耀斑、冕环、光球亮点等。在这些研究中,对目标进行形态学观察是一个非常重要的工作手段。通常这些目标的尺度在角秒甚至亚角秒量级,而在设计实际望远镜成像终端时,为了

收稿日期: 2019-12-10; 修回日期: 2019-12-27; 录用日期: 2020-01-17

* E-mail: shangzhenhong@126.com

兼顾视场和分辨率,几乎都是利用奈奎斯特频率进行采样甚至欠采样,这样即便在目前的太阳高分辨图像上,这些目标也仅占据边长为几个到几十像元的区域。如果将目标 1:1 显示在一个高清显示器上(如 1920 pixel \times 1080 pixel),而不通过图像放大的措施,是难以看清它们的各种细节的。目前常用的图像放大技术几乎都是通过插值法来进行的,比如二次线性或三次样条插值法。这些方法都是利用邻近像素的值来估计目标点的强度,如二次线性依赖周围 4 个点,三次样条依赖周围 16 个点,这意味着这些方法都会平滑掉图像信息,导致放大后的图像变模糊。但随着这几年深度学习技术的发展,利用深度学习来进行高清晰度图像放大有了非常大的进展。

基于深度学习的图像放大方法通过海量数据训练深度神经网络,建立层次化回归模型,对低质图像与目标图像之间的复杂非线性关系进行定量描述。目前,基于深度学习的图像放大方法的研究已经取得了显著的成果,许多优秀的网络模型在单幅图像的高分辨率放大中表现出了优异的性能。SRCNN 模型^[3]首次将深度学习应用于图像的高分辨率放大中,在数据输入网络之前,通过对数据的插值预处理,使图像达到目标图像大小,经过三层卷积网络输出重建的高分辨率结果。FSRCNN 模型^[4]对 SRCNN 进行了改进,该模型使用反卷积层对图像进行上采样,直接输入低分辨率(LR)图像,网络的整个运算过程都是在低分辨率空间进行的,实现了端到端的训练。与 FSRCNN 模型不同,ESPCN 模型^[5]使用亚像素卷积层对图像进行上采样。VDSR 模型^[6]使用残差的思想学习低质图像到目标图像之间的残差,残差的使用为后续的单幅图像高分辨率重建提供了新的思路和方法。DRCN 模型^[7]首次将已有的递归神经网络结构应用在单幅高分辨率图像放大方法中,并且基于 VDSR 中残差的思想,加深了网络结构。RED^[8]最主要的思想是提出一种非常深的基于卷积结构的编码-解码框架,用于图像的重建。DRRN 模型^[9]借助 ResNet^[10]的思想,使用更深的网络结构实现了网络性能的进一步提升。SRDenseNet 模型^[11]首次将 DenseNet 模型^[12]结构应用于图像高分辨率重建,并且获得了理想的效果。MemNet 模型^[13]通过引入深度持续记忆网络来实现长期的记忆功能。RDN 模型^[14]则结合 MemNet 和 SRDenseNet 的思想,提出一种新的残差稠密网络模型,该模型在单幅图像的高分辨率重建中表现出优于其他模型的性能。已经证明基于参照的图像

放大方法(RefSR)能够进一步丰富重建图像的细节信息,但是当参照图像与输入的低分辨率图像相似度较低时,重建性能明显降低。SRNTT 模型^[15]则能够自适应地对参照图像的纹理进行迁移,有效解决了 RefSR 存在的问题。除此之外,针对一般网络模型只能实现图像单一尺度的放大问题,Meta-SR 模型^[16]的提出实现了任意尺寸的图像放大,该放大方法具有更广泛的实际应用。

本文将基于深度学习的图像放大方法应用于天文领域中,对新真空太阳望远镜(NVST)高分辨率图像中的太阳小尺度结构进行精细放大。参照残差稠密网络结构,针对太阳图像的结构特征和本文的数据分析方法,对网络结构和损失函数进行改进,改进后的网络模型能够充分提取和利用低分辨率太阳图像的各级特征,且最小化损失函数使重建结果在残差分析中具有良好表现。制作训练样本对时,使用 Binning 技术^[17]对高分辨率太阳图像进行降采样处理,Binning 技术能够有效降低图像的读出噪声,经过该技术降采样之后再放大得到的高分辨率图像具有更高的信噪比(SNR)。使用残差分析、相关性分析及功率谱分析对太阳图像的重建误差进行严格的定量评估。

