

面向异构图像压缩感知的阶数自适应多假设重构

郑颢铄, 刘浩, 燕帅, 陈根龙

引用本文

郑颢铄, 刘浩, 燕帅, 陈根龙. 面向异构图像压缩感知的阶数自适应多假设重构[J]. 计算机科学, 2024, 51(10): 302-310.

ZHENG Yongxian, LIU Hao, YAN Shuai, CHEN Genlong. [Order-adaptive Multi-hypothesis Reconstruction for Heterogeneous Image Compressive Sensing](#) [J]. Computer Science, 2024, 51(10): 302-310.

相似文章推荐 (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)

[面向最优直方图求解的监督学习模型研究](#)

Study on Supervised Learning Model for Optimal Histogram Solution

计算机科学, 2023, 50(9): 145-151. <https://doi.org/10.11896/jsjcx.230300065>

[基于多尺度注意力机制的两阶段文物图像修复方法](#)

Two-stage Method for Restoration of Heritage Images Based on Muti-scale Attention Mechanism

计算机科学, 2023, 50(6A): 220600129-8. <https://doi.org/10.11896/jsjcx.220600129>

[基于改进狮群进化算法的面向空间众包平台的多工作者多任务路径规划方法](#)

Multi-worker and Multi-task Path Planning Based on Improved Lion Evolutionary Algorithm for Spatial Crowdsourcing Platform

计算机科学, 2021, 48(11A): 30-38. <https://doi.org/10.11896/jsjcx.201200085>

[基于颜色校正和去模糊的水下图像增强方法](#)

Underwater Image Enhancement Based on Color Correction and Deblurring

计算机科学, 2021, 48(4): 144-150. <https://doi.org/10.11896/jsjcx.200800185>

[面向一致增强评估的子集比例动态选取方法](#)

Subset Ratio Dynamic Selection for Consistency Enhancement Evaluation

计算机科学, 2021, 48(2): 153-159. <https://doi.org/10.11896/jsjcx.200800188>

面向异构图像压缩感知的阶数自适应多假设重构

郑颢铄 刘浩 燕帅 陈根龙

东华大学信息科学与技术学院 上海 201620

(2222048@mail.dhu.edu.cn)

摘要 大数据时代到来,使得图像传感应用面临大维度处理与大容量传输的挑战,压缩感知技术及相关算法在一定程度上解决了该问题。然而,现有压缩感知算法存在对异构图像集泛化性不足的问题,需要为此类图像集设计高泛化性的压缩感知重构算法。因此,基于泛化性较高的多假设预测机制,提出一种阶数自适应多假设重构算法。首先通过窗口自适应线性预测器对各块进行预处理,根据预处理获得的相关性指标,改变多假设搜索窗口的大小,并依据相似度对搜索窗口内的预测块进行排序,结合自适应的搜索窗口挑选不同数量的高相似预测块,生成多假设预测的重构图像。选取自然图像集以及X光胸片和脑磁两个异构图像集进行实验,在不同采样率下对比所提算法与传统的多假设压缩感知重构算法以及两种新近提出的基于多假设预测的算法性能。实验结果表明,所提算法具有良好的性能提升。在自然图像集下,相比两种新近提出的基于多假设预测的重构算法,所提算法保持了一定的恢复质量,且运行时间分别减少了17.5%,28.7%。此外,相比两种新近提出的算法,在胸片图像集下,所提算法分别获得了1.16dB,1.43dB的平均PSNR提升,以及36.1%,21.5%的平均运行时间减少;在脑磁图像集下,所提算法分别获得了1.64dB,1.97dB的平均PSNR提升,以及平均28.6%,26.1%的运行时间减少。整体而言,所提算法具有较低的时间复杂度、较高的恢复质量,综合性能更佳。

关键词: 压缩感知重构;多假设预测;线性预测器;阶数自适应;异构图像集

中图分类号 TN919.8

Order-adaptive Multi-hypothesis Reconstruction for Heterogeneous Image Compressive Sensing

ZHENG Yongxian, LIU Hao, YAN Shuai and CHEN Genlong

College of Information Science and Technology, Donghua University, Shanghai 201620, China

