

基于 Boosting 回归的单帧图像超分辨率重建

罗爽¹, 黄辉^{2*}, 张凯兵¹

¹西安工程大学电子信息学院, 陕西 西安 710048;

²广西科技师范学院职业技术教育学院, 广西 来宾 546199

摘要 实例学习是一种有效的单帧图像超分辨率重建技术,关键在于如何建立低分辨率与高分辨率图像之间的映射关系。许多研究表明,当面对复杂多样的自然图像时,类型单一的回归模型难以重建出理想的高分辨率图像。为此,以 A+ 算法为基础,提出一种基于 Boosting 集成学习的超分辨率算法,通过不断增强回归模型的互补性,超分辨率重建模型能较好地适用于不同内容的图像。该算法首先利用 Boosting 思想训练多组具有互补性的子回归器;然后对各组子回归器进行组合,生成泛化能力更强、重建性能更好的集成模型;最后利用级联残差回归策略,采用由粗到精的方式逐渐合成高分辨率图像,以进一步提高超分辨率重建图像的质量。在 5 个标准数据集上对所提方法和 4 种基于实例学习的主流超分辨率方法进行了比较,结果表明,所提超分辨率重建方法能够重建出图像边缘更加清晰和纹理细节更加丰富的高质量图像。

关键词 图像处理; 图像超分辨率重建; A+ 算法; Boosting 集成学习; 级联残差回归

中图分类号 TN911.73

文献标志码 A

doi: 10.3788/LOP202259.0810018

Boosting Regression-Based Single-Image Super-Resolution Reconstruction

Luo Shuang¹, Huang Hui^{2*}, Zhang Kaibing¹

¹School of Electronics and Information, Xi'an Polytechnic University, Xi'an, Shaanxi 710048, China;

²School of Vocational and Technical Education, Guangxi Science & Technology Normal University, Laibin, Guangxi 546199, China

Abstract Example learning is an effective single-image super-resolution reconstruction technique. The key function of this technique is determining how to establish the mapping relationship between high- and low-resolution images. Especially, when dealing with complex and diverse natural images, several studies have shown that it is difficult to reconstruct ideal high-resolution images using a single regression model. Therefore, this study uses the A+ algorithm as a starting point and proposes a super-resolution algorithm based on the theory of Boosting ensemble learning that can adapt to various types of natural images by continuously enhancing the complementarity of the regression model. First, the Boosting scheme is used to train multiple sets of complementary subregressors. Then, all sets of subregressors are merged to generate an integrated model with stronger generalization ability and better reconstruction performance. Finally, a cascaded residual regression strategy and a coarse-to-fine technique are used to gradually synthesize high-resolution images to further improve the image quality. The proposed method was compared with four state-of-the-art examples of learning-based super-resolution methods using five standard datasets. The experimental results show that the proposed method can reconstruct high-quality images with clearer edges and richer texture details.

Key words image processing; image super-resolution reconstruction; A+ algorithm; Boosting ensemble learning; cascaded residual regression

收稿日期: 2021-01-07; 修回日期: 2021-02-27; 录用日期: 2021-05-13

基金项目: 国家自然科学基金(61971339, 61471161)、陕西省自然科学基金基础研究计划重点项目(2018JZ6002)、西安工程大学博士启动基金(BS1616)、西安工程大学研究生创新基金(chx2020015)

通信作者: huang760915hui@163.com

1 引言

在日常生活与实际应用中,人们对高分辨率图像的需求十分迫切。例如,在遥感成像、医疗成像、视频监控等应用场景中,高分辨率图像有助于工作人员获取更多的有用信息,从而做出更加科学合理的决策。因此,图像超分辨率重建作为一种有效提高图像分辨率的信号处理技术应运而生,该技术旨在以最低成本从一幅或多幅低分辨率图像中重建出高于成像系统物理分辨率的高质量图像。目前,主流的图像超分辨率技术可大致分为三类,即基于插值的方法^[1-2]、基于重构的方法^[3-4]和基于实例学习的方法^[5-6]。

虽然基于插值的方法原理简单、计算复杂度低,但该方法由于直接通过空间域中已知近邻像素的加权平均估计高分辨率网格中的未知像素,重建的图像边缘锯齿效应十分明显。而基于重构的方法尽管能有效保持光滑的图像边缘,但其本质是利用图像本身和先验信息进行图像上采样,因此在没有增量信息输入的情况下难以恢复丢失的纹理细节信息。

相比之下,基于实例学习的方法通过机器学习技术建立低-高分辨率图像之间的映射关系,能够有效估计出低分辨图像中丢失的高频细节,即使在放大倍数较大的情况下,仍然能够合成边缘清晰、纹理细节丰富的高质量图像。常用的基于实例学习的方法有邻域嵌入法^[7-8]、稀疏表示法^[9-10]和基于回归的方法^[11-12]等。其中,基于回归的方法是一种直接将低分辨率特征空间投影到高分辨率特征空间的超分辨率方法,该方法可进一步分为两个子类,即分段线性回归方法和基于深度学习的非线性回归方法。

分段线性回归是一种常用的超分辨率重建方法,该方法通过将低-高分辨率图像之间复杂的非线性回归问题转换为子空间内的线性回归问题,有效提高了算法效率和重建性能。最具代表性的方法为 Timofte 等^[13]提出的锚点邻域回归(ANR)算法。考虑到自然图像的结构复杂性,ANR 算法采用字典原子作为锚点,将整个特征空间上的非线性映射转换为局部子空间上的线性映射。随后, Timofte 等^[14]将锚点的邻域选择范围扩展到整个原始数据集,进一步将 ANR 算法改进为 A+ 算法。此外, Zhang 等^[15]利用 k-means 聚类算法将低分辨率特征空间划分为多个线性子集,提出了一种学习多线性映射函数的快速超分辨率重建方法。Hu 等^[16]将级联策略

引入到分段线性回归模型,以减小重建图像与真实图像之间的误差。Huang 等^[17]根据低分辨率图像块插值曲率的不同对图像块进行划分,进而在线性空间上建立多混合先验超分辨率模型(MMPM)。

随着卷积神经网络的发展,基于深度学习的超分辨率方法^[18-19]取得了一系列突破性研究成果。最近的研究中, Dong 等^[20]率先提出了超分辨率卷积神经网络(SRCNN)。Liu 等^[21]将传统稀疏编码与深度学习相结合,提出了一种基于稀疏编码的超分辨率网络。Kim 等^[22]通过增加卷积层数,进一步提高了重建图像质量。2017 年, Ledig 等^[23]提出的 SRGAN 模型首次突破了高倍超分辨率放大的瓶颈,同时构建了一种由 16 个残差块组成的深度残差网络 SRResNet。随后, Lim 等^[24]在 SRResNet 的基础上移除了残差结构中的批归一化(BN)层,从而在有限的计算资源下建立了一个性能更好的超分辨率模型。尽管基于深度学习的方法有助于获得良好的重建性能,然而该方法通常需要大量训练样本进行学习,对计算设备性能要求较高,因此不论在数据采集还是模型训练上都面临巨大挑战,无法在计算资源受限的环境下使用。

