

文章编号: 2095-4980(2020)04-0665-08

基于随机森林的红外图像超分辨率算法

王成凯, 杨晓敏, 严斌宇*

(四川大学 电子信息学院, 四川 成都 610065)

摘要: 为提高低分辨率红外图像的分辨率, 提出了一种红外图像超分辨率算法。该算法训练 2 个随机森林模型: 红外图像训练第 1 个模型、配准的多传感器图像训练第 2 个模型。采用自适应边缘提取算法提取红外图像与可见光图像的边缘, 计算输入的低分辨率红外图像块与对应的高分辨率可见光图像块之间的相关系数。根据相关性选择合适的重建模型, 用选择的模型重建高分辨率红外图像块, 并整合为高分辨率红外图像。实验结果表明, 与超分辨率随机森林算法相比, 算法重建的高分辨率红外图像具有更高的客观指标, 峰值信噪比(PSNR)平均提升了 0.09 dB, 并且获得更为清晰的主观视觉效果, 更接近原始图像。

关键词: 红外图像; 超分辨率; 随机森林; 多传感器; 相关性

中图分类号: TN912; TP391.4

文献标志码: A

doi: 10.11805/TKYDA2019139

Infrared image super-resolution algorithm based on random forest

WANG Chengkai, YANG Xiaomin, YAN Binyu*

(School of Electronic and Information, Sichuan University, Chengdu Sichuan 610065, China)

Abstract: In order to improve the resolution of low-resolution infrared images, this paper proposes an infrared image super-resolution algorithm based on random forest. Firstly, two random forests models are trained independently. The first model is trained by using infrared images, while the second is trained by using registered multi-sensor images. Then, an adaptive extraction algorithm is utilized to extract the edges of infrared images and registered visible light images. The correlation coefficient between the low-resolution patch of infrared image and the high-resolution patch of visible light image is calculated. According to the correlation coefficient, an appropriate model can be selected. Finally, the selected model is utilized to reconstruct the high-resolution infrared patch. All these patches are integrated into a high-resolution infrared image. The experimental results show that the proposed method can obtain better performance compared with the super-resolution random forest algorithm. The Peak Signal to Noise Ratio(PSNR) of testing images is increased by 0.09 dB on average. The reconstructed images, with better visual effect, are closer to original images.

Keywords: infrared image; super-resolution; random forest; multi-sensor; correlation

红外图像可以反映场景的辐射特性, 在医疗诊断、远程监控、卫星图像等领域被普遍应用。与低分辨率图像相比, 高分辨率图像包含更多的高频细节, 可以提供更多信息。由于成像装置的限制, 实际获得的红外图像的分辨率普遍较低。为了提高红外图像的空间分辨率, 最直接的方法是使用更高分辨率的成像传感器。但是升级硬件不仅耗时而且非常昂贵, 特别是在医学成像和卫星图像等领域。因此实际中很少采用这种解决方案。数字图像处理领域中的超分辨率技术致力于恢复低分辨率图像丢失的高频信息, 可以有效地解决该问题。超分辨率是从一幅或多幅低分辨率图像恢复出对应的高分辨率图像的技术^[1]。近年来, 超分辨率技术已经在医学成像等领域获得广泛应用。现有的图像的超分辨率(Super Resolution, SR)算法大致可以分为 3 类: 插值的算法^[2-3]、重建算法^[4-6]、学习的算法^[7-9]。插值算法主要有: 线性插值、Bicubic 插值和 Lanczo 插值等, 利用图像相邻像素的像素值之间

收稿日期: 2019-04-26; 修回日期: 2019-06-08

基金项目: 四川省科技厅重点研发资助项目(2018GZ0178)

作者简介: 王成凯(1995-), 男, 在读硕士研究生, 主要研究方向为图像处理、机器学习。email:chengkaiyin@foxmail.com

通信作者: 严斌宇 email:yby@scu.edu.cn

的相关性来预测子像素。这些算法虽然简单快速,但是由于过度平滑,在重建过程中会丢失边缘、纹理等高频信息。重建算法利用多幅同一场景具有轻微位移的低分辨率图像重建高分辨力图像。这些算法可以获得相对较好的性能,但是仍然存在过度平滑的问题。学习算法,主要有 Yang 等算法^[10]、Zeyde 等算法^[11]。这些算法将训练图像分割为有重叠的图像块,将低分辨率图像块与高分辨力图像块之间存在的共性关系作为先验信息进行学习。使用学习得到的模型可以较好地预测丢失的高频信息。