2 NVST 数据

一米 NVST^[18]是我国最大的太阳望远镜,也是世界上几大太阳高分辨观测系统之一。NVST 的多通道成像系统^[19-20]主要对太阳光球的氧化钛(TiO)波段(705.8 nm)和色球 Ha 波段(656.3 nm)进行观测。在 TiO 波段,斑点重建后的视场为 2560 pixel \times 2160 pixel,像素分辨率为 0.052";在 Ha 波段,斑点重建后的视场为 1024 pixel \times 1024 pixel,像素分辨率为 0.136"。这意味着 1"的精细结构在光球上占据 20 pixel,而在色球上只有 7 pixel。本工作采用的 NVST 数据是 2017-08-19T04:12:26:76—05:15:55:06 12671 号活动区的 Ha 波段观测数据经过斑点掩模法重建的结果。对 Ha 波段重建结果进行裁剪,获得 40000 张大小为 256 \times 256 的 Ha 波段图像。使用 2 \times 2 Binning 和 4 \times 4 Binning 对数据进行 2 倍和 4 倍的降采样处理。在得到的训练样本对中,30000 对作为训练集,2000 对作为验证集,8000 对作为测试集,且三种数据集之间不存在交集。研究证明,深度学习通常受益于海量数据的训练,因此训练过程中使用随机裁剪、图像旋转及图像翻转的方式进行数据扩增。

Binning 技术具体的操作是将多个相邻像素合并为一个超级像素,该超级像素的强度值为多个像素强度值的平均。在图像处理过程中,每个像素都会伴随着随机噪声,Binning 技术能够降低噪声,得益于 Binning 技术在进行多个像素的合并时噪声能相互抵消;而在像素的叠加过程中,将图像的信号相加取平均,该值接近于信号的真值,因此 Binning 技术能够有效提高图像的信噪比。令图像中每个像素的信号为 $s(a,b)$,每个像素的随机噪声方均根值为 $n(a,b)$,噪声功率为 $n^2(a,b)$ 。像素合并时,信号是线性相加的,噪声是功率相加的。假设合并 m 个像素,合并后的信号 $S(b)$ 和噪声 $N(b)$ 的表达式分别为

$$S(b) = \sum_{i=1}^m s(a,b) = m \times s(a,b), \quad (1)$$

$$N(b) = \sqrt{\sum_{i=1}^m n^2(a,b)} = \sqrt{m} \times n(a,b). \quad (2)$$

未采用 Binning 技术之前的信噪比为 $\frac{S_1}{N_1} = \frac{s(a,b)}{n(a,b)}$,采用 Binning 技术之后的信噪比为 $\frac{S_2}{N_2} = \frac{S(b)}{N(b)} = \frac{m \times s(a,b)}{\sqrt{m} \times n(a,b)} = \sqrt{m} \times \frac{S_1}{N_1}$ 。




图 1 操作过程。(a) 2×2 Binning; (b) 4×4 Binning

Fig. 1 Operating process. (a) 2×2 Binning; (b) 4×4 Binning




图 2 所提网络的结构图

Fig. 2 Architecture of proposed network

3.1.1 浅层特征提取模块

如图 2 所示,SFEM 包含两层大小为 3×3 的卷积核,且采用 SAME 卷积方式的卷积结构来提取输入的低分辨率太阳图像的低级特征。经过卷积操

因此可以证明,使用 Binning 技术对数据进行降采样,若采样过程中将 m 个像素合并,则合并后图像的信噪比为原来的 \sqrt{m} 。例如采用 4×4 Binning 对图像降采样,即将相邻的 16 个像素合并,则合并之后的图像的信噪比为原来的 4 倍。图 1 为 2×2 Binning 和 4×4 Binning 操作过程示意图。

3 网络结构和训练策略

3.1 网络结构

基于改进的残差密集连接网络,对 NVST 高分辨率图像中太阳小尺度结构进行精细放大。针对 NVST 图像高频信息较少、整体较模糊等问题,对残差密集连接网络构架进行调整,将网络中的密集跳接块(RDB)采用密集连接的方式相连。RDB 的密集连接实现了 RDB 之间特征的重复使用,有利于前 RDB 的输出与当前 RDB 特征的融合,可以充分利用网络提取到的低分辨率图像的各级特征重建出高分辨率图像的细节信息。本网络模型主要包含 3 个部分,即浅层特征提取模块(SFEM)、残差密集跳接块(RDBS)、上采样(UPM)网络,网络结构如图 2 所示,其中 I_{LR} 为输入的低分辨率图像, I_{HR} 为经过网络后输出的高分辨率图像。

作,每个卷积层均输出 64 个特征图,且特征图尺寸与低分辨率图像相同。低分辨率图像输入网络后,经过第一层网络,输出的特征图记为 F_{-1} :

$$F_{-1} = H_{SFEM_1}(I_{LR}), \quad (3)$$

式中: $H_{\text{SFE}_1}(\cdot)$ 表示浅层特征图提取网络中的第一个卷积层的操作。特征图 F_{-1} 一方面用于第二层网络中的特征提取, 另一方面直接输入后续网络, 用于计算全局残差。第二层卷积网络的操作过程为