为克服上述难题,许多研究者以 ANR 或 A+ 为研究起点,尝试了一系列改进工作。例如 Jiang 等^[25]根据字典原子与输入低分辨率块之间相关性大小为输入的低分辨图像块分配不同权值,提出了一种局部正则锚点邻域回归算法。Wu 等^[26]以高分辨率块相似性为依据,对高分辨率块表示系数进行了适当调整。Zhang 等^[27]在 A+ 算法基础上提出学习循环残差回归器,以一种由粗到精的方式实现超分辨率重建,从而得到更接近原始图像的重建图像。然而,上述方法生成的回归模型类型较单一,当面对内容复杂多样的测试图像时难以重建出令人满意的高分辨率图像。为此,受 Boosting 集成学习思想和 Nejadi 等^[28]提出的增量字典学习方法的启发,本文以 A+ 算法为研究基础,提出了一种基于 Boosting 集成学习的超分辨率方法,即利用 Boosting 策略训练多组具有互补性的子回归器,通过不同子回归器之间的互补性增强超分辨率模型的整体泛化能力。

2 相关工作

2.1 过完备字典学习

稀疏表示理论认为,自然图像的局部结构特征

可以近似地表示为过完备字典中少数原子的稀疏线性组合。该理论被广泛应用于多种图像处理问题中,例如图像压缩^[28]、图像超分辨率重建^[29]、人脸识别^[30]等。其中,较经典的一种字典学习方法为 Aharon 等^[31]提出的 K-SVD 算法,其目标函数为

$$\begin{aligned} (\mathbf{D}, \mathbf{A}) = \arg \min_{\mathbf{D}, \mathbf{A}} \|\mathbf{Y} - \mathbf{D}\mathbf{A}\|_{\text{F}}^2 \\ \text{s.t. } \|\mathbf{a}_m\|_0 \leq s, \quad \forall m = 1, 2, \dots, M, \end{aligned} \quad (1)$$

式中: $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_M] \in \mathbf{R}^{n \times M}$ 表示由 M 个 n 维特征向量组成的数据集; $\mathbf{D} \in \mathbf{R}^{n \times K}$ 为包含 K 个原子的过完备字典; $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_M] \in \mathbf{R}^{K \times M}$ 为稀疏系数矩阵,且矩阵中每列向量不超过 s 个非零元素。(1)式的求解通过交替更新系数矩阵 \mathbf{A} 和字典 \mathbf{D} 实现,具体分为两步:第一步在字典固定的情况下,利用正交匹配追踪(OMP)算法^[32]完成稀疏编码;第二步在系数矩阵固定的情况下,通过对误差项进行奇异值分解(SVD)和最小化误差重构更新字典中的原子。

2.2 A+算法回顾

近来,由 Timofte 等^[14]提出的基于 A+ 的超分辨率算法因优越的重建性能而受到广泛关注。该算法通过学习分段线性映射函数实现低分辨率特征空间到高分辨率特征空间的转换。在算法训练阶段,每个字典原子被看作是低分辨率特征空间中的一个锚点,进而在每个锚点周围组成高-低分辨率邻域对,并在每个邻域对上建立与之对应的映射函数(回归器)。测试阶段,通过为每个低分辨率输入特征依次匹配一个最优回归器,最终实现低分辨率特征到高分辨率特征的快速变换。

设 $\mathbf{X}^{\text{H}} \in \mathbf{R}^{N_{\text{H}} \times M}$ 表示由 M 个 N_{H} 维高分辨率特征向量组成的训练数据集, $\mathbf{X}^{\text{L}} \in \mathbf{R}^{N_{\text{L}} \times M}$ 表示相应的低分辨率数据集。首先,利用 K-SVD 字典学习算法在低分辨率数据集上学习一个低分辨率字典 $\mathbf{D}^{\text{L}} = [\mathbf{d}_1^{\text{L}}, \mathbf{d}_2^{\text{L}}, \dots, \mathbf{d}_K^{\text{L}}] \in \mathbf{R}^{N_{\text{L}} \times K}$, 其中 K 表示 \mathbf{D}^{L} 中原子的个数;然后将各个原子 $\mathbf{d}_i^{\text{L}} (i = 1, 2, \dots, K)$ 分别作为锚点,在低分辨率数据集中寻找与 \mathbf{d}_i^{L} 相关性较高的 p 个特征向量,组成以 \mathbf{d}_i^{L} 为锚点的低分辨率邻域矩阵 $\mathbf{N}_i^{\text{L}} \in \mathbf{R}^{N_{\text{L}} \times p}$ 。设 $\mathbf{N}_i^{\text{H}} \in \mathbf{R}^{N_{\text{H}} \times p}$ 表示相应的高分辨率邻域矩阵,则该低分辨率邻域与高分辨率邻域之间的映射函数 \mathbf{F}_i 可由脊回归模型^[33]表示为

$$\min_{\mathbf{F}_i} \|\mathbf{N}_i^{\text{H}} - \mathbf{F}_i \mathbf{N}_i^{\text{L}}\|_{\text{F}}^2 + \lambda \|\mathbf{F}_i\|_{\text{F}}^2, \quad (2)$$

式中: $\lambda > 0$ 为平衡重构误差项与正则项之间关系的系数。 \mathbf{F}_i 的近似解表示为

$$\mathbf{F}_i = \mathbf{N}_i^{\text{H}} \left[(\mathbf{N}_i^{\text{L}})^{\text{T}} \mathbf{N}_i^{\text{L}} + \lambda \mathbf{I} \right]^{-1} (\mathbf{N}_i^{\text{L}})^{\text{T}}, \quad (3)$$

式中: \mathbf{I} 是一个 $p \times p$ 的单位矩阵。因此,对于一个给定的低分辨率输入特征向量 \mathbf{y} , 若 $\mathbf{d}_j^{\text{L}} (j = 1, 2, \dots, K)$ 表示与 \mathbf{y} 相似性最大的锚点, \mathbf{F}_j 表示与该锚点对应的回归器,则估计的高分辨率特征向量 $\hat{\mathbf{y}}$ 为

$$\hat{\mathbf{y}} = \mathbf{F}_j \mathbf{y}. \quad (4)$$

由于字典和相应的回归器均在训练阶段通过离线学习获得,故在测试阶段只需为每个低分辨率特征向量匹配一个最优回归器,即可实现快速高效的超分辨率重建。

3 所提方法内容

3.1 方法概述

为了获得泛化能力更强、重建性能更好的超分辨率模型,提出了一种基于 Boosting 回归器学习和级联残差回归的超分辨率方法,图 1 为所提方法的基本框架。所提方法分为训练阶段和测试阶段,其中训练阶段包含 4 个步骤。

1) 建立训练集:给定一组高分辨率图像,首先采用双立方插值算法将其下采样到某个确定的尺寸,作为与原始高分辨率图像对应的低分辨率图像,再对其进行相同倍数的上采样,将上采样得到的插值图像与原始高分辨率图像构成低-高分辨率图像训练集。

2) 特征表示:首先,将训练图像划分为固定大小的图像块;然后,从低分辨率图像块提取一阶和二阶梯度特征,组成低分辨率特征集;同时,将原始高分辨率图像块与低分辨率图像块之差作为将要进行估计的高频细节,得到相应的高分辨率特征集。