针对可见光图像,现有算法已经可以获得较好的重建效果。但是对于红外图像,重建效果仍然不能令人满意。而且,关于红外图像超分辨率的研究较少,关于多传感器的红外图像超分辨率的研究更少^[12]。首先,现有算法仅使用红外图像组成的训练集学习先验信息,但是由于红外图像的热成像原理,天然缺失部分高频信息;其次,由于成像装置的限制,实际中很难获得大量包含丰富细节的红外图像。

由于使用不同传感器获取的图像天然地提供了同一场景的补偿信息,因此,结合红外图像和可见光图像的先验信息提升红外图像的超分辨率性能在理论上是可行的。本文提出了基于随机森林的红外图像超分辨率算法,使用配准的多传感器图像训练两个随机森林模型,并根据相关性自适应地选择更准确的模型,因此充分利用了多传感器图像提供的补偿信息。实验结果表明,本文提出的基于随机森林的红外图像超分辨率算法可以获得较好的重建效果。

1 基本理论

1.1 超分辨率随机森林算法

超分辨率的任务是根据给定的低分辨率图像重建其对应的高分辨率图像,使重建的图像尽可能接近真实的高分辨率图像。根据文献[10]中的假设,超分辨率问题可描述为:

$$Y = SDX + N \quad (1)$$

式中: S 是用于模糊 X 的滤波器; D 是降低 X 分辨率的下采样算子; N 是用于向 X 添加随机加性噪声的扰动算子。

近年来,基于稀疏表示理论的字典学习方法受到广泛关注。这些方法必须通过稀疏编码构建成对的过完备字典,这是一个很耗时的过程。Schulter 等于 2015 CVPR 会议上提出一种通过局部线性回归直接学习低分辨率域到高分辨力域映射关系的新算法,即超分辨率随机森林算法(Supre-Resolution Forests, SRF)^[13]。根据文献[13]中的假设,超分辨率问题可重新描述为:

$$\hat{x}_H = W(x_L)x_L \quad (2)$$

式中: x_L 是低分辨率输入; $W(x_L)$ 是回归函数。问题转化为尽可能准确地确定依赖于训练样本的回归函数 $W(x_L)$, 而非构建成对过完备字典。该算法使用随机森林算法学习回归函数。随机森林是一种有监督学习算法,是多棵决策树的集成。在训练阶段,随机森林算法使用训练样本独立地训练多棵决策树。

训练一棵决策树的算法流程如下:

a) 使用 bootstrap 算法对训练样本进行随机采样。这一过程有效地增加了训练集的多样性。针对每一棵决策树,使用尽可能不同的训练集。

b) 在每个节点上,使用分割函数递归地将训练样本分到不同的子节点。分割函数如式(3):

$$\sigma(x_L, \theta) = \begin{cases} 0, & r_\theta(x_L) < 0 \\ 1, & r_\theta(x_L) \geq 0 \end{cases} \quad (3)$$

式中: $r_\theta(x_L)$ 是决定如何分割训练样本的响应函数。通常有 2 种选择,如式(4)~式(5)所示:

$$r_\theta(x_L) = x_L[\theta_1] - \theta_{th} \quad (4)$$

$$r_\theta(x_L) = x_L[\theta_1] - x_L[\theta_2] - \theta_{th} \quad (5)$$

式中: $[]$ 算子为从向量 x_L 中选择一维, θ_1 和 θ_2 为从 x_L 中选择的 2 个维度; θ_{th} 为阈值,是一个自适应参数。

c) 确定参数 θ_{th} 的最优值。为了保证节点上样本的纯度,需要找到最优的 θ 值。随机采样一系列的值 θ_k , 根据损失函数找到其中最优的值 θ^* 。对于每个 θ_k 确定的分割函数,其损失为:

$$Q(\sigma, \theta, x_H, x_L) = \sum_{c \in \{L, R\}} |X^c| \cdot E(X_H^c, X_L^c) \quad (6)$$