Abstract The arrival of the big data era poses challenges for processing and transmitting large amounts of image data. The compressive sensing technology and related algorithms have solved some of these problems to a certain extent. However, existing compressive sensing algorithms still have problems when adapting to heterogeneous image sets. Therefore, it is necessary to design a highly generalized compressive sensing reconstruction algorithm for such image sets. In this paper, an order-adaptive multi-hypothesis reconstruction algorithm is proposed according to a multi-hypothesis prediction mechanism with high generalization. The proposed algorithm preprocesses each block using a window-adaptive linear predictor and changes the size of the multi-hypothesis searching window according to the correlation index obtained from preprocessing. The prediction blocks within the searching window are sorted according to block-wise similarity and different numbers of highly similar prediction blocks are selected from the adaptive searching window for the reconstructed image of multi-hypothesis prediction. Experiments are conducted on a natural image set and two heterogeneous image sets of X-ray chest and brain MRI. At different sampling rates, many experiments and analyses are carried out by comparing the traditional multi-hypothesis compressive sensing reconstruction algorithm and two recent algorithms of multi-hypothesis prediction. The experimental results show a good performance improvement of the proposed algorithm compared to the traditional multi-hypothesis compressive sensing reconstruction algorithm. On the natural image set, the proposed algorithm maintains a certain recovery quality and achieves an average runtime decrease of 17.5% and 28.7% respectively, compared to two recently proposed algorithms. As compared to two recent proposed algorithms: on the X-ray chest image set, the average PSNR value of proposed algorithm increases by 1.16dB and 1.43dB, and the average runtime decreases by 36.1% and 21.5%, respectively. On the brain MRI image set, the average PSNR value increases by 1.64dB and 1.97dB, and the average runtime decreases by 28.6% and 26.1%, respectively. Overall, the proposed algorithm has low computational complexity and high recovery quality with better tradeoff performance.

到稿日期:2023-08-24 返修日期:2024-01-09

基金项目:国家自然科学基金(62001099)

This work was supported by the National Natural Science Foundation of China(62001099).

通信作者:刘浩(liuhao@dhu.edu.cn)

Keywords Compressive sensing reconstruction, Multi-hypothesis prediction, Linear predictor, Order-adaptive, Heterogeneous image set

1 引言

随着社会发展和大数据时代的到来,图像传感应用需应对越来越高清和大容量的信号数据,信息传输需要及时处理。虽然压缩感知(Compressive Sensing, CS)在减少观测数据方面具有明显优势,但仍存在数据处理量大、存储负担重以及不易扩展等问题。这些因素推动了分块压缩感知(Block Compressive Sensing, BCS)技术的发展,其可用于分布式和快速数据处理。BCS将图像划分为多个块,分别进行随机采样,各块使用相同的观测矩阵投影至低维空间。相比传统CS方法,BCS的观测矩阵尺寸较小,可以减少编码端存储负担,也使得变换编码后的信号具有更强的稀疏性,且解码端的计算复杂度降低,大大提高了图像的重构速度。在过去的10年中,图像压缩感知领域的挑战包括使用随机采样算子的高计算成本和大内存负担,解决方案包括使用结构随机矩阵^[1],以及将CS采样限制在分块上^[2-3]。例如,基于BCS的平滑投影Landweber重建(BCS-SPL)及其离散小波变换域的多尺度变体(MS-BCS-SPL)^[4]提供了比全图CS更快的重构速度。BCS作为不断发展的图像压缩感知编码解码框架,受到广泛关注,并已成功应用于医学图像等领域。

基于以上研究,Chen等将预测加残差重构的多假设方法扩展到了分块压缩感知中^[5],以增强BCS重构的效果,提出了多假设压缩感知重构(Multiple Hypothesis, MH)算法,用于静态图像和视频重构。对于静态图像,MH算法首先进行初始的BCS重构,并利用各块的相邻信息生成预测残差。多假设预测采用距离加权的Tikhonov正则化,以寻找最佳的假设组合。多假设预测生成了待恢复信号的测量域残差,通常比原始信号更容易压缩,因此更适合进行压缩感知重构。作为BCS领域的代表性技术,多假设预测能够鲁棒地提高重构图像的恢复质量,已被广泛用作新近提出的算法的基础结构,但其存在预测模型阶数经验固定的问题^[6-7]。

近年来,许多图像恢复方案利用了图像的稀疏性^[8]。例如,利用字典或变换对图像组合进行稀疏化处理^[9]。除了局部稀疏性,图像还具有非局部结构,非局部自相似先验指自然图像内部包含大量相似的区域,且这些区域在空间上相距较远。非局部自相似表征了纹理和结构的重复性,这些纹理和结构位于图像的不同区域。基于非局部自相似的图像恢复机制主要分成两类:一类为结构稀疏表示,另一类为低秩最小化。基于结构稀疏表示的代表性算法包括非局部自相似先验图像恢复^[10]、组稀疏表示图像恢复^[11]和基于片组的非局部自相似先验学习^[12];基于低秩最小化的代表性算法包括秩残差约束^[13]和加权核范数最小化^[14]。