$$F_0 = H_{\text{SFE}_2}(F_{-1}), \quad (4)$$

式中: $H_{\text{SFE}_2}(\cdot)$ 表示浅层特征图提取网络中的第二个卷积层的操作。该卷积层进一步提取到特征 F_0 ,




图 3 RDB 的结构图

Fig. 3 Architecture of RDB

令网络包含 D 个 RDB(本文中 $D = 12$), RDB 之间采用密集跳跃连接。用 F_{i-1} 表示第 $(i-1)$ 个 RDB 的输出, 那么第 i 个 RDB 的输出 F_i 为

$$F_i = R_{\text{RDB}_i}([F_0, F_1, \dots, F_{i-1}]), \quad (5)$$

式中: $R_{\text{RDB}_i}(\cdot)$ 表示第 i 个 RDB 的操作; $[F_0, F_1, \dots, F_{i-1}]$ 表示 SFEM 中第二个卷积网络的输出 F_0 与 $1, 2, \dots, i-1$ 个 RDB 输出特征的合并。假设第一个 RDB 的输入 F_0 的特征图有 R_0 个, 每一个 RDB 输出的特征图为 R 个, 则经过 D 个 RDB 的密集跳接之后输出的特征图有 $R_0 + R \times D$ 个。每一个 RDB 中包含 C 个 3×3 的卷积层 ($C = 6$), C 个卷积层之间采用密集跳跃连接。将第 i 个 RDB 的输入记为 $F = [F_0, F_1, \dots, F_{i-1}]$, 那么第 i 个 RDB 中第 j 个卷积层的输出 $F_{i,j}$ 表示为

$$F_{i,j} = \Phi_{\text{RDB}_{i,j}}([F, F_{i,1}, \dots, F_{i,j-1}]), \quad (6)$$

式中: $\Phi_{\text{RDB}_{i,j}}(\cdot)$ 表示第 i 个 RDB 中第 j 个卷积层的操作 (包含卷积操作与 ReLU); $[F, F_{i,1}, \dots, F_{i,j-1}]$ 表示多个特征的合并; F 表示第 i 个 RDB 的输入; $F_{i,1}, F_{i,2}, \dots, F_{i,j-1}$ 表示第 i 个 RDB 中第 $1, 2, \dots, j-1$ 个卷积层输出的特征图。设定 F 的特征图有 G_0 个, RDB 中每个卷积层输出的特征图为 G 个, 则经过第 i 个 RDB 中 C 个卷积层密集跳接之后的输出 $F_{i,C}$ 的特征图有 $G_0 + G \times C$ 个。经过 C 个卷积层的密集跳接提取到图像的各级特征之后, 对特征进行融合。多层卷积的密集跳接会导致特征图数量的急剧增加, 为了对特征维度进行控制, 使用 1×1 卷积对特征进行降维, 降维之后的特征图记为 $F_{i,LF}$ 。之后通过局部残差结构来加快数据在网络

将 F_0 继续传入网络的下一个模块, 作为 RDBS 的输入。

3.1.2 残差密集跳接块

RDBS 以 RDB 为基本单元, 包括密集跳接层、局部特征融合 (LFF)、局部残差学习 (LRL) 三个部分。其中密集跳接层能够充分提取并利用各级特征, LRL 能够提高信息在网络中的流动效率。RDB 的具体结构如图 3 所示。

中的流动, 将第 i 个 RDB 的输入 F 直接与 C 层卷积特征融合之后的结果 $F_{i,LF}$ 相加, 作为第 i 个 RDB 的输出。因此第 i 个 RDB 的输出 F_i 为

$$F_i = F_{i,LF} + F. \quad (7)$$

整个网络中同样需要对多个 RDB 密集跳接之后的特征进行融合和降维操作, 将该操作之后的特征图记为 F_{GF} 。将 SFEM 中第一个卷积层的输出 F_{-1} 直接输送到网络后端, 用于计算整体残差, 则上采样模块的输入 F_{DF} 为

$$F_{\text{DF}} = F_{\text{GF}} + F_{-1}. \quad (8)$$

3.1.3 上采样网络

在网络末端使用亚像素卷积对特征图进行上采样操作, 实现低分辨率图像到高分辨率图像的重构。相对于反卷积^[21]上采样, 亚像素卷积可以降低上采样过程中人工因素所造成的影响。通过多个 RDB 的密集跳接, 网络充分提取和利用了低分辨率图像的各级特征, 为最后的上采样网络提供了大量的低分辨率图像特征, 有助于网络根据低分辨率图像特征推断出高分辨率的图像细节。在网络的末端进行上采样, 一方面可以避免对图像进行插值预处理, 防止丢失相应的低分辨率图像信息; 另一方面, 整个网络的运算过程都是在低分辨率空间完成的, 减少了计算量, 加速了训练进程。

3.2 训练策略

选择合适的训练策略的目的是使训练过程能够快速收敛, 同时获得具有良好泛化能力的模型。深度模型的训练往往伴随着大量时间和计算机资源的耗费, 因此能够令模型快速收敛, 且对计算机资源需