式中: L 和 R 分别为左右子节点; $| \cdot |$ 算子统计落到每个子节点上的样本数; $X_{\{H,L\}}^{Lc} = \{x_{\{H,L\}} : \sigma(x_L, \theta) = 0\}$ 和 $X_{\{H,L\}}^{Rc} = \{x_{\{H,L\}} : \sigma(x_L, \theta) = 1\}$ 分别为落到左右子节点上的样本集合。 $E(X_H, X_L)$ 通过式(7)计算:

$$E(X_H, X_L) = \frac{1}{|X|} \sum_{n=1}^{|X|} (\|x_H^n - m(x_L^n)\|^2 + k \cdot \|x_L^n - \bar{x}_L\|^2) \quad (7)$$

式中： $m(x_L^n)$ 是样本 x_L^n 的重建版本； \bar{x}_L 是 x_L^n 的均值； k 是一个超参数。

d) 生成叶节点上的回归模型。当决策树生长到最大深度 ζ_{\max} ，样本不再分割，当前节点确定为叶节点。在每一个叶节点上，根据样本学习到一个回归模型，如式(8)：

$$m_t(x_L) = \sum_{j=0}^J W_j^t \phi_j(x_L) \quad (8)$$

为求得所有的 W_j^t ，需要解决一个最小二乘问题，其闭式解为：

$$W^T = (\Phi(X_L)^T \Phi(X_L) + \lambda I)^{-1} \Phi(X_L)^T X_H \quad (9)$$

式中： $\Phi(\cdot)$ 为基函数，通常使用线性函数 $\phi_j(x) = x$ ； $\{X_L, X_H\}$ 为落到叶节点上的训练样本集合； λ 为正则化参数。

至此，一棵决策树训练完成。按照上述流程，独立训练多棵决策树，集成为一个随机森林模型进行超分辨力重建。在重建阶段，将一个低分辨力输入 x_L 送入模型，将所有决策树的算术均值作为高分辨力输出 \hat{x}_H 。重建过程用式(10)表示：

$$\hat{x}_H = m(x_L)x_L = \frac{1}{T} \sum_{t=1}^T m_{l(t)}(x_L) \quad (10)$$

式中 $l(t)$ 表示第 t 棵树上的叶节点。

1.2 自适应边缘提取算法

上节提到，超分辨力的主要任务是恢复低分辨力图像缺失的高频信息。图像的高频信息主要体现在边缘和纹理区域。因此，经常需要提取图像的边缘区域以便进行超分辨力处理^[12]。但是提取边缘容易受到噪声以及光照的影响。本文算法中，采用一种自适应的边缘提取算法提取红外图像和可见光图像的边缘图。该算法可以有效地克服噪声以及光照不均对边缘提取的影响。提取边缘的过程见式(11)：

$$G(x, y) = \max\{grad_k(x, y)\}, \quad k \in \{1, 2, 3, 4\} \quad (11)$$

式中

$$grad_k(x, y) = \frac{1}{16} \sum_{i=1}^5 \sum_{j=1}^5 I(x-3+i, y-3+j) \times g_k(i, j) \quad (12)$$

式中 $g_k(i, j), k \in \{1, 2, 3, 4\}$ 是 4 个从不同的方向自适应提取边缘的高通滤波器，如图 1 所示。

为说明该自适应边缘提取算法的优越性，将提取的边缘图与 Laplacian 算子、Sobel 算子提取的边缘图进行比较，结果如图 2 所示。从图 2 可以看出，使用 Laplacian 算子提取的边缘受噪声影响较大，而使用 Sobel 算子提取的边缘对光照敏感。本文中使用的自适应边缘提取算法很好地提取了建筑物的边缘，受噪声的影响较小，很好地克服了光照不均的影响。

1.3 相关系数

在本文算法中，需要找到红外图像与配准的可见光图像之间的高相关性区域。由于现有的学习算法针对图像块进行研究，将像素之间的相关性转化为计算红外图像块与可见光图像块之间的相关系数。红外图像与配准的可见光图像的相关性主要体现在边缘及纹理区域，通过计算红外图像与可见光图像的边缘图的图像块来表征像素之间的相关性。

理论上，皮尔逊相关系数可以反映 2 个向量之间线性相关的强弱程度，其值介于 0 与 1 之间，其中 0 表示 2 个向量完全无关，1 表示 2 个向量完全相关。本文算法使用皮尔逊相关系数表征红外图像与可见光图像之间的相关系数。数值越大，说明红外边缘图像块与对应的可见光边缘图像块的相关性越高。为计算相关系数，将红外边缘图像块与可见光图像边缘块按行重构为列向量，分别表示为 C_{IR} 和 C_{VI} 。计算皮尔逊相关系数见式(13)：

$$S = \frac{\overline{C_{IR} \cdot C_{VI}} - \overline{C_{IR}} \cdot \overline{C_{VI}}}{\sqrt{(\overline{C_{IR}^2} - \overline{C_{IR}}^2) \cdot (\overline{C_{VI}^2} - \overline{C_{VI}}^2)}} \quad (13)$$