针对上述两类机制,组稀疏编码将图像的局部稀疏性和非局部自相似性进行了集成。Zha等设计了一种自适应字典^[15],可弥合结构稀疏表示和低秩最小化之间的差距。在自适应字典下,组稀疏编码和低秩最小化问题等价,因此可通过估计每个片组的奇异值来测量每个片组的稀疏系数,从而

提出了加权 L_p 范数的组稀疏编码(Group-based Sparse Coding Weighted L_p -norm, GSC-WLP)算法,该算法适用于压缩感知重构。结构稀疏表示和低秩最小化均已被证明对图像恢复问题非常有效。因此,Zha等提出了一种混合结构稀疏误差(Hybrid Structural Sparsification Error, HSSE)算法^[16],该算法可应用于图像恢复与压缩感知重构,利用内部和外部图像先验相互提供额外信息,弥补非局部自相似的不足,以获得更好的图像恢复效果。

异构图像集指在内容、外观或风格方面与自然图像集显著不同的图像集合。在图像处理中,应用BCS技术解决了数据处理及维度灾难等问题,但产生了为异构图像集设计和优化重构算法,以消除误差和块效应的需求。HSSE和GSC-WLP作为两种新提出的算法,均使用多假设预测作为基础结构,但它们针对所用数据集还进行了大量的参数优化,并且HSSE进一步使用外部图像数据针对所用数据集进行了分布拟合,在自然图像集下取得了优异的恢复质量。但是,这些新算法应用于异构图像集的泛化能力受到了限制,且非局部自相似先验广泛针对自然图像集,难以处理异构图像集。类似于HSSE与GSC-WLP等基于字典学习的压缩感知重构算法,基于深度学习的压缩感知技术存在着相同的拟合问题,虽然通过高度适配训练数据的分布,能够在自然图像集上获得出色的重建结果,但是由于异构图像集与自然图像集的分布不同,因此这些算法运用到异构图像集时往往效果不佳。故面向异构图像集,基于深度学习的压缩感知重构算法的泛化性能仍然受到了一定程度的限制。多假设预测的复杂度较低,无须针对特定数据集进行优化。

受以上分析的启发,本文提出了一种阶数自适应多假设(Order-Adaptive MultiHypothesis, OAMH)重构算法,通过自适应地改变搜索窗口和候选预测块,可实现比传统多假设重构更高的图像恢复质量,时间复杂度仅略微增加,且泛化性较强。概括而言,本研究的主要贡献如下:

- 1)引入窗口自适应线性预测器,对各块进行预处理,根据初始重构图像中当前块和周围块的相关性指标来选择预测块,分析当前块的区域特征,以获得搜索窗口的最佳大小。
- 2)引入阶数自适应预测模块,根据块间欧几里得距离,在搜索窗口内选择不同数量的高相似预测块,并根据不同窗口大小选择不同的预测块,所提算法在各类图像集上都表现出极佳的综合性能。

2 背景

压缩感知是一种着重于面向大维度、大数据量的信号获取理论,对于图像等可压缩的多媒体信号,压缩感知理论同样适用。图像信号传统采样:满足奈奎斯特采样的各类方法,在欠采样率下容易引入重构伪影和失真,只有采样率为带宽两倍以上,才可无失真重构。压缩感知重构具有良好的恢复质量和更低的采样率。

压缩感知理论一般使用线性随机观测矩阵对图像信号

进行采样,如高斯随机投影矩阵,随后利用非线性方法对具有稀疏性的测量信号进行重构。图像压缩感知的主要工作在编码端与解码端,可以减少图像信号的传输负担。

2.1 分块压缩感知 (BCS)

压缩感知理论指出,如果想要从 M 阶测量信号中恢复原始信号 $x \in \mathbb{R}^N$ 且 $M \ll N$; 令 $y = \Phi x$, 其中 $y \in \mathbb{R}^M$, Φ 是一个 $M \times N$ 的观测矩阵, 采样率 $S = M/N$ 。

若 x 在某个正交基 Ψ 下的稀疏度很高, 那么可以通过测量信号的一些随机线性投影 y 来恢复信号, 而无须采集信号的完整样本, 通常采用最优化。

$$\hat{x} = \arg \min_{x \in \mathbb{R}^N} \|\Psi x\|_1, \text{ s. t. } y = \Phi x \quad (1)$$