求较少的优化算法才具有实用性。

选择网络训练策略时,有三点问题需要考虑:在太阳图像的观测中,大气抖动具有非稳态性,并且太阳图像包含高噪声;残差密集跳接网络中,残差密集块之间,密集块内的卷积层之间,均包含密集连接,训练过程中计算量巨大会使显存消耗急剧增加;为了获得具有良好泛化能力的模型,需要使用具有不同结构、不同特征的大量的太阳图像对网络进行训练。基于这三点考虑,选择 Adam 优化算法^[22]来训练网络。该算法的优点在于可以在训练过程中为不同的参数设计独立的自适应学习率,有利于网络的优化,适用于含大规模数据和参数的问题,且所需内存少、计算效率高。

与原残差稠密网络不同,本网络采用方均差作为损失函数。使用残差分析对重建误差进行定量评估,该损失函数通过最小化残差的平方和来优化网络,使得重建结果在残差分析中具有明显优势。损失函数为

$$l(\Theta) = \frac{1}{N} \sum_{k=1}^N \|F(I_{LR}^k, \Theta) - I_{HR}^k\|_2^2, \quad (9)$$

式中: $\{I_{LR}^k, I_{HR}^k\}$ 表示训练使用的数据样本对; Θ 表示网络中的参数; k 表示训练的迭代次数; N 表示迭代总次数。训练的目标就是使损失函数最小化。

实验基于 Ubuntu16.04 系统,使用 TITAN X 显卡、Intel(R) CPU e3-1245 v5,并使用 PyTorch 深度学习框架搭建深度神经网络架构。训练时,设置最小批次为 16;每次随机裁剪 32×32 大小的图像并作为输入;设置初始学习率为 0.0001,每训练 200 轮,学习率变为原来的 1/2。经过 1000 次迭代,大概耗时 2 d,训练基本达到收敛。

4 实验结果与分析

4.1 Binning 降采样之后再放大的结果分析

选取的测试数据是 NVST 在 2014-03-20T 03:54:10—2014-03-20T05:35:13 的 12010 号活动区 Ha 波段的 200 张观测数据经过斑点掩模法的重建结果数据。对每张图像进行裁剪,获得 200 张大小为 256×256 的原始太阳图像;对原始图像进行 2 倍和 4 倍的 Binning 降采样之后获得对应的低分辨率图像;再分别使用本方法与三种插值法,即双三次插值(BICUBIC)法^[23],双线性插值(LINEAR)法^[24]及最近邻插值(NEAREST)法^[25]将低分辨率图像放大 2 倍和 4 倍,获得对应的高分辨率图像,在获得的高分辨率结果中随机选取 20 组数据进行实验分析。

4.1.1 定性分析

在 20 组实验结果中随机选取一组,根据视觉效果对本方法与传统插值法的实验结果进行对比。图 4 为原始图像经过 Binning 降采样之后放大 2 倍和 4 倍的高分辨率图像以及对应的残差图。

从图 4 图像细节的放大结果可以看出,相对于三种插值法,在放大倍数相同的情况下,本方法放大的精细结构具有更清晰的视觉效果。从图 4 残差图中可以看出,本方法的残差图具有明显较弱的目标结构。因此从视觉效果方面可以证明,本方法对 NVST 高分辨率图像中太阳小尺度结构具有更好的精细放大效果。

4.1.2 定量分析

4.1.2.1 残差分析

针对定性分析时选取的实验结果,绘制对应的残差分布曲线图进行残差分析,如图 5 所示,以残差值为横坐标,以该残差值对应的像素在整体像素中所占的百分比值作为纵坐标。

从图 5 可以看出,在对 Binning 降采样之后的低分辨率图像进行相同倍数放大时,本方法的残差分布范围均小于其他三种插值法。因此可以证明经过本方法放大之后的图像与原始图像之间具有较小的误差。

残差的方均根(RMS)的表达式为

$$R_{MS} = \sqrt{(x_1^2 + x_2^2 + \dots + x_n^2)/n}, \quad (10)$$

式中: x_n 表示每个像素对应的残差值。由于残差的 RMS 值对残差的极大值和极小值极敏感,因此通过计算残差的 RMS 来准确地评估重建的高分辨率太阳图像与原始高分辨率太阳图像之间的误差。

图 6 为 20 组残差的 RMS 曲线,横坐标表示图像的个数,纵坐标表示该图像对应残差的 RMS。

从图 6 可知,本方法重建结果的残差 RMS 值均低于其他三种插值法,表明本文方法重建误差较小,在对 NVST 图像进行精细放大时具有明显的优势。

4.1.2.2 相关性分析

图 7 为相关性分析图,以原始高分辨率太阳图像 $I_{original}$ 的像素强度值为横坐标,以原始图像 Binning 降采样之后再放大的图像 I_{HR} 的像素强度值为纵坐标。散点分布所拟合的直线表达式为

$$I_{HR} = h \times I_{original}. \quad (11)$$

当 $h = 1$ 时, $I_{HR} = I_{original}$,表示重建的高分辨率太阳图像与原始图像对应像素强度相等,在图 7 中显示为散点在斜率为 1 的直线附近均匀紧密分布,