Fig.1 Four adaptive edge extraction high-pass filters
图 1 4 个自适应提取边缘的高通滤波器

式中： S 为红外边缘图像块和可见光边缘图像块的相关系数； $\overline{C_{IR}}$ 和 $\overline{C_{VI}}$ 分别为红外边缘图像块和可见光边缘图像块的均值；算子 \square 为 2 个向量逐元素相乘。

2 基于随机森林的红外图像超分辨率算法

2.1 使用异构训练集训练两个随机森林模型

上节提到，基于学习的超分辨率算法针对图像块进行研究。通常的做法是，首先将一幅训练图像按照固定大小以及固定步长分割为带有重叠部分的图像块；然后，为获取边缘及纹理等高频信息，使用不同的滤波器提取特征；最后将提取到的特征作为训练样本训练模型。分割图像块和提取特征的过程可表示为：

$$P^i = Patch^i(Y) \tag{14}$$

$$y^i = F(P^i) \tag{15}$$

式中： Y 是训练图像； P^i 是使用分割算子 $Patch(\cdot)$ 提取的第 i 个图像块； y^i 是使用滤波器 $F(\cdot)$ 得到的特征，即训练样本。

由于配准的异构图像本质上提供了同一场景的互补信息。结合红外图像和可见光图像的先验信息提高红外图像重建性能的假设是合理的。在本文算法中，需要分别训练 2 个不同的随机森林模型。第 1 个模型仅使用包含红外图像的训练集训练，而第 2 个模型使用包含已配准的异构图像的训练集联合训练。为获取包含异构先验信息的训练样本，需要先对训练图像进行预处理。

给定一个包含已配准的红外图像和可见光图像的高分辨率数据集。为获得对应的低分辨率图像，超分辨率算法通常的做法是，先使用 Bicubic 插值算法对高分辨率图像下采样，再上采样到原始分辨率。由于 Bicubic 插值算法会丢失大量高频信息，可将结果作为低分辨率图像。使用式(14)分割图像块，得到的图像块集合为 $P = \{P_{LRIR}, P_{HRIR}, P_{HRVI}\}$ ， P_{LRIR} 表示低分辨率红外图像块， P_{HRIR} 表示高分辨率红外图像块， P_{HRVI} 表示高分辨率可见光图像块；使用式(15)从图像块集合中提取特征，得到的特征集合为 $F = \{F_{LRIR}, F_{HRIR}, F_{HRVI}\}$ ， F_{LRIR} 表示低分辨率红外特征， F_{HRIR} 表示高分辨率红外特征， F_{HRVI} 表示高分辨率可见光特征。由于 F_{HRVI} 可能包含对应的 F_{LRIR} 缺失的高频信息，使用 F_{HRVI} 作为辅助信息建立决策树叶节点上的回归模型，可以更加准确地预测高分辨率输出。为了整合来自红外图像和可见光图像的先验信息，拼接 F_{HRVI} 与 F_{LRIR} 作为低分辨率训练样本，使用 F_{HRIR} 作为高分辨率训练样本。获得先验信息的过程如图 3 所示。

在本文算法中，使用异构训练集分别构建两个不同的随机森林模型进行超分辨率重建。第一个模型使用包含红外先验信息的训练样本集合 $Set1 = \{F_{LRIR}, F_{HRIR}\}$ ，与传统算法的训练方法一致，称为单源模型。而第二个模型使用包含多传感器先验信息的训练样本集合 $Set2 = \{F_{HRVI} + F_{LRIR}, F_{HRIR}\}$ 训练，称为多传感器模型。训练随机森林模型的流程如图 4 所示。