3) Boosting 模型训练:首先通过所提 Boosting 回归器学习算法得到一组具有互补性的子回归器 $\mathbf{F}_1, \dots, \mathbf{F}_T$;接着合并所有子回归器,得到性能优于单个子回归器的集成回归器 \mathbf{F}_r^* ;最后利用 \mathbf{F}_r^* 估计每一幅低分辨率训练图像对应的高分辨率图像。Boosting 回归器学习算法的详细步骤由 3.2 节给出。

4) 基于级联残差回归的模型优化:采用级联残差回归策略,将第 r 轮估计的高分辨率图像作为第

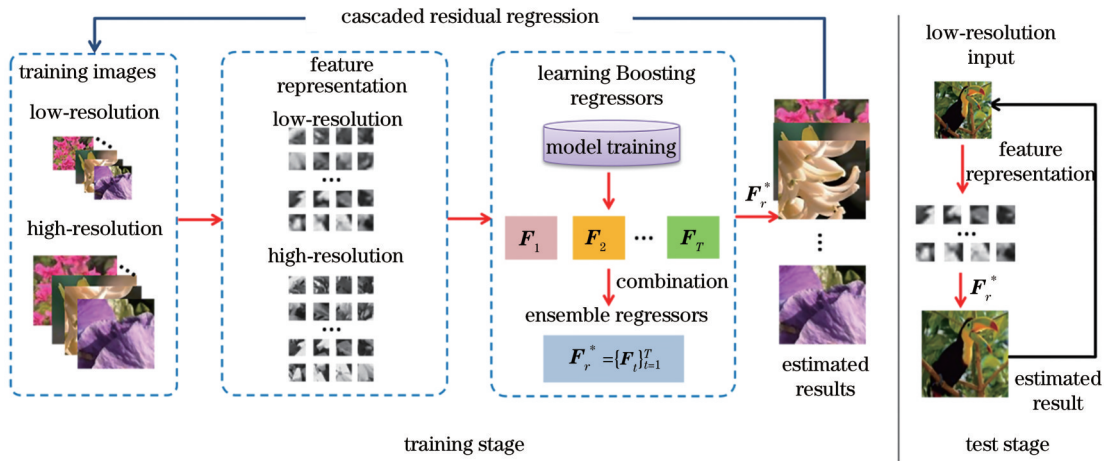


图 1 所提方法框图

Fig. 1 Framework of the proposed method

$r+1$ 轮的低分辨率输入图像,完成训练集的更新,随后再次利用 Boosting 回归器学习算法在新的训练集上建立第 $r+1$ 轮的集成回归器 F_{r+1}^* ,并由此建立多级回归模型 $\{F_r^*\}_{r=1}^R$ 以实现重建结果的优化,其中 r 表示级联次数。级联残差回归框架搭建方法由 3.3 节给出。

在测试阶段,利用训练得到的多级回归模型 $\{F_r^*\}_{r=1}^R$,以同样的级联方式对低分辨率测试图像进行超分辨率重建,即可获得最终的高分辨率估计结果。

3.2 Boosting 回归器学习

在 A+ 算法中, Timofte 等^[14] 通过学习低分辨率

特征空间上的过完备字典建立分段线性回归器。然而,由于单一字典对不同的数据集具有不同的表示能力,即该字典可能对某一类图像具有较强的表示能力,而不适用于其他类型的图像,因此限制了模型的灵活性和普适性。受 Boosting 集成学习思想和 Nejadi 等^[28] 提出的增量字典学习方法的启发,以 A+ 算法为基础,通过学习多个具有互补性的子字典建立多组子回归器,进而提高整个回归模型的泛化能力。图 2 为 Boosting 回归器学习算法的框架图,其中包括 T 层回归器训练,除第一层不包含字典优化和回归器优化外,其余每层均由 5 部分组成,依次为字典学习、回归器建立、样本划分、字典优化和回归器优化。

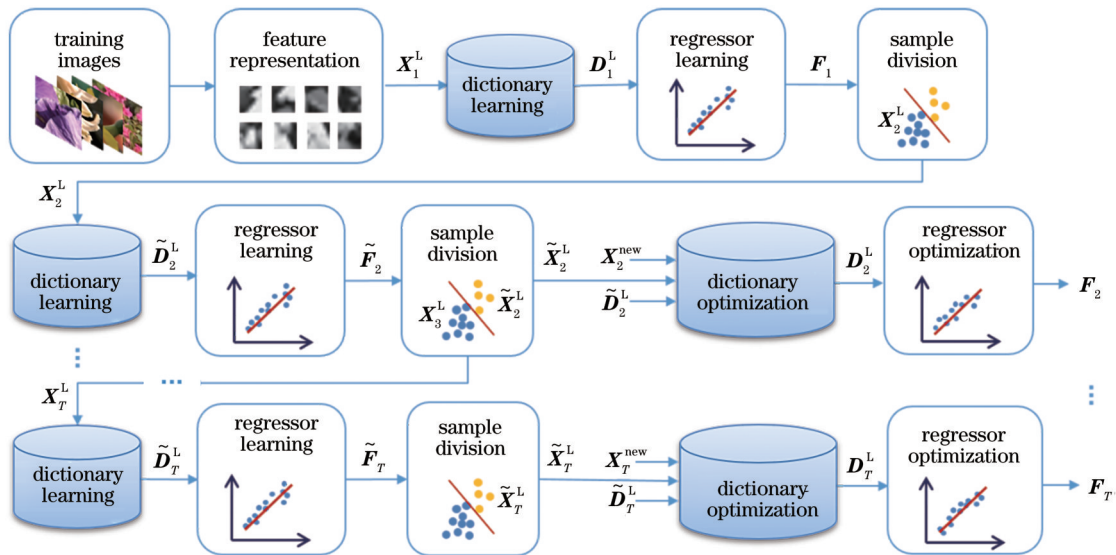


图 2 Boosting 回归器学习算法框图

Fig. 2 Block diagram of Boosting regressor learning algorithm

在第一层中,首先对训练集中的低分辨率图像进行双立方插值放大,并从插值图像提取一阶和二阶梯度特征,构成第一层的低分辨率特征集 $\mathbf{X}_1^L \in \mathbf{R}^{N_L \times M}$ 。同时,将原始高分辨率图像与低分辨率图像之差作为将要进行估计的高频细节,得到相应的高分辨率特征集 $\mathbf{X}_1^H \in \mathbf{R}^{N_H \times M}$ 。随后,利用 K-SVD 字典学习算法在低分辨率特征空间上学习一个子字典 \mathbf{D}_1^L ,计算公式为

$$\begin{aligned} \mathbf{D}_1^L = \arg \min_{\mathbf{D}_1^L, \mathbf{A}_1^L} & \|\mathbf{X}_1^L - \mathbf{D}_1^L \mathbf{A}_1^L\|_F^2 \\ \text{s. t. } & \|\mathbf{a}_{1,m}^L\|_0 \leq s, \forall m = 1, 2, \dots, M, \end{aligned} \quad (5)$$