图 4 视觉效果图和残差图。(a) 2 倍放大;(b) 4 倍放大

Fig. 4 Visual effect images and residual images. (a) $2\times$ magnification; (b) $4\times$ magnification




图 5 残差分布。(a) 2 倍放大;(b) 4 倍放大

Fig. 5 Residual distribution. (a) $2\times$ magnification; (b) $4\times$ magnification

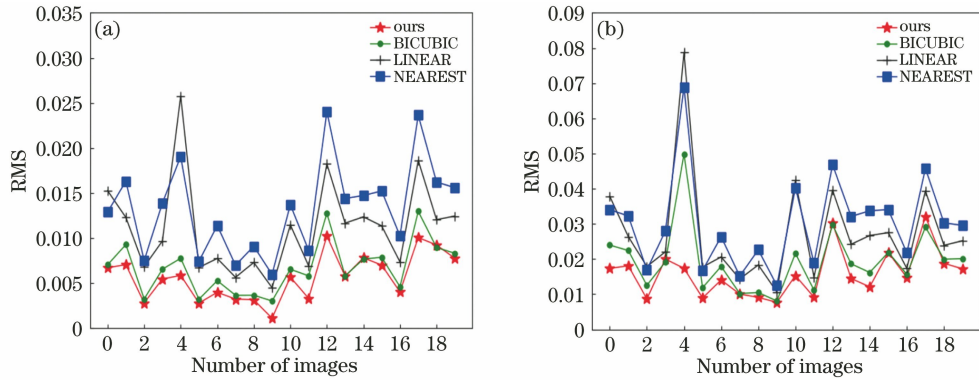


图 6 RMS 曲线。(a) 2 倍放大;(b) 4 倍放大

Fig. 6 Curves of RMS. (a) $2\times$ magnification; (b) $4\times$ magnification

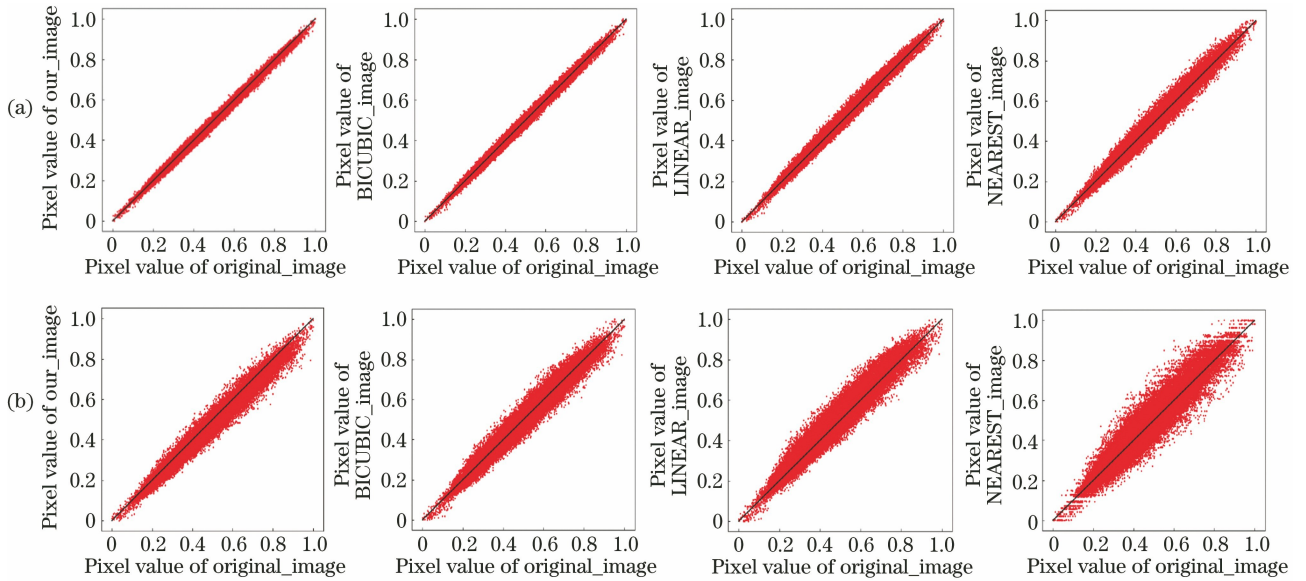


图 7 相关性图。(a) 2 倍放大;(b) 4 倍放大

Fig. 7 Correlation diagrams. (a) $2\times$ magnification; (b) $4\times$ magnification