2.2 结合自适应边缘提取算法计算相似性并选择重建模型

给出用于测试的已配准的多传感器图像，重建高分辨率红外图像的过程分为 2 个步骤：

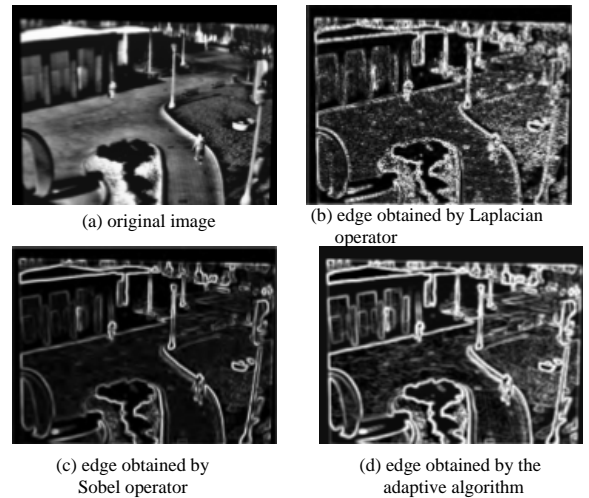


Fig.2 Comparison of edges obtained by different filters
图 2 不同算子提取的边缘图比较

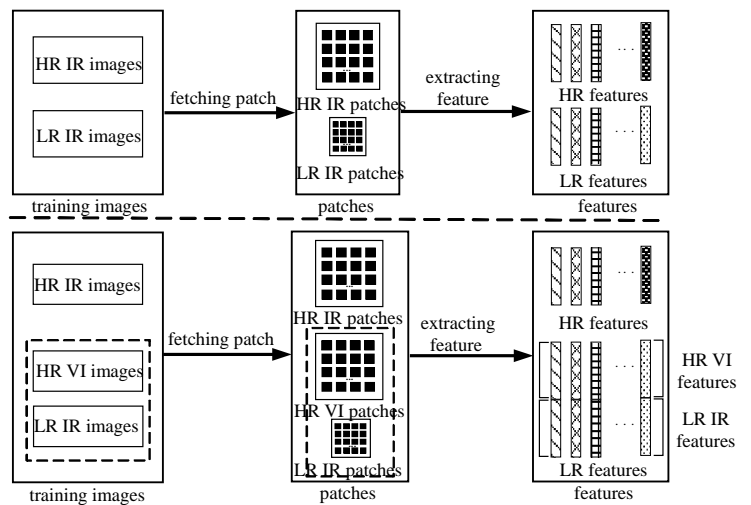


Fig.3 Illustration of obtaining the training samples
图 3 获得训练样本流程图

第 1 步 使用 Bicubic 插值算法对高分辨力红外图像下采样，再上采样到原始分辨率，结果作为低分辨率红外图像。与训练阶段的预处理过程一致，将测试图像分割为图像块，并从图像块中提取特征。然后将特征作为输入分别送入 2.1 节中构建的 2 个随机森林模型中，经过多元回归，得到 2 个重建的高分辨率红外图像块集合，分别表示为 $P_1=(P_1^1, P_1^2, \dots, P_1^l)$ 和 $P_2=(P_2^1, P_2^2, \dots, P_2^l)$ 。集合 P_1 使用多传感器模型重建，而集合 P_2 使用单源模型重建。

上节提到，由于成像装置的限制以及热成像原理，实际获取的红外图像通常缺少高频信息，而缺失的高频信息可能存在于配准的高分辨率可见光图像中。在红外图像中，并非所有的区域都与对应的可见光图像区域高度相关。如果在相关性不高的红外图像区域，融合对应可见光图像区域的信息，反而会对重建结果产生负面影响。本文算法只对相关性高的红外图像区域添加对应可见光图像区域的补偿信息。

第 2 步 使用 1.2 节中提到的自适应边缘提取算法提取低分辨率红外图像和高分辨力可见光图像的边缘图。为了尽可能多地保留来自多传感器图像的信息，将从边缘图中提取的图像块作为特征，分别表示为集合 $f_{IR}=(f_{IR}^1, f_{IR}^2, \dots, f_{IR}^l)$ 和集合 $f_{VI}=(f_{VI}^1, f_{VI}^2, \dots, f_{VI}^l)$ ，所有特征都以列向量的形式表示。集合 f_{IR} 中的特征有序地拼接为一个整合特征 F_{IR} ，同理得到另一个整合特征 F_{VI} 。计算 F_{IR} 和 F_{VI} 的皮尔逊相关系数作为相关性阈值 S ，表示红外图像与可见光图像之间的全局相关性。使用这种方法，针对不同的测试图像，可以自适应地选择阈值。计算输入的红外特征 f_{IR}^i 与对应的可见光特征 f_{VI}^i 之间的相关系数 S_i 。比较 S_i 与 S ，如果 $S_i > S$ ，则认为相应的红外图像块 P_i^l 为高相关性区域。对这类红外图像块，使用多传感器模型重建的 P_i^l 图像块作为高分辨力输出。反之，使用单源模型重建的 P_i^l 图像块作为高分辨力输出。重建高分辨力红外图像的流程如图 5 所示。