式中: $\mathbf{X}_1^L = [\mathbf{x}_{1,1}^L, \mathbf{x}_{1,2}^L, \dots, \mathbf{x}_{1,M}^L]$ 为低分辨率特征集; \mathbf{A}_1^L 为 \mathbf{X}_1^L 的稀疏表示矩阵, $\mathbf{a}_{1,m}^L$ 为矩阵 \mathbf{A}_1^L 中的第 m 列向量。令 $\mathbf{d}_{1,i}^L (i = 1, 2, \dots, K)$ 表示字典 \mathbf{D}_1^L 中的第 i 个原子,则以 $\mathbf{d}_{1,i}^L$ 为锚点的 p 个最相关邻居可通过计算 \mathbf{X}_1^L 中各个特征向量与 $\mathbf{d}_{1,i}^L$ 的投影绝对值求出,即

$$\mathbf{b} = \left\{ \text{abs} \left[\left(\mathbf{d}_{1,i}^L \right)^T \mathbf{X}_1^L \right] \right\}, \quad (6)$$

式中: \mathbf{b} 是一个由原子 $\mathbf{d}_{1,i}^L$ 与 \mathbf{X}_1^L 中所有低分辨率特征向量的投影绝对值组成的向量。假设投影绝对值较大的 p 个低分辨率特征向量及其对应的高分辨率特征向量组成的邻域矩阵对记为 $\{\mathbf{N}_{1,i}^L, \mathbf{N}_{1,i}^H\}$, 则根据 A+ 算法可进一步求出该邻域对上的映射函数 $\mathbf{F}_{1,i}$, 计算公式为

$$\mathbf{F}_{1,i} = \mathbf{N}_{1,i}^H \left[\left(\mathbf{N}_{1,i}^L \right)^T \mathbf{N}_{1,i}^L + \lambda \mathbf{I} \right]^{-1} \left(\mathbf{N}_{1,i}^L \right)^T. \quad (7)$$

以 \mathbf{D}_1^L 中每个原子依次为锚点建立映射函数,最终可获得一组线性回归器 $\mathbf{F}_1 = \{\mathbf{F}_{1,i}\}_{i=1}^K$ 。然后,通过为每个低分辨率特征向量 $\mathbf{x}_{1,m}^L (m = 1, 2, \dots, M)$ 匹配一个最优回归器 $\mathbf{F}_{1,j}$, 可估计得到与 $\mathbf{x}_{1,m}^L$ 对应的高分辨率特征向量 $\hat{\mathbf{x}}_{1,m}$, 即

$$\hat{\mathbf{x}}_{1,m} = \mathbf{F}_{1,j} \mathbf{x}_{1,m}^L, \quad \forall m = 1, 2, \dots, M, \quad (8)$$

其中, j 值的表达式为

$$j = \arg \max_{i=1, \dots, K} \left\{ \text{abs} \left[\left(\mathbf{d}_{1,i}^L \right)^T \mathbf{x}_{1,m}^L \right] \right\}. \quad (9)$$

随后,根据特征集上全体样本的重构误差大小进行样本划分,具体步骤如下。

1) 计算每个样本的重构误差,得到重构误差向量 $\mathbf{e}_1 = [e_{1,1}, \dots, e_{1,M}]^T$, 表达式为

$$e_{1,m} = \|\mathbf{x}_{1,m}^H - \hat{\mathbf{x}}_{1,m}\|_2^2, \quad (10)$$

式中: $\mathbf{x}_{1,m}^H$ 表示与 $\hat{\mathbf{x}}_{1,m}$ 对应的原始高分辨率特征向量。

2) 对误差向量 \mathbf{e}_1 中的元素值进行排序,将其中最大的 $(M - M/T)$ 个误差值对应的低分辨率特征集表示为 $\mathbf{X}_2^L (T$ 为 Boosting 模型的层数), 并将其用于下一层字典学习,进而利用 (5) 式和 (7) 式学习得到字典 \mathbf{D}_2^L 和回归器 $\tilde{\mathbf{F}}_2$ 。

与第一层不同,在其余每层的样本划分阶段,除该层重构误差向量 $\mathbf{e}_t (t = 2, \dots, T)$ 中最大的 $(M - M/T)$ 个误差值对应的低分辨率特征集 \mathbf{X}_{t+1}^L 将用于下一层字典学习以外,其余低分辨率特征向量组成的子集(记作 $\tilde{\mathbf{X}}_t^L$)将进一步用于字典优化和回归器优化。优化阶段具体过程如图 3 所示,该阶段通过补充新训练样本和优化字典 $\tilde{\mathbf{D}}_t^L$ 实现回归器优化,从而建立针对某种特定类型图像具有较好重建性能的子回归器 \mathbf{F}_t 。如图 3 所示,首先从新的训练图像 $\mathbf{I}_t^{\text{new}}$ 中提取图像特征 $\mathbf{X}_t^{\text{new}} = [\mathbf{x}_{t,1}^{\text{new}}, \dots, \mathbf{x}_{t,N}^{\text{new}}]$, 然后利用回归器 $\tilde{\mathbf{F}}_t$ 估计高分辨率特征集,并计算新样本的重构误差向量 $\mathbf{e}_t^{\text{new}} = [e_{t,1}^{\text{new}}, \dots, e_{t,N}^{\text{new}}]^T$ 。设 $\tilde{\mathbf{e}}_t$ 表示 $\tilde{\mathbf{X}}_t^L$ 对应的误差向量,则根据 $\tilde{\mathbf{e}}_t$ 和新样本的重构误差,可将样本集 $\tilde{\mathbf{X}}_t^L$ 扩充为 $\mathbf{X}_t^{\text{ref}}$:

$$\mathbf{X}_t^{\text{ref}}: \tilde{\mathbf{X}}_t^L \cup \left\{ \mathbf{x}_{t,n}^{\text{new}}: \min(\tilde{\mathbf{e}}_t) \leq e_{t,n}^{\text{new}} \leq \max(\tilde{\mathbf{e}}_t) \right\}, \quad 1 \leq n \leq N, \quad (11)$$

式中: $\min(\cdot)$ 和 $\max(\cdot)$ 分别表示返回向量中的最小元素值和最大元素值。随后,将字典 $\tilde{\mathbf{D}}_t^L$ 作为初始字典,利用 K-SVD 算法在 $\mathbf{X}_t^{\text{ref}}$ 上学习得到优化后的字典 \mathbf{D}_t^L , 进而利用 A+ 算法建立相应的回归器 \mathbf{F}_t 。

当 T 层训练结束之后,对所有子回归器 $\mathbf{F}_1, \dots, \mathbf{F}_T$ 进行合并,得到最终的集成回归器 $\mathbf{F}_T^* = \{\mathbf{F}_t\}_{t=1}^T$ 。由于用作字典优化的样本的重构误差总是限定在某一较小阈值内,因此通过优化阶段可产生最适合该类样本的子字典和子回归器,且不同子回归器之间具有较强的互补性,从而使得集成回归器对不同内容和结构的图像具有较强的鲁棒性。