且散点越靠近该直线,重建误差越小;当 $h \neq 1$ 时, $\mathbf{I}_{HR} = h\mathbf{I}_{original}$, 表示重建的高分辨率太阳图像与原始图像对应像素之间亮度的差值是原始灰度级的倍数,不存在较大的结构误差,只需要调整亮度即可。因此,在相关性图中根据散点分布所成直线的斜率和散点分布的紧密程度(所成直线的粗细)来评估重建误差。

从图 7 可以看出,在放大倍数相同时,相比其他三种插值法,本方法的散点在斜率为 1 的直线附近均匀分布,且分布更紧密。结果表明,用本方法放大之后的图像与原始图像具有更高的相关系数,即本方法重建出了更接近原始图像的精微结构。

4.1.2.3 PSNR/SSIM 分析

峰值信噪比(PSNR)可以作为放大的高分辨率图像中信号重建质量的评价标准,结构相似度(SSIM)可以衡量重建图像与目标图像之间的相似

度,因此使用这两个指标对实验结果进行评价。

从图 8 的 PSNR 曲线中可以看出,在放大倍数相同时,本方法的 PSNR 均高于其他三种插值法,即通过本文方法重建的高分辨率图像质量较高。从图 8 的 SSIM 曲线中也可以看出,在放大倍数相同时,本文方法的 SSIM 值均高于其他三种插值法。结果表明,本方法重建出了与原始图像最近似的高分辨率图像。

4.1.2.4 功率谱分析

使用 Binning 技术对图像进行降采样操作,虽然会降低图像的分辨率,但是同时会降低噪声,使得重建的图像具有更高的信噪比,因此根据功率谱(PSD)来分析本文方法与其他三种插值法的放大结果。将放大后经过归一化处理的高分辨率太阳图像对应的功率谱图像转换到极坐标,并对功率谱值进行对数化处理,得到功率谱图,如图 9 所示,以频率