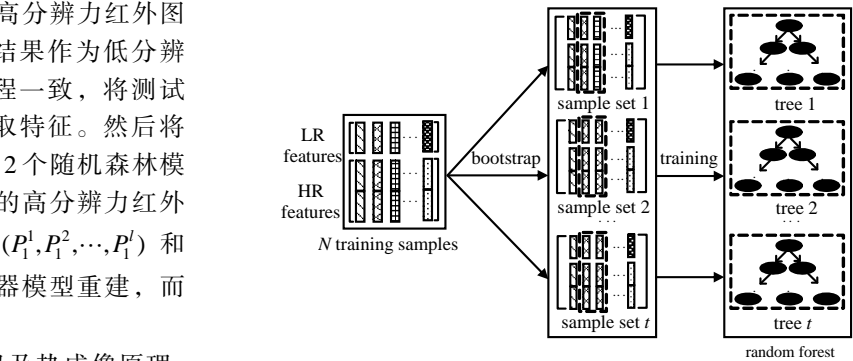


Fig.4 Process of training a random forest
图 4 训练随机森林模型的流程示意图

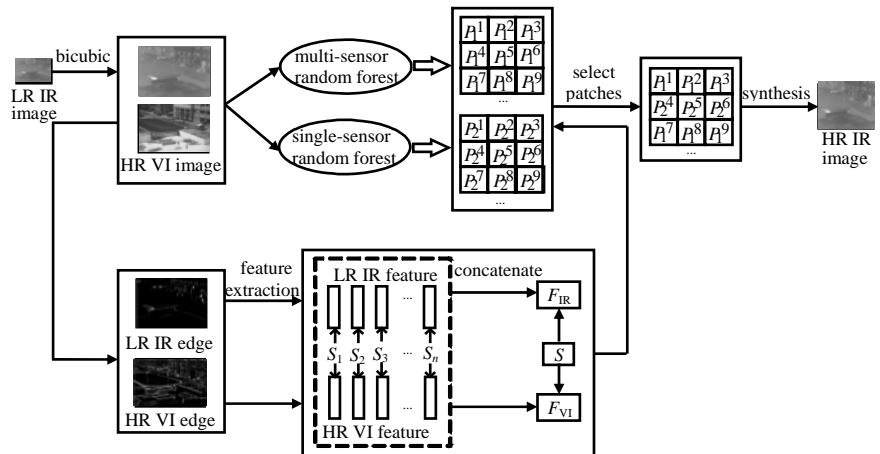


Fig.5 Process of reconstruction
图 5 重建流程示意图

2.3 相关算法研究

论述 2 种典型的提升红外图像超分辨率性能的算法，并与本文算法做方法和思路上的对比。文献[14]中，为提高红外图像的分辨率，作者提出 1 种基于多元回归模型的多传感器红外图像超分辨率算法。该算法改进了传统的基于稀疏表示的字典学习算法。在训练阶段，与本文算法的预处理方法一致，拼接 F_{HRVI} 与 F_{LRIR} 作为低分辨率训练样本，使用 F_{HRRR} 作为高分辨力训练样本，再使用 k -means 聚类算法将训练样本分成多个簇，同一簇中的训练样本具有相似的模式。然后针对每一个簇，训练成对的过完备字典，得到多对具有不同模式的字典。在重建阶段，每一个输入的低分辨率图像块被分到距离聚类中心最近的 k 个簇，根据其距离计算 k 个权重。使用这 k 个簇对应的字典重建该低分辨率图像块，得到 k 个重建的高分辨率图像块，再进行加权平均得到最终的高分辨率图像块。最后整合所有的高分辨率图像块得到重建的高分辨率红外图像。

在文献[15]中，为提高红外图像的分辨率，作者提出一种使用多尺度稀疏编码以及模糊聚类提高红外图像分辨率的算法。该算法仍然基于稀疏表示的字典学习算法，融合来自多传感器图像的先验信息构建训练集。在训练阶段，使用不同的特征提取算子构建多尺度训练集，然后使用模糊聚类算法(Fuzzy C-Means, FCM)将每个训练集都分成多个具有相似模式的簇。与文献[14]的做法一致，针对每一个簇训练成对的过完备字典。低分辨率图像的重建过程与文献[14]一致。关于这 2 种算法的更多细节读者可阅读文献[14]与文献[15]。