3.3 级联残差回归方法

为进一步减小超分辨率重建图像与原始高分辨率图像之间的差异,文献[16]和文献[27]采用级联策略逐渐为低分辨率图像补充新的高频细节,以获得更高质量的超分辨率重建结果。受级联思想的启发,将类似方法用于 Boosting 回归模型中,通过训练多级残差回归器逐渐提高重建图像质量。与上述方法相比,所提级联残差回归方法主要存在两方面不同:首先,采用 3.2 节介绍的 Boosting 回归模

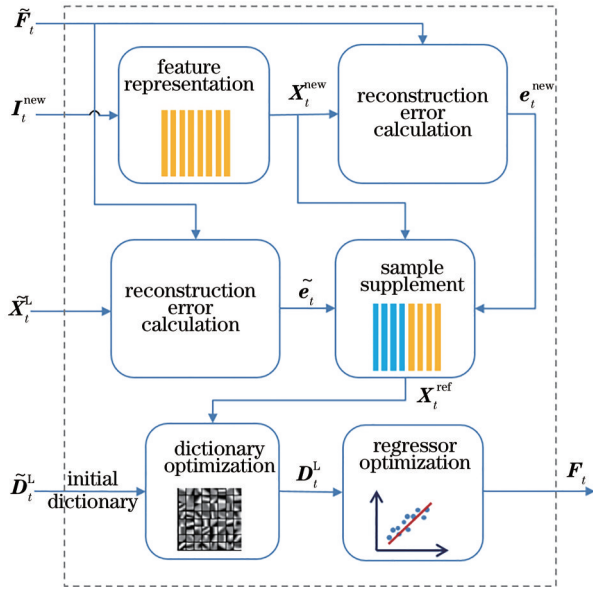


图3 优化阶段框图

Fig. 3 Block diagram of refinement stage

型作为级联的基础超分辨率模型；其次，在求残差过程中，估计的高分辨率图像块将被融合成一幅完整的图像，随后再划分成图像块用于残差计算，而非直接利用估计的图像块进行计算，因此更有助于保持图像的局部结构。与单次回归算法相比，级联残差回归方法以一种由粗到精的方式逐渐合成高分辨率图像，因而能够获得更接近真实图像的高分辨率估计结果。

级联残差回归过程包含4个基本步骤：1) 利用第 r 轮的 Boosting 集成回归器 F_r^* 合成高分辨率图像 \hat{I}_r ；2) 计算原始高分辨率图像与第 r 轮重建图像的残差 E_r ；3) 将 \hat{I}_r 用作第 $r+1$ 轮的低分辨率输入， E_r 用作相应的高分辨率输入，完成数据集的更新；4) 再次执行 Boosting 回归器学习算法，建立第 $r+1$ 轮的集成回归器 F_{r+1}^* 。上述步骤共循环执行 R 次，最终得到一组基于 Boosting 回归模型的残差回归器 $\{F_r^*\}_{r=1}^R$ 。由于每次循环相当于为低分辨率输入图像补充新的图像细节，因此最终获得的重建图像将更接近于原始高分辨率图像。

3.4 基于 Boosting 回归的超分辨率重建

通过 Boosting 回归器学习和级联残差回归策略，可得到一组基于 Boosting 回归模型的残差回归器 $\{F_r^*\}_{r=1}^R$ 。在测试阶段，残差回归器 $\{F_r^*\}_{r=1}^R$ 将用于超分辨率重建任务中。

对一幅给定的低分辨率输入图像 Y_1^L ，首先利用双立方插值算法对其进行上采样，使其与期望的高

分辨率图像大小保持一致；然后使用一阶和二阶梯度特征将插值图像块表示为向量形式，作为低分辨率特征集；随后利用多级残差回归器中的 F_1^* 估计相应的高分辨率特征向量，得到高分辨率图像 \hat{Y}_1 ；之后将图像 \hat{Y}_1 用作下一轮的低分辨率输入图像，并通过与训练阶段类似的级联残差回归策略，依次使用回归器 F_2^*, \dots, F_R^* 进行高分辨率特征估计，以获得边缘更清晰、纹理细节更丰富的高分辨率图像；最后将第 R 轮得到的高分辨率特征向量转换为图像块并添加到低分辨率图像的插值图像块上，经融合后输出最终的高分辨率图像 \hat{Y}_R 。

4 实验结果与分析

4.1 数据集与参数设置

在训练阶段，采用与 A+ 算法中相同的 69 幅训练图像训练字典 D_1^L ，并在每层优化阶段依次新增 50 幅彩色图像用于样本扩充，每层新增的 50 幅图像为从公开数据集 BSDS300 中随机选取的图像。由于人类视觉系统对图像亮度通道的敏感程度高于色度通道，因此将彩色图像从 RGB 颜色空间转换到 YCbCr 颜色空间，且只在亮度通道图像上进行超分辨率重建，对于色度通道 (Cb 和 Cr) 图像则直接采用双立方插值算法进行放大。

在测试阶段，分别在 Set5、Set10、Set14、B100、Urban100 五个标准数据集和一个实测数据集上进行实验。五个标准数据集所包含的图像数量分别为 5、10、14、100、100，其中包括人物、动植物、建筑物等多种图像内容，实测数据集由 5 幅手机实拍的低分辨率图像组成。

实验中，超分辨率放大倍数分别设置为 2 和 3。对于 2 倍放大的情况，输入图像块大小设置为 6×6 ，相邻图像块之间重叠区域大小设置为 4×4 ；对于 3 倍放大的情况，输入图像块大小设置为 9×9 ，图像块重叠区域设置为 6×6 。表 1 和表 2 中，子字典大小 K 分别设置为 512 和 1024，其余实验中子字典大小 K 均设置为 512，推荐 Boosting 层数 T 和级联残差回归次数 R 分别为 2 和 3。每个字典原子的最相关近邻数 p 设置为 2048。所有实验均在 Intel Core i5-486 7400 3.00 GHz PC 上进行，并在 Matlab R2018a 编程环境中实现。

4.2 实验评价指标

超分辨图像质量评价方法分为主观质量评价和客观质量评价。主观质量评价是通过人眼观察，

表 1 不同超分辨率方法在 2 倍放大时的平均 PSNR 和 SSIM 值

Table 1 Average PSNR and SSIM values of different methods for $\times 2$ magnification

Dataset	Evaluation index	A+	SRCNN	Zhang's	MMPM	Ours ($K=512$)	Ours ($K=1024$)
Set5	PSNR	36.41	36.35	36.19	36.80	36.77	36.81
	SSIM	0.951	0.952	0.950	0.956	0.955	0.955
Set10	PSNR	33.00	32.94	32.76	33.43	33.50	33.56
	SSIM	0.927	0.927	0.925	0.933	0.933	0.934
Set14	PSNR	32.22	32.23	32.07	32.43	32.50	32.53
	SSIM	0.902	0.904	0.899	0.907	0.907	0.907
B100	PSNR	31.09	31.13	30.94	31.35	31.35	31.38
	SSIM	0.881	0.884	0.877	0.889	0.889	0.889
Urban100	PSNR	28.98	29.07	28.97	29.51	29.64	29.69
	SSIM	0.886	0.889	0.886	0.898	0.900	0.900