其中, Φ, Ψ 需要具备足够的不相关性。分块压缩感知的基本原理是将原始图像分成多个块, 对每个块分别进行压缩感知采样, 即 BCS 编码, 这可以通过将每个块投影到一个低维空间来实现。由于每个块通常是稀疏的, 因此在低维空间中进行投影后, 可以使用更少的观测来捕获信号的主要信息从而进行 BCS 图像恢复, 即 BCS 解码。

2.2 多假设预测

BCS 重构技术, 例如基于块采样算子的 BCS-SPL, 在恢复质量方面可能存在劣势。由于压缩感知采样通常在全局范围内效果更好, 因此多假设预测被引入分块压缩感知重构。为了产生高度可压缩的残差, 应该创建尽可能接近原始图像 x 的预测, 这意味着需要寻找以下优化问题。对于多假设重构, 目标是通过引入 Tikhonov 正则化对最小二乘问题进行最优化。

$$\hat{w}_i = \arg \min_w \|y_i - \Phi H_i w\|_2^2 + \lambda \| \Gamma w \|_2^2 \quad (2)$$

其中, $y = \Phi x$ 表示观测值; x 表示原始图像; \tilde{x} 表示一个预测图像, 满足 $\tilde{x} = H_i \hat{w}_i$ 并且 $x \approx \tilde{x}$; H_i 是假设矩阵, 由假设块组合构成; \tilde{x} 为初始重构图像, 一般使用 BCS-SPL 算法生成; Γ 被称为 Tikhonov 矩阵; i 代表 BCS 各个块的序号参数 λ 控制正则化。最终的重构图像由公式 $\hat{x} = \tilde{x} + \text{Reconstruct}(y - \Phi \tilde{x}, \Phi)$ 计算得到, 其中 $\text{Reconstruct}()$ 代表任一压缩感知重构机制。

图 1 为多假设的示意图, 图 1(a) 表示在搜索窗口中为当前块生成多假设, 假设块是在 $B \times B$ 大小的当前块周围、宽度为 w 的窗口内, 所有 $B \times B$ 大小的重叠块; 图 1(b) 表示为大小为 $B \times B$ 的当前块内的每个大小为 $b \times b$ 的更小片生成多假设; 图 1(c) 是将所有 $b \times b$ 的片进行零填充并组合预测矩阵 H_i 。

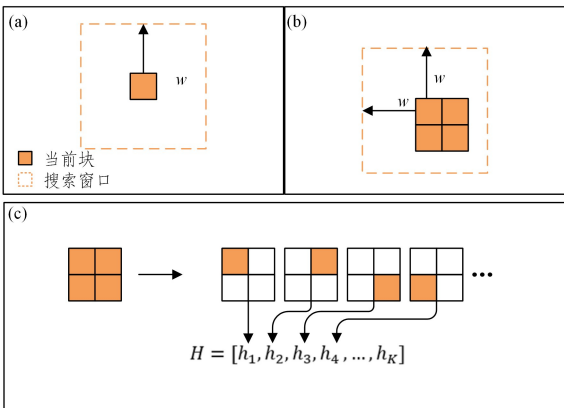


图 1 多假设的示意图

Fig. 1 Multi-hypothesis diagram

图 2 给出了基于多假设预测的重构流程。在 BCS 编码后, 对初始重构图像进行多假设预测, 生成的预测图像与 BCS 解码图像相加后进行迭代。多假设预测的输出是当前块的残差预测值。多假设预测具有预测速度更快和更通用的优点, 而使用外部或内部图像先验进行 BCS 重构的算法应用于异构图像集时可能出现性能下降。为了消除在不同情况下生成预测图像时像素丢失或冗余像素对当前块的影响, 本文提出了一种新的压缩感知重构算法——阶数自适应多假设重构 (OAMH)。所提 OAMH 算法基于传统的多假设压缩感知重构, 在原本固定的预测块搜索窗口之上加入自适应机制。在自适应线性预测器中, 对于不同的采样率, 搜索窗口会增加或减小, 并且根据搜索窗口的大小和相似度来选择预测块。所提算法的具体流程将在第 3 章中描述。