上述 2 种算法, 均基于稀疏表示的字典学习算法进行改进。首先融合多传感器图像的先验信息构建训练集, 再使用不同的聚类算法将训练集分成不同的簇, 针对每个簇学习过完备字典。与原始的基于稀疏表示的字典学习算法相比, 由于这 2 种算法融合了多传感器图像的互补信息, 红外图像的超分辨率效果有了较大提升。但是, 这 2 种算法在训练阶段需要构建多个成对的过完备字典, 在重建阶段需要经历耗时的稀疏编码过程。本文算法沿用了上述算法融合多传感器图像互补信息的思想, 但是采用通过局部线性回归直接学习映射关系的超分辨率随机森林算法训练模型和重建图像。而且, 上述算法均假设在所有区域, 融合可见光图像的信息都可以提升红外图像的重建效果。然而实际上, 红外图像和可见光图像并非在所有区域都是高度相关的, 在相关性不高的区域融合可见光图像的信息, 反而会对重建结果产生负面影响。本文算法克服了这一问题, 在训练阶段, 分别训练包含互补信息的多传感器模型和只包含红外信息的单源模型, 在重建阶段, 本文算法使用自适应边缘提取算法计算红外图像块与可见光图像块之间的相关性, 根据相关性为红外图像块选择更加准确的重建模型, 使得重建效果更优。

3 实验结果分析

3.1 数据集以及参数设置

介绍数据集的来源。从 <https://www.dgp.toronto.edu/~nmorris/data/IRData/> 下载实验数据集^[14], 数据集中原始的红外图像和可见光图像均为包含丰富细节的高分辨率图像。用作测试的图像如图 6 所示。上面一行为红外图像, 下面一行为已经配准的可见光图像。从左到右依次标记为 A~E 组。

然后介绍实验参数的设置。随机森林算法的性能主要受决策树的数量 N -trees 和训练样本的数量 N -samples 影响。为了公平比较, 本文算法使用相同的训练集, 所以算法性能主要受 N -trees 影响。其他相关参数, 比如决策树的深度 ζ_{max} 、每个节点的最大样本数量 S_{max} , 对算法性能的影响并不明显, 按照文献[13]进行设置, 分别为 15 和 512。上采样因子设为 3。因此, 仅探索参数 N -trees 变化对算法性能的影响。设置横坐标参数 N -trees 在[1,45]之间变化, 纵坐标参数为测试图像的平均 PSNR 值。除第一次设为 1 外, 其他次以步长 5 变化, 选择其中的最优参数。结果如图 7 所示。

从图 7 可以看出, 随着 N -trees 从 1 增长到 25, 测试图像的平均 PSNR 值从 39.01 dB 大幅度上升到 39.56 dB。然而, 一旦 N -trees 取值超过 25, PSNR 值将会缓慢下降直到一个稳定的范围。这一现象表明, 当参数 N -trees 达到 25 左右时, 本文算法的性能趋于饱和。

3.2 与其他算法的比较

在实验中, 与一些经典的基于学习的算法进行比较。比较的算法包括: Bicubic 算法、Yang 等算法、Zeyde 等算法、SRF 算法。文献[17]中的开源框架包含了常见的基于学习的算法, 比如 Bicubic 算法、Zeyde 算法、Yang 的算法。文献[13]提供了 SRF 算法。与本实验无关的参数都使用原文献中的最优设置。使用峰值信噪比(PSNR)和结构相似性(Structural Similarity, SSIM)作为客观评价指标。实验结果如表 1 和表 2 所示。

表 1 各种算法的 PSNR 比较结果(单位: dB)

Table1 Comparison of PSNR of various methods

method	Bicubic	Yang et al.	Zeyde et al.	SRF	proposed
image A	33.04	34.09	34.20	38.02	38.15
image B	32.28	33.07	33.70	35.81	35.86
image C	35.44	36.48	37.22	40.05	40.19
image D	34.80	35.56	36.65	45.13	45.18
image E	33.11	34.28	34.35	38.32	38.41