表 2 不同超分辨率方法在 3 倍放大时的平均 PSNR 和 SSIM 值

Table 2 Average PSNR and SSIM values of different methods for $\times 3$ magnification

Dataset	Evaluation index	A+	SRCNN	Zhang's	MMPM	Ours ($K=512$)	Ours ($K=1024$)
Set5	PSNR	32.46	32.41	32.56	32.66	32.76	32.78
	SSIM	0.905	0.904	0.907	0.910	0.911	0.911
Set10	PSNR	29.04	29.07	29.11	29.25	29.40	29.48
	SSIM	0.845	0.843	0.848	0.852	0.855	0.856
Set14	PSNR	29.09	29.02	29.10	29.19	29.22	29.25
	SSIM	0.816	0.814	0.816	0.821	0.819	0.820
B100	PSNR	28.16	28.19	28.22	28.33	28.35	28.38
	SSIM	0.775	0.779	0.779	0.786	0.785	0.785
Urban100	PSNR	25.93	25.85	26.02	26.10	26.25	26.28
	SSIM	0.792	0.787	0.794	0.798	0.804	0.806

从而对重建图像质量的好坏做出的人为评价。相对而言,主观质量评价更加侧重于人类视觉系统对图像的理解和评价。然而,由于不同观测者的主观性偏差,在对图像质量进行评价时往往还需要采取一种或多种客观质量评价方法,以消除人的主观因素引起的不确定性。常用的客观质量评价指标有峰值信噪比(PSNR)和结构相似性(SSIM)等。

其中,PSNR通过比较估计图像和原始图像之间的均方误差来衡量估计图像的失真程度,单位为dB,PSNR越大表示图像失真越小,图像质量越高。PSNR的计算公式为

$$R_{\text{PSN}} = 10 \log_{10} \left(\frac{P^2}{E_{\text{MS}}} \right), \quad (12)$$

式中: E_{MS} 为估计图像与原始高分辨率图像之间的均方误差; P 表示图像量化灰度等级,根据图像中像素可变区间的最大值, P 取1或255。

SSIM通过对比图像的亮度和信息来衡量两幅图像的相似程度。SSIM越大表示两幅图像相似性越高,最大值为1。设 \mathbf{X} 和 \mathbf{Y} 分别表示原始图像和估计图像,则SSIM定义为

$$S_{\text{SIM}}(\mathbf{X}, \mathbf{Y}) = \frac{(2\mu_X\mu_Y + c_1)(2\sigma_{\text{XY}} + c_2)}{(\mu_X^2 + \mu_Y^2 + c_1)(\sigma_X^2 + \sigma_Y^2 + c_2)}, \quad (13)$$

式中: μ_X 和 μ_Y 分别为 \mathbf{X} 和 \mathbf{Y} 的平均值; σ_X 和 σ_Y 分别为 \mathbf{X} 和 \mathbf{Y} 的方差; σ_{XY} 为 \mathbf{X} 与 \mathbf{Y} 的协方差;参数 c_1 、 c_2 为常数,用于防止分母为0。

4.3 实验结果

为验证所提方法的有效性和性能优势,以PSNR和SSIM作为客观质量评价指标,并与其他4种基于实例学习的主流超分辨率算法进行比较,包括Timofte等^[14]改进的锚点邻域回归算法(A+方法);Dong等^[20]提出的基于卷积神经网络的超分辨率方法(SRCNN方法);Zhang等^[27]通过学习循环残

差回归器改进的 A+ 算法 (Zhang's 方法); Huang 等^[17]提出的基于多混合先验的超分辨率模型 (MMPM 方法)。所有对比方法均由作者提供的公开代码在推荐参数配置下实现。

表 1 和表 2 分别为不同超分辨率方法在 2 倍和 3 倍放大时的平均 PSNR 和 SSIM 值,加粗字体表示最优重建结果。由表中数据可知,所提方法在 5 个标准数据集上均表现出较好的重建性能。对于 3 倍放大的情况,当所提方法的子字典大小 K 为 512 时,相比于 A+ 方法,平均 PSNR 值可提高 0.13 dB~0.36 dB,平均 SSIM 值可提高 0.006~0.012;相比于 SRCNN 方法,平均 PSNR 值可提高 0.19 dB~0.4 dB,平均 SSIM 值可提高 0.005~0.017;相比于 Zhang's 方法,平均 PSNR 值可提高 0.12 dB~0.29 dB,平均 SSIM 值可提高 0.003~0.01。且除了在 Set14 和 B100 两个数据集上的 SSIM 指标略低于 MMPM 方法外,所提方法的其余评价指标均为最优。此外,从表 1 和表 2 中可以看出,当子字典大小 K 为 1024 时,实验结果可进一步得到提升。

为了全面评价不同超分辨率模型的重建性能,图 4 给出了 3 倍放大时 5 种算法在 Set5 数据集上的平均 CPU 运行时间与 PSNR 值的对比图,图中纵轴表示 Set5 中 5 幅图像的平均 PSNR 值,横轴为重建每幅图像所需的平均 CPU 运行时间。由图 4 显示的结果可以看出,在合成超分辨率图像时,所提方

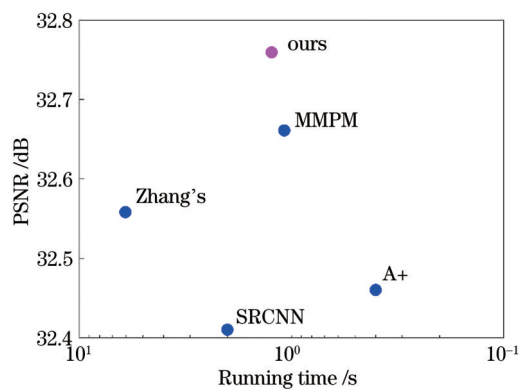


图 4 3 倍放大时不同超分辨率方法在数据集 Set5 上的性能对比

Fig. 4 Performance comparison of different super-resolution methods on Set5 dataset for $\times 3$ magnification

法能够以较快运行速度得到优于其他超分辨率方法的重建结果。特别地,与最具竞争性的 MMPM 方法相比,所提方法在相近的运行时间内取得了远远高于 MMPM 方法的客观质量评价分数。

为了从视觉质量上对比不同超分辨率方法的重建性能,图 5 和图 6 分别展示了 Set10 数据集中“Flower”图像和 Urban100 数据集中“Img092”图像在 3 倍放大时的超分辨率重建结果。从图 5 可以看出:尽管 SRCNN 方法和 MMPM 方法能清晰地保留图像中显著的枝干边缘,但在叶片区域仍存在明显的锯齿效应;而 A+ 方法和 Zhang's 方法虽在一定程



图 5 数据集 Set10 中“Flower”3 倍放大的超分辨率结果。(a) 原图; (b) A+ 方法; (c) SRCNN 方法; (d) Zhang's 方法; (e) MMPM 方法; (f) 所提方法

Fig. 5 Super-resolution results of “Flower” in Set10 dataset for $\times 3$ magnification. (a) Original image; (b) A+ method; (c) SRCNN method; (d) Zhang's method; (e) MMPM method; (f) Ours