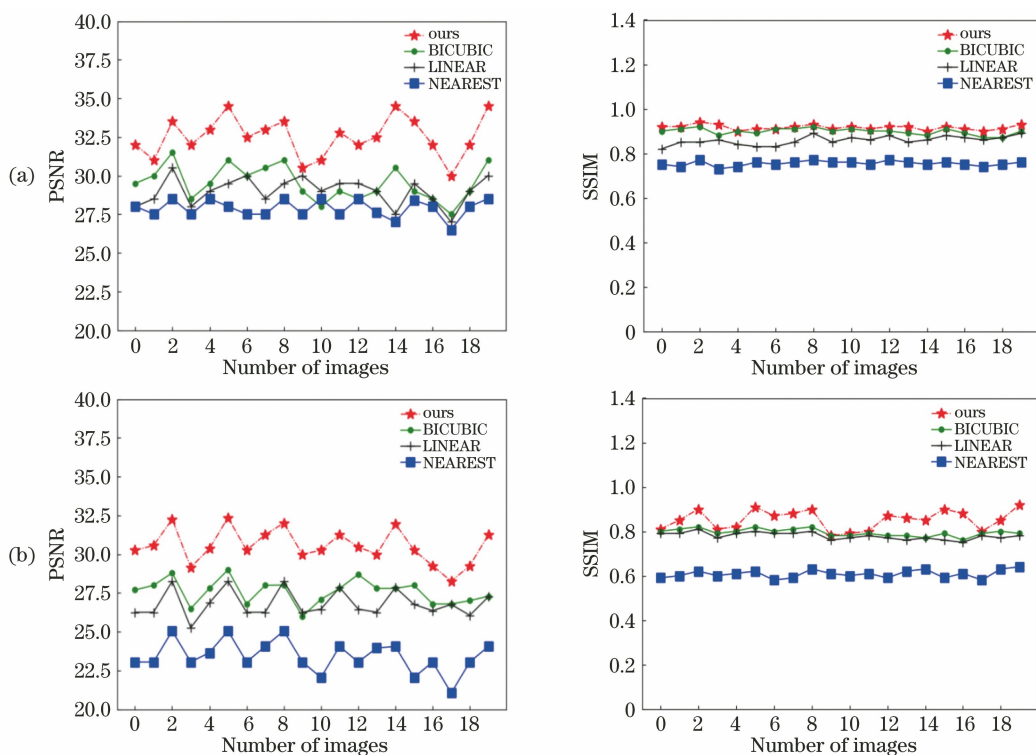


图 8 PSNR/SSIM 曲线。(a) 2 倍放大;(b) 4 倍放大

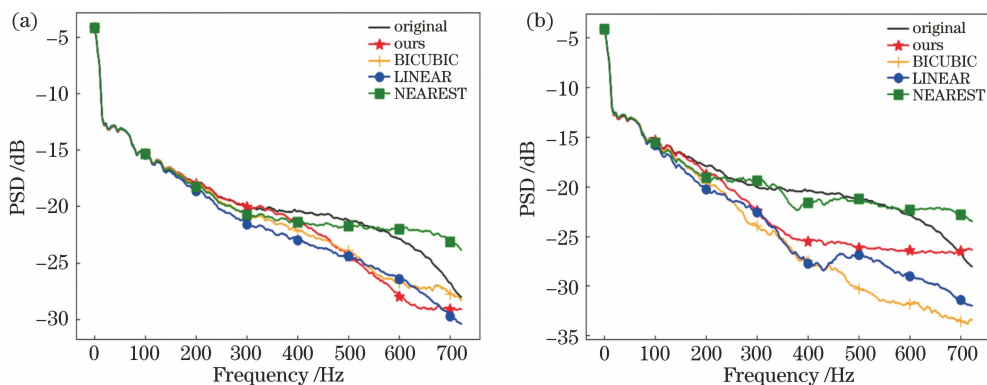
Fig. 8 Curves of PSNR/SSIM. (a) $2\times$ magnification; (b) $4\times$ magnification

图 9 功率谱。(a) 2 倍放大;(b) 4 倍放大

Fig. 9 Power spectra. (a) $2\times$ magnification; (b) $4\times$ magnification

为横坐标,以频率对应的功率谱值为纵坐标。

在功率谱中,由于所使用的数据是经过斑点掩模法重建之后的模拟数据,数据本身进行过降噪处理,因此原始数据的高频部分功率较小。从图 9 可以看出,本文方法在中低频部分功率与原始高分辨率图像保持一致,即本文方法很好地保留了原始图像的信息;而在高频部分,相比原始高分辨率图像中的功率,本文方法功率减小,有效地降低了噪声,而三种插值法虽然也可以抑制噪声,但是在中低频部分均丢失了图像信息。尤其 BICUBIC 法中目标像素的值与周围 16 个像素相关,影响范围较大,在插值过程中会平滑掉许多图像信息。实验结果表明,

本方法在保留原始图像细节信息的同时还能够提高图像的信噪比。

4.2 实际观测数据的放大结果分析

为了证明本方法同样适用于实际观测场景中,使用本方法与三种插值法对实际观测的微小结构进行放大。为了观察精细结构,在 NVST 实际观测的 2017-08-19T06:52:04 的 12671 号活动区的 TiO 波段数据中随机截取多张 32×32 的局部结构图,对该局部结构分别进行 2 倍和 4 倍的放大。在测试结果中随机选取一组结果,根据视觉效果对放大之后的局部进行对比,结果如图 10 所示。




图 10 实际观测结果放大后的视觉效果图。(a) 2 倍放大;(b) 4 倍放大

Fig. 10 Visual effect images of magnified actual observations. (a) $2\times$ magnification; (b) $4\times$ magnification

通过训练样本对来训练网络,网络能够学习到高分辨率图像与低分辨率图像之间复杂的非线性映射关系。使用实际观测数据直接放大图像,没有可参照的目标图像,但训练好的网络仍然能够重建出高分辨率的太阳图像,这是本文方法相对三种传统插值法的优势之一。根据图 10 实际观测的 NVST 高分辨率图像中太阳小尺度结构放大结果来看,本文方法能够对实际观测的高分辨率图像进行精细放大。相对传统插值法,本文方法重建出了更锐利的图像边缘和更丰富的图像细节信息。

5 结 论

为了克服传统插值法放大图像时出现的锯齿效应和失真现象,将基于深度学习的图像放大方法应用于天文领域,提出基于改进的残差密集连接网络的 NVST 高分辨率图像太阳小尺度结构的精细放大方法。经过 Binning 降采样,将大量 NVST 的 Ha 波段数据制作成训练样本库来训练深度神经网络,使用训练好的模型分别对 Binning 降采样之后的数据与实际观测数据进行不同倍数的放大。从视觉效果可以看出,相对三种传统插值法,使用本文方法放大的图像具有更精细的结构,残差分析可以证明,通过本文方法放大的图像与原始图像的残差图具有明显较弱的目标结构,残差图分布曲线也可以证明本方法的残差分布明显小于三种传统插值法,多组结果的残差 RMS 曲线更能进一步证明本文方法具有更小的重建误差;根据相关性分析结果可知,本方法放大的图像与原始图像之间具有较高的相关系数;功率谱分析结果表明,本方法能够保留更多的太阳

图像高频信息,除此之外,经过 Binning 降采样之后再重建的高分辨率图像具有更高的信噪比;根据多组 PSNR/SSIM 可知,在放大倍数相同的情况下,本方法两个指标均高于传统插值法。尽管多项指标均证明本文方法在 NVST 高分辨率图像微小结构的精细放大中具有明显优势,但仍然具有局限性。首先本方法的降噪效果只对欠采样之后的数据有效,其次在对太阳图像放大时,放大的图像中并不能出现原本图像中看不出来的结构。