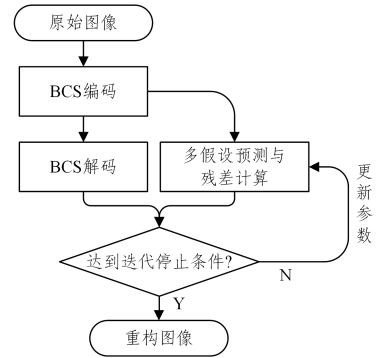


图 2 基于多假设预测的重构流程

Fig. 2 Reconstruction process based on multi-hypothesis prediction

3 阶数自适应多假设重构

基于多假设预测的压缩感知重构算法在搜索窗口内, 选取当前块的周围块作为当前块的多假设。如果图像恢复质量较差, 则多假设可能不合适。也就是说, 周围块可能不足以生成足够正确的预测矩阵 H_i 。当不正确地选择假设时, 图像恢复质量将会降低, 即多假设预测只在每次迭代中使用固定大小的预测搜索窗口。Kallummil 等^[17]提出了一种通用残差阈值预测器, 利用该预测器自动调整支撑信号的形状来预测局部信号。而对于信号预测的顺序和支撑信号的形状, 可以使用贝叶斯信息准则来确定, 可在线性预测的偏差和方差之间取得平衡。自适应线性预测能够适配像素的局部相关性与非局部相关性, 通过灵活地选择更相关的像素来估计当前块, 有助于获取图像的重要特征或进行相关性分析。受通用残差阈值预测器的启发, 所提 OAMH 算法基于自适应线性预测原理, 使用当前块的周围像素来评估当前块与周围块的相似度, 并将其作为评判准则进行多假设预测优化。

3.1 窗口自适应线性预测器

对于当前块的任一待评估像素, 其预测值可以表示为对其周围像素的线性组合。

$$\hat{x} = u_k(x)^T \cdot \hat{a} \quad (3)$$

$$\text{其中, } \hat{a} = \arg \min_a \sum_{y \in T_k} \|y - u_k(y)^T \cdot a\|_2^2 \quad (4)$$

其中, \hat{a} 是由像素训练集 T_k 进行最优化计算后获得的最佳线性系数。其他符号的定义由以下流程确定: 根据当前像素与

周围像素 $\mathbf{u}_i(x)$ 之间的相关性,形成从高到低排序的像素集合。该集合表示为:

$$U(x) = \{\mathbf{u}_1(x), \mathbf{u}_2(x), \dots \mid |p_1(x)| \geq |p_2(x)| \geq \dots\} \quad (5)$$

相关性 $p_i(x)$ 排序由式(6)决定, X, Y 表示分别以待评估像素与其周围像素为中心的块,可根据精度选取不同尺寸, n 代表块内像素数。

$$\text{cor}(X, Y) = \frac{\sum_i^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_i^n (X_i - \bar{X})^2 \cdot \sum_i^n (Y_i - \bar{Y})^2}} \quad (6)$$

接下来,所提算法将扩大搜索范围,在当前像素周围寻找训练集 T_k ,按照一定阈值进行搜索。

$$T_k = \left\{ y \mid \frac{1}{K} \|\mathbf{u}_k(y) - \mathbf{u}_k(x)\| \leq \tau \right\} \quad (7)$$

其中, K 为需要自适应调整的模型阶数; τ 是一个阈值,定义为初始状态下像素训练集 T_k 中各像素的相似像素集合与待分析像素的相似像素集合差距的最大值,用于防止阶数 K 变化后更新的训练集引入更加冗余的信息。

$$\tau = \max_y \frac{1}{k_s} \|\mathbf{u}_k(y) - \mathbf{u}_k(x)\| \quad (8)$$

其中, \mathbf{u}_{k_s} 是 U 的子集,由集合 U 中前 k_s 个像素组成,与初始 K 值相同,设置为 3。 K 的最终值由以下基于贝叶斯信息准则的公式确定:

$$\text{loss}(\mathbf{u}_k, T_k) = -\frac{1}{|T_k|} \sum_{j=1}^{|T_k|} \log D(r_j^k) + \frac{K \cdot \log |T_k|}{2|T_k|} \quad (9)$$

$$D(r_j^k) = \begin{cases} 1 - e^{-\frac{1}{\sqrt{2}\sigma}}, & r_j^k = 0 \\ \frac{1}{2} \left(e^{-\frac{|r_j^k| - 0.5}{\sigma\sqrt{e}}} - e^{-\frac{|r_j^k| + 0.5}{\sigma\sqrt{e}}} \right), & 0 < |r_j^k| < R \\ \frac{1}{2} e^{-\frac{|r_j^k| - 0.5}{\sigma\sqrt{e}}}, & |r_j^k| = R \end{cases} \quad (10)$$

其中,残差 $r_j = y_j - \mathbf{u}_k(y_j)^T \cdot \hat{\mathbf{a}}$,依据拉普拉斯分布建模进行计算; R 为最大残差绝对值。