图6 数据集 Urban100 中“Img092”3倍放大的超分辨率结果。(a)原图;(b) A+方法;(c) SRCNN方法;(d) Zhang’s方法;(e) MMPM方法;(f)所提方法

Fig. 6 Super-resolution results of “Img092” in Urban100 dataset for $\times 3$ magnification. (a) Original image; (b) A+ method; (c) SRCNN method; (d) Zhang’s method; (e) MMPM method; (f) Ours

度上抑制了叶片边缘的锯齿现象,但难以保持清晰的枝干;相比之下,所提方法在叶片和枝干两个局部视觉放大区域内均能够产生较清晰的轮廓和较高的视觉质量,这是由于基于 Boosting 回归的超分辨率重建算法能够逐渐增强子回归器之间的互补性,从而使得集成模型能够更好地适应不同图像中复杂的图像局部结构。从图6可以看出:SRCNN方法易产生边缘振铃效应,大大影响了重建图像质量;尽管 A+方法和 Zhang’s方法重建的图像中无明显锯齿状边缘,但重建图像较为模糊;MMPM方法进一步抑制了锯齿现象,但在右下角的局部视觉放大区域内出现了明显的伪像和失真;所提方法更有利于保持清晰的图像边缘和较为丰富的纹理细节。此外,为了进一步评估所提方法的应用参考价值,图7给出了不同方法对5幅手机实拍低分辨率图像进行3倍放大的超分辨率重建结果,经对比,能够得到与上述结果类似的结论。

4.4 参数分析

为了验证不同参数对实验结果的影响,对 Boosting 层数 T 、级联残差回归次数 R 和子字典大小 K 进行分析,以进一步验证所提方法对提高超分辨率重建性能的有效性。

1) Boosting 层数 T 对重建结果的影响。图8和图9中的实线分别给出了数据集 B100 和数据集 Set10 中所有图像的平均 PSNR 值随参数 T 变化的情况。由图8和图9可以看出,当 T 从1变化到3时,两个数据集的平均 PSNR 值均有所提升,尤其当 T 从1变化到2时提升较为明显。考虑到当子字典大小 K 设置为 512 时, T 从1变化到5的过程中,模型

中的回归器总数依次从 512 递增到 2560,因此为了公平验证 Boosting 回归策略的有效性,图8和图9中的虚线给出了不采用 Boosting 回归策略(即 T 始终为 1),而直接将模型中回归器的总数依次设置为 512, 1024, 1536, 2048, 2560 时的平均 PSNR 值。结果表明,在回归器总数相同的情况下,通过 Boosting 回归策略分层训练得到的子回归器之间具有较强的互补性,因此模型整体泛化能力也得到增强。而当 T 超过 3 时,由于出现过拟合现象,数据集 Set10 中重建图像质量有所下降。综上考虑,推荐 T 为 2。

2) 级联残差回归次数 R 对重建结果的影响。为验证级联残差回归模型的有效性,表3列出了5个标准数据集在使用不同级联次数 R 时的性能评价结果,鉴于当 $R=1$ 时未进行任何参数更新,故相当于级联未生效的情况。对比表3中的数据可知,随着 R 增加,所有数据集上的平均 PSNR 和 SSIM 值均有所提升,但提升幅度逐渐减小。由于级联残差回归能够逐渐为重建图像补充新的高频细节,因此能够有效减小超分辨率重建图像与原始高分率图像之间的差异。考虑到 R 的大小与算法时间复杂度呈正相关,为保持算法重建性能和重建时间复杂度之间的平衡,推荐 R 为 3。

3) 子字典大小 K 对重建结果的影响。字典大小即字典中原子的个数对所提方法的重建结果有非常重要的影响。为验证该影响,实验采用数据集 Set5 作为测试集,在其他参数均为推荐取值的情况下分别对子字典大小为 64, 128, 256, 512, 1024, 2048 时的重建结果进行了比较。重建图像的平均 PSNR 和 SSIM 值随子字典大小的变化情况如图 10



图 7 实测数据集中 3 倍放大的超分辨率结果。(a) A+ 方法; (b) SRCNN 方法; (c) Zhang's 方法; (d) MMPM 方法; (e) 所提方法
 Fig. 7 Super-resolution results on real-world dataset for $\times 3$ magnification. (a) A+ method; (b) SRCNN method; (c) Zhang's method; (d) MMPM method; (e) Ours

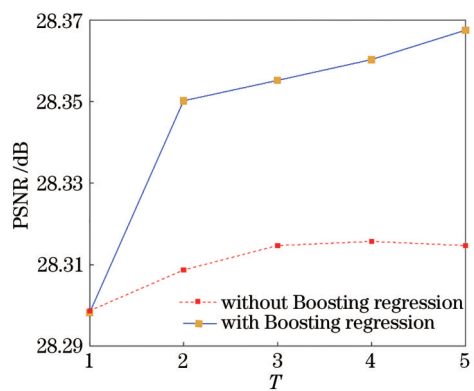


图 8 参数 T 对数据集 B100 平均 PSNR 值的影响
 Fig. 8 Influence of parameter T on the average PSNR in B100 dataset




图 9 参数 T 对数据集 Set10 平均 PSNR 值的影响
 Fig. 9 Influence of parameter T on the average PSNR in Set10 dataset

表 3 五个标准数据集在使用不同级联次数时的性能评价

Table 3 Performance evaluation on five benchmarks by using different cascaded times

R	Set5		Set10		Set14		B100		Urban100	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
1	32.610	0.9081	29.197	0.8508	29.133	0.8178	28.284	0.7826	25.998	0.7956
2	32.745	0.9103	29.368	0.8544	29.217	0.8193	28.349	0.7843	26.199	0.8018
3	32.759	0.9107	29.403	0.8552	29.219	0.8194	28.350	0.7845	26.258	0.8039




图 10 子字典大小对数据集 Set5 重建结果的影响。(a)平均 PSNR 值随子字典大小变化情况；
(b)平均 SSIM 值随子字典大小变化情况

Fig. 10 Influence of sub-dictionary size on the reconstruction results in Set5 dataset. (a) Average PSNR value varying with sub-dictionary size; (b) average SSIM value varying with sub-dictionary size

所示。由图 10 可知,字典大小与超分辨重建性能基本呈正相关。其原因在于,字典越大,包含的有用信息越多,重建结果越理想,而当字典大小增加到一定程度时,能提供的信息趋于饱和,因此重建性能的提升逐渐变缓。经综合考虑,采用的子字典大小为 512。

5 结 论

利用 Boosting 集成学习思想和级联残差回归策略,提出了一种新的基于实例学习的超分辨率重建方法。一方面,通过学习多层 Boosting 回归器逐渐增强子回归器之间的互补性,有利于提升超分辨率回归模型的整体泛化能力;另一方面,采用级联残差回归策略由粗到精地合成高分辨率图像,有利于进一步提高超分辨率重建图像的质量。实验结果表明,所提方法在客观评价指标和主观视觉质量上均优于其他 4 种对比方法。尽管提出的超分辨率方法能获得较好的重建性能,但仍存在两方面不足。首先,由经典 K-SVD 算法得到的字典原子并不正交,易造成信息冗余;其次,级联策略的使用在一定程度上增加了算法时间复杂度,不利于实时应用。因此,如何改进字典学习算法和提高算法效率是下一阶段需要进一步深入研究的问题。