Fig.6 Images used for testing

图 6 测试图像




Fig.7 Influence of the parameter N -trees

图 7 参数 N -trees 对算法性能的影响示意图

表 2 各种算法的 SSIM 比较结果
Table1 Comparison of SSIM of various methods

method	Bicubic	Yang et al.	Zeyde et al.	SRF	proposed
image A	0.969 3	0.961 4	0.974 6	0.981 1	0.981 6
image B	0.963 7	0.954 3	0.971 2	0.976 1	0.976 9
image C	0.974 3	0.966 2	0.981 1	0.985 0	0.985 3
image D	0.972 3	0.962 7	0.977 9	0.985 7	0.986 1
image E	0.963 8	0.955 0	0.970 7	0.978 9	0.979 3

表 1 和表 2 记录了测试图像用各种超分辨率算法重建的客观指标,表 1 为 PSNR 的比较结果,表 2 为 SSIM 的比较结果。从数据可以看出,对于所有测试图像,本文算法均可达到最优。从客观指标来看,本文算法取得了更好的效果。下面从主观的视觉效果来评价本文算法的性能,如图 8 所示。

从图 8 可以看出,Zeyde 算法与 SRF 算法均可获得较好的重建的红外图像,但是本文算法仍可获得更清晰的红外图像。从重建图像的局部放大图可以看出,Bicubic 算法重建的红外图像较为模糊,在台阶边缘处等几何区域表现得非常明显。Yang 算法重建的红外图像过度平滑,而且在台阶等物体边缘存在严重的振铃效应。Zeyde 算法的重建的图像较为清晰,但在物体边缘处仍然存在轻微的振铃现象。SRF 算法作为一种优秀的超分辨率算法,重建的图像更加清晰,但在台阶等物体边缘比本文算法表现得更加平滑。而本文算法很好地克服了过度平滑问题和振铃效应,重建的高分辨率红外图像非常清晰,最接近原始的红外图像。




Fig.8 Qualitative comparison of image A
图 8 图 A 的主观效果比较

4 结论

针对与可见光图像相比,实际获取的红外图像分辨率不高的问题,提出了一种基于随机森林的多传感器红外图像超分辨率算法。由于本文算法充分利用了红外图像与配准的可见光图像对同一场景的补偿信息,可以提升红外图像的重建效果。在训练阶段,本文算法使用红外图像训练集以及多传感器图像训练集分别训练 2 个不同的随机森林模型。在重建阶段,针对测试图像块,根据其与对应的可见光图像块之间的相关性选择合适的模型,以相对较小的误差重建高分辨力图像块。使用本文算法重建低分辨率测试图像,并与 Bicubic 算法、Yang 等算法、Zeyde 等算法、SRF 算法重建的图像进行比较。实验结果表明,本文提出的基于随机森林的多传感器红外图像超分辨率算法可以获得更好的客观指标与主观效果,比 SRF 算法重建的红外图像的 PSNR 平均高出 0.09 dB,并且获得了更为清晰的高分辨率红外图像。

参考文献:

- [1] 沈志伟,杨晓敏,吴炜,等. 自适应半耦合稀疏字典学习算法[J]. 太赫兹科学与电子信息学报, 2018,16(3):164-169,181. (SHEN Zhiwei,YANG Xiaomin,WU Mei,et al. Adaptive semi-coupled sparse dictionary learning algorithm[J]. Journal of Terahertz Science and Electronic Information Technology, 2018,16(3):164-169,181.)
- [2] KIMMEL R. Demosaicing: image reconstruction from color CCD samples[J]. IEEE Transactions on Image Processing, 1999, 8(9):1221-1228.
- [3] LI X. Demosaicing by successive approximation[J]. IEEE Transactions on Image Processing, 2005,14(3):370-379.
- [4] SHEN H,ZHANG L,HUANG B,et al. A MAP approach for joint motion estimation,segmentation,and super resolution[J]. IEEE Transactions on Image Processing, 2007,16(2):479-490.
- [5] ZHANG L,ZHANG H,SHEN H,et al. A super-resolution reconstruction algorithm for surveillance images[J]. Signal Processing, 2010,90(3):848-859.
- [6] FARSIU S,ROBINSON M D,ELAD M,et al. Fast and robust multiframe super resolution[J]. IEEE Transactions on Image Processing, 2004,13(10):1327-1344.
- [7] FREEMAN W T,JONES T R,PASZTOR E C. Example-based super-resolution[J]. IEEE Computer Graphics and Applications, 2002,22(2):56-65.