通过最小化 $\text{loss}(\mathbf{u}_k, T_k)$ 函数,可得到最优的模型阶数 K 。根据贝叶斯信息准则,最小化模型阶数包含了对参数的约束,有助于防止模型过拟合,增强参数的泛化性能。窗口自适应线性预测器(Window-Adaptive Linear Predictor, WALP)获得的模型阶数一定程度上表征了当前像素与周围像素的相关性:阶数越小,即可以使用较少的邻近像素线性地预测出待评估像素,反映了待评估像素与邻近像素的高相关性;阶数越大,待评估像素预测则需要更多邻近像素参与,且可能取自较远像素,因而相关性较弱。

3.2 阶数自适应预测

BCS 将图像分割成具有相同边长的块,边长通常设置为 32。多假设预测首先使用 BCS 获得初始重构图像 $\bar{\mathbf{x}}$,随后在 $\bar{\mathbf{x}}$ 每个块的处理中,使用周围块的所有细节在特定搜索窗口中生成多假设,进行预测生成、残差计算与迭代。

阶数自适应多假设重构算法利用初始重构图像 $\bar{\mathbf{x}}$ 的特性(即模块 WALP 输出结果),判断当前块与周围块之间的相关性,生成相关性指标,以此为参照调整后续预测阶段的搜索

窗口大小。所提算法自适应地调整搜索窗口的大小并进行多假设重构,我们将此模块命名为阶数自适应预测(Poamh),模块的流程如下。

线性预测训练集的搜索范围限制在 MH 预测的最大搜索窗口范围内,用每个块边缘的多个非连续像素作为输入像素,评估处理当前块与周围块之间的关系。在 WALP 模块计算出最佳模型阶数 K 后,可获得所有 \mathbf{u}_k 像素的位置信息。随后, Poamh 模块忽略当前块内部的 \mathbf{u}_k 像素,仅计算最大搜索窗口内当前块外的 \mathbf{u}_k 像素数。每个块的 \mathbf{u}_k 数量表示为 $n_{u_k, i} (i=1, \dots, n_{\text{subblock}})$, n_{subblock} 表示块的总个数。

对于低相关性区域,多假设容易受到来自周围区域冗余像素的影响,从而导致预测误差,因此应减少周围冗余像素造成的干扰;对于高相关性区域,需要从周围块获得更多可用像素,并应适当扩展搜索窗口。在不同采样率下进行多假设预测 BCS 重构,应考虑上述两种情况。所提算法能够在减少干扰信息与从周围块获得更多相似像素之间取得平衡。搜索窗口大小变化的块占所有块的比例将在下一节中进行说明。窗口大小变化可以总结为:首先对窗口中的所有假设块根据其当前块的相似度进行排序,并生成集合 $P_i (i=1, \dots, n_{\text{subblock}})$ 。

$$P_i = \{h_1, h_2, \dots, \mid |s_1| \geq |s_2| \geq \dots\} \quad (11)$$

其中, h 表示假设块, s 表示假设块和当前块之间的相似度。利用欧几里得距离评估块间的相似度。块间欧几里得距离越小,则相似度 s 越高。经过上述方法排序后,所提算法对所有假设块进行下一步选择。假设块数量的设置分为两种:对于需要放大窗口的块,假设块数量由多假设重构算法中初始搜索窗口的大小决定;对于需要缩小窗口的块,假设块由缩小的搜索窗口大小决定。图 3 展示了搜索窗口大小的变化。




图 3 搜索窗口大小变化的示意图

Fig. 3 Illustration of searching window size changes

具体窗口大小变化方式可以分为以下两种:

1) 扩大窗口大小的块

(1) 多假设搜索窗口的范围增大为 w' 。统计放大窗口范围内的所有假设块,以生成按照相似度排序的集合 P_i 。

(2) 将相似度靠前的绝大部分假设块设置为新的待使用假设块,剩余部分将被淘汰。待使用的假设块数量由原有窗口大小 w 决定,生成的假设块集合命名为 P_i' :

$$P_i' = \{h_1, h_2, \dots, h_{n_w} \mid |s_1| \geq |s_2| \geq \dots \mid s_{n_w}\} \quad (12)$$