参 考 文 献

- [1] Zhang L, Wu X L. An edge-guided image interpolation algorithm via directional filtering and data fusion[J]. IEEE Transactions on Image Processing, 2006, 15(8): 2226-2238.
- [2] Ye W, Ma K K. Convolutional edge diffusion for fast contrast-guided image interpolation[J]. IEEE Signal Processing Letters, 2016, 23(9): 1260-1264.
- [3] Ren C, He X H, Teng Q Z, et al. Single image super-resolution using local geometric duality and non-local similarity[J]. IEEE Transactions on Image Processing, 2016, 25(5): 2168-2186.
- [4] Chen H G, He X H, Qing L B, et al. Single image super-resolution via adaptive transform-based nonlocal self-similarity modeling and learning-based gradient regularization[J]. IEEE Transactions on Multimedia, 2017, 19(8): 1702-1717.
- [5] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations[M]//Boissonnat J D, Chenin P, Cohen A, et al. Curves and surfaces 2010. Lecture notes in computer science. Heidelberg: Springer, 2012, 6920: 711-730.
- [6] Li B, Ma L. Super-resolution reconstruction of densely connected generative adversarial network

- images[J]. *Laser & Optoelectronics Progress*, 2020, 57(22): 221011.
- 李斌, 马璐. 密集连接的生成对抗网络图像超分辨率重建[J]. *激光与光电子学进展*, 2020, 57(22): 221011.
- [7] Gao X B, Zhang K B, Tao D C, et al. Image super-resolution with sparse neighbor embedding[J]. *IEEE Transactions on Image Processing*, 2012, 21(7): 3194-3205.
- [8] Yang S Y, Wang Z Y, Zhang L, et al. Dual-geometric neighbor embedding for image super resolution with sparse tensor[J]. *IEEE Transactions on Image Processing*, 2014, 23(7): 2793-2803.
- [9] Yang J C, Wright J, Huang T S, et al. Image super-resolution via sparse representation[J]. *IEEE Transactions on Image Processing*, 2010, 19(11): 2861-2873.
- [10] Wang S L, Zhang L, Liang Y, et al. Semi-coupled dictionary learning with applications to image super-resolution and photo-sketch synthesis[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition, June 16-21, 2012, Providence, RI, USA. New York: IEEE Press, 2012: 2216-2223.
- [11] Chen X Y, Zhang W J, Sun W Z, et al. Super-resolution reconstruction of images based on multi-scale and multi-residual network[J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 181009.
- 陈星宇, 张伟劲, 孙伟智, 等. 基于多尺度与多重残差网络的图像超分辨率重建[J]. *激光与光电子学进展*, 2020, 57(18): 181009.
- [12] Wu L, Lü G Q, Xue Z T, et al. Super-resolution reconstruction of images based on multi-scale recursive network[J]. *Acta Optica Sinica*, 2019, 39(6): 0610001.
- 吴磊, 吕国强, 薛治天, 等. 基于多尺度递归网络的图像超分辨率重建[J]. *光学学报*, 2019, 39(6): 0610001.
- [13] Timofte R, de Smet V, van Gool L. Anchored neighborhood regression for fast example-based super-resolution[C]//2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE Press, 2013: 1920-1927.
- [14] Timofte R, de Smet V, van Gool L. A+: adjusted anchored neighborhood regression for fast super-resolution[M]//Cremers D, Reid I, Saito H, et al. *Computer vision-ACCV 2014. Lecture notes in computer science*. Cham: Springer, 2015, 9006: 111-126.
- [15] Zhang K B, Tao D C, Gao X B, et al. Learning multiple linear mappings for efficient single image super-resolution[J]. *IEEE Transactions on Image Processing*, 2015, 24(3): 846-861.
- [16] Hu Y T, Wang N N, Tao D C, et al. SERF: a simple, effective, robust, and fast image super-resolver from cascaded linear regression[J]. *IEEE Transactions on Image Processing*, 2016, 25(9): 4091-4102.
- [17] Huang Y F, Li J, Gao X B, et al. Single image super-resolution via multiple mixture prior models[J]. *IEEE Transactions on Image Processing*, 2018, 27(12): 5904-5917.
- [18] Chen Z H, Wu H B, Pei H D, et al. Image super-resolution reconstruction method based on self-attention deep network[J]. *Laser & Optoelectronics Progress*, 2021, 58(4): 0410013.
- 陈子涵, 吴浩博, 裴浩东, 等. 基于自注意力深度网络的图像超分辨率重建方法[J]. *激光与光电子学进展*, 2021, 58(4): 0410013.
- [19] Qu H C, Tang B W, Yuan G S. Improved super-resolution image reconstruction algorithm[J]. *Laser & Optoelectronics Progress*, 2021, 58(2): 0210018.
- 曲海成, 唐博文, 袁贵森. 改进的超分辨率图像重建算法[J]. *激光与光电子学进展*, 2021, 58(2): 0210018.
- [20] 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.
- [21] Liu D, Wang Z W, Wen B H, et al. Robust single image super-resolution via deep networks with sparse prior[J]. *IEEE Transactions on Image Processing*, 2016, 25(7): 3194-3207.
- [22] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1646-1654.
- [23] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [24] 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), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1132-1140.
- [25] Jiang J J, Ma X, Chen C, et al. Single image super-resolution via locally regularized anchored neighborhood regression and nonlocal means[J]. *IEEE Transactions on Multimedia*, 2017, 19(1): 15-26.
- [26] Wu H P, Zhang J, Wei Z H. High resolution similarity directed adjusted anchored neighborhood regression for single image super-resolution[J]. *IEEE Access*, 2018, 6: 25240-25247.
- [27] Zhang K B, Wang Z, Li J, et al. Learning recurrent residual regressors for single image super-resolution [J]. *Signal Processing*, 2019, 154: 324-337.
- [28] Nejati M, Samavi S, Karimi N, et al. Boosted dictionary learning for image compression[J]. *IEEE Transactions on Image Processing*, 2016, 25(10): 4900-4915.
- [29] Cheng D Q, Yu W J, Guo X, et al. Super-resolution reconstruction algorithm based on adaptive image online dictionary learning[J]. *Laser & Optoelectronics Progress*, 2020, 57(6): 061505.
- 程德强, 于文洁, 郭昕, 等. 自适应的图像在线字典学习超分辨率重建算法[J]. *激光与光电子学进展*, 2020, 57(6): 061505.
- [30] Zhang G Q, Porikli F, Sun H J, et al. Cost-sensitive joint feature and dictionary learning for face recognition[J]. *Neurocomputing*, 2020, 391: 177-188.
- [31] Aharon M, Elad M, Bruckstein A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
- [32] Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. *IEEE Transactions on Information Theory*, 2007, 53(12): 4655-4666.
- [33] Golub G H, Hansen P C, O'Leary D P. Tikhonov regularization and total least squares[J]. *SIAM Journal on Matrix Analysis and Applications*, 1999, 21(1): 185-194.