参 考 文 献

- [1] Rao C H, Zhu L, Zhang L Q, et al. Development of solar adaptive optics [J]. Opto-Electronic Engineering, 2018, 45(3): 170733.
饶长辉,朱磊,张兰强,等. 太阳自适应光学技术进展[J]. 光电工程, 2018, 45(3): 170733.
- [2] Bao H, Rao C H, Tian Y, et al. Research progress on adaptive optical image post reconstruction [J]. Opto-Electronic Engineering, 2018, 45(3): 170730.
鲍华,饶长辉,田雨,等. 自适应光学图像事后重建技术研究进展[J]. 光电工程, 2018, 45(3): 170730.
- [3] Dong C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution [M]//Fleet D, Pajdla T, Schiele B, et al. Computer Vision-ECCV 2014. Cham: Springer, 2014: 184-199.
- [4] Dong C, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network [M]//Leibe B, Matas J, Sebe N, et al. Computer Vision-ECCV 2016. Cham: Springer, 2016: 391-407.
- [5] 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]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 26-July 1, 2016, Las Vegas, Nevada. New York: IEEE, 2016: 1874-1883.
- [6] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, Nevada. New York: IEEE, 2016: 1646-1654.
- [7] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, Nevada. New York: IEEE, 2016: 1637-1645.
- [8] Mao X J, Shen C H, Yang Y B. Image restoration using convolutional auto-encoders with symmetric skip connections [EB/OL]. (2016-08-30) [2019-12-10]. <https://arxiv.xilesou.top/abs/1606.08921>.
- [9] Tai Y, Yang J, Liu X M. Image super-resolution via deep recursive residual network [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE, 2017: 3147-3155.
- [10] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, Nevada. New York: IEEE, 2016: 770-778.
- [11] Zhang Y L, Tian Y P, Kong Y, et al. Residual dense network for image super-resolution [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 18-23, 2018, Salt Lake City, UT. New York: IEEE, 2018: 2472-2481.
- [12] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE, 2017: 4700-4708.
- [13] Tai Y, Yang J, Liu X M, et al. MemNet: a persistent memory network for image restoration [C]//The IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice. New York: IEEE, 2017: 4539-4547.
- [14] Zhang Y L, Tian Y P, Kong Y, et al. Residual dense network for image super-resolution [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 18-23, 2018, Salt Lake City, UT. New York: IEEE, 2018: 2472-2481.
- [15] Zhang Z F, Wang Z W, Lin Z, et al. Image super-resolution by neural texture transfer [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA. New York: IEEE, 2019: 7982-7991.
- [16] Hu X C, Mu H Y, Zhang X Y, et al. Meta-SR: a magnification-arbitrary network for super-resolution [C]//The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA. New York: IEEE, 2019: 1575-1584.
- [17] Li H, Zhang H, Guo X L, et al. Image restoration after pixel binning in image sensors [J]. *Tsinghua Science and Technology*, 2009, 14(4): 541-545.
- [18] Chen Y C, Liu G Q. The error analysis and correction of NVST's long-term tracking [J]. *Astronomical Research & Technology*, 2016, 13(2): 205-212.
陈宇超, 柳光乾. NVST 的长期跟踪误差分析及改正 [J]. *天文研究与技术*, 2016, 13(2): 205-212.
- [19] Wang L K, Xu Z, Jin Z Y, et al. The measurement and analysis of the wavelength shift of the FOV of narrow-band high-resolution imaging channel at NVST [J]. *Astronomical Research & Technology*, 2018, 15(4): 448-455.
王良凯, 徐稚, 金振宇, 等. NVST 高分辨窄带成像系统视场频漂的实测与分析 [J]. *天文研究与技术*, 2018, 15(4): 448-455.
- [20] Li Y Y, Chen Y C, Yang L, et al. A synchronized data acquisition system in the multi-channel observation system on the NVST of the YNAO [J]. *Astronomical Research & Technology*, 2015, 12(3): 323-330.
李玉艳, 陈宇超, 杨磊, 等. NVST 多通道成像观测系统的数据同步采集 [J]. *天文研究与技术*, 2015, 12(3): 323-330.
- [21] Zeiler M D, Taylor G W, Fergus R. Adaptive deconvolutional networks for mid and high level feature learning [C]//2011 International Conference on Computer Vision, November 6-13, 2011, Barcelona, Spain. New York: IEEE, 2011: 2018-2025.
- [22] Kingma D P, Ba J. Adam: a method for stochastic optimization [EB/OL]. (2017-01-30) [2019-12-10]. <https://arxiv.xilesou.top/abs/1412.6980>.
- [23] Zhou D W. An edge-directed bicubic interpolation algorithm [C]//2010 3rd International Congress on Image and Signal Processing, October 16-18, 2010, Yantai, China. New York: IEEE, 2010: 1186-1189.
- [24] Blu T, Thévenaz P, Unser M. Linear interpolation revitalized [J]. *IEEE Transactions on Image Processing*, 2004, 13(5): 710-719.
- [25] Jiang N, Wang L. Quantum image scaling using nearest neighbor interpolation [J]. *Quantum Information Processing*, 2015, 14(5): 1559-1571.