其中, n_w 表示原有窗口大小内的假设块数量。

(3) 由 P_i' 生成多假设预测矩阵 \mathbf{H}_i 。

2) 缩小窗口大小的块

(1) 多假设搜索窗口的范围保持不变。统计当前窗口

范围内的所有假设块,以生成按照相似度排序的集合 P_i 。

(2)将相似度靠前的大部分假设块设置为新的待使用假设块,剩余部分将被淘汰。待使用的假设块数量由缩小后的搜索窗口大小 w'' 决定,生成的假设块集合命名为 P_i'' :

$$P_i'' = \{h_1, h_2, \dots, h_{n_{w''}} \mid |s_1| \geq |s_2| \geq \dots \geq |s_{n_{w''}}|\} \quad (13)$$

其中, $n_{w''}$ 表示缩小后窗口大小内的假设块数量。

(3)由 P_i'' 生成多假设预测矩阵 H_i 。

在 Poamh 模块的最后部分,即获得所有多假设预测矩阵后,进行基于 Tikhonov 正则化的权重最优化,生成预测图像。OAMH 算法的主要伪代码如算法 1 所示,块分类示意图如图 4 所示。OAMH 算法能够决定哪些块的搜索窗口需要被缩小,而哪些块的搜索窗口需要被放大,剩余块的搜索窗口大小不需要改变。

算法 1 阶数自适应多假设重构

输入: $\bar{x}_0, \mathbf{y}, \Phi = [\Phi_R; \Phi_H], \Psi, \bar{\mathbf{x}}, \mathbf{b}, \mathbf{w}, B=32, \tau, n_{\text{subblock}}$

输出: $\bar{\mathbf{x}}$

初始化: $i=1, \bar{\mathbf{x}}_0 = \bar{\mathbf{x}}, s_0=0, R_0 = +\infty$

1. for $i=1$ to n_{subblock} do
2. $n_{u_{k,i}} = \text{WALP}(\bar{\mathbf{x}})$
3. end for
4. reset $i=1$
5. repeat
6. if $n_{u_{k,i}}$ 属于 $n_{u_{k,i}} (i=1$ to $n_{\text{subblock}})$ 相似度前 5%
7. $w = w'$
8. else if $n_{u_{k,i}}$ 属于 $n_{u_{k,i}} (i=1$ to $n_{\text{subblock}})$ 相似度后 5%
9. $w = w''$
10. end if
11. $\bar{\mathbf{x}}_i = P_{\text{oamh}}(\bar{\mathbf{x}}, \mathbf{y}, \Phi, \mathbf{w}, B)$
12. $\hat{\mathbf{x}}_i = \bar{\mathbf{x}}_i + \text{BCS-SPL}(y - \Phi_R \bar{\mathbf{x}}_i, \Phi_H, \Psi, B)$
13. $s_i = \text{SSIM}(\hat{\mathbf{x}}_i, \hat{\mathbf{x}}_{i-1}), R_i = \|\mathbf{y}_H - \Phi_H \hat{\mathbf{x}}_i\|_2$
14. if $b < B$ then
15. if $(R_i < R_{i-1} \& |s_i - s_{i-1}| \leq \tau)$ or $R_i > R_{i-1}$ then $b \leftarrow b \times 2, w \leftarrow w \times 2$
16. end if

17. update $\bar{\mathbf{x}} \leftarrow \hat{\mathbf{x}}_i$
18. $i=i+1$
19. until $R_i > R_{i-1} \& b=B$

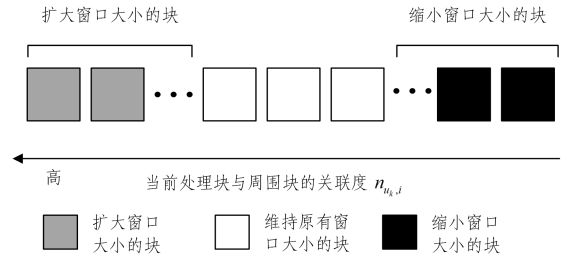


图 4 块分类的示意图

Fig. 4 Illustration of block classification

对于当前块而言,与周围块具有极高或极低相关性的块比例均不会太高,图 4 中分别用灰色、黑色表示。

4 实验结果与分析

本文进行了大量实验来比较所提 OAMH 算法和其他重构算法,如 MH^[5], GSC-WLP^[15] 和 HSSE^[16], 它们的代码可以在相应的网站上找到。本文的仿真平台如下: Intel Core (TM) i7-8750 CPU、2.20GHz、32GB 内存、Windows 11 操作系统、MATLAB R2021b。

4.1 数据集

为评估所提算法,本文实验选用 3 个公开数据集。1) 自然图像集 Set11^[18], 包括“Barbara”“Boat”“Cameraman”“Couple”“Fingerprint”“Flinstones”“House”“Lena”“Mandrill”“Peppers”“Streamandbirdge”共 11 幅图像。2) 异构图像集 tawsifur^[19], 该胸片图像集由“tawsifur_covid19”“tawsifur_Normal”和“tawsifur_Viral Pneumonia”3 个子类 X 光胸片图像构成, 各子类包含 200 幅图像。3) 异构图像集 BrainMRI^[20], 该脑磁图像集由两类脑磁图像构成, 各子类包含 100 幅图像。图 5 给出了上述 3 个图像集的代表图像直方图, 可见 3 个图像集在图像直方图上具有显著差异, 表明自然图像集 Set11 与另两个图像集存在高度的异构性。

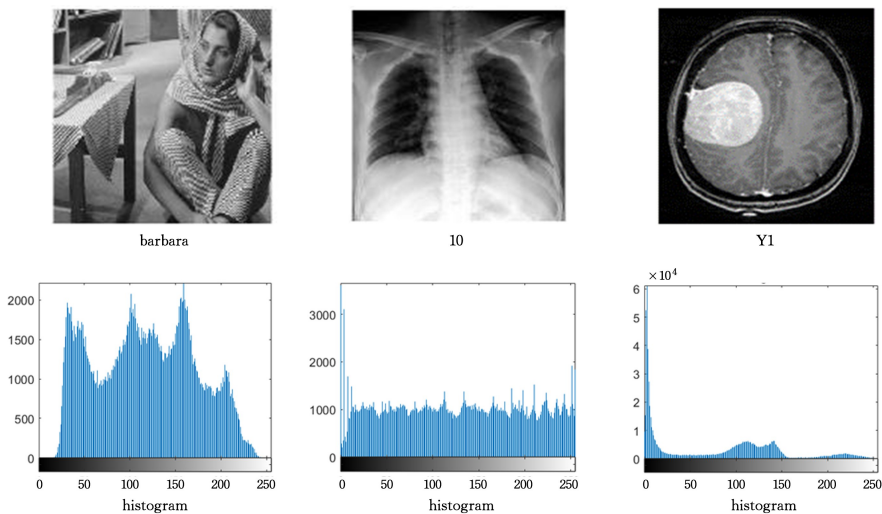


图 5 各图像集代表图像的直方图对比

Fig. 5 Histogram comparison of representative image from different image sets

4.2 算法参数设置

与现有分块压缩感知算法相同,采样率设置为 0.1~0.5。在所有实验中,图像大小均为 512,块大小设置为 32×32 。搜索窗口 w 设置为 5~8,所提 OAMH 算法对 w 的扩展或减少设置为 1~2,以生成新的搜索窗口大小。我们选择了 10%(5%+5%)的块更改搜索窗口大小,使用的观测矩阵为高斯随机矩阵。MH, HSSE 与 GSC-WLP 算法的实验参数均按照对应文献中的最佳参数进行设置, MH 算法的搜索窗口大小设置如下:采样率 0.1~0.3 的搜索窗口大小设置为 6,采样率 0.4~0.5 的搜索窗口大小设置为 8。HSSE 算法与 GSC-WLP 算法的搜索窗口与 MH 算法相同。

图 6 给出了 Set11 图像集中图像“boat”的 $n_{u_k, i}$ 统计图,它显示了每个块与周围块之间的相关度分布。从图中可以看出,当前块与周围块相关度大小的分布集中在中间值,这类类似于正态分布的特性。这可以侧面表明,与周围块具有高或低相关性的块只占图像所有块的极小部分。3 类实验图像集的其他图像也具有相同的规律。为了确定改变窗口大小块占全部块的选择比例,我们对 9%, 7%, 5% 和 3% 的不同比例(ratio)参数进行了实验。图 7 给出了在 0.3 采样率下典型图像“boat”的每个选择比例通过 OAMH 获得的重构图像 PSNR 值。它表明,对于“boat”测试图像,5% 的选择比例获得了最佳的 PSNR 性能。对于其余测试图像,增加或减少 5% 窗口块比其他比例的泛化性更高,平均效果提升最好,不会出现指标剧烈波动的情况。




图 6 图像“boat”的 $n_{u_k, i}$ 分布直方图

Fig. 6 Histogram of $n_{u_k, i}$ distribution in image “boat”




图 7 图像“boat”不同选择比例的 PSNR

Fig. 7 PSNR of image “boat” at different selection ratios

4.3 算法复杂度分析

就算法复杂度而言,所提算法针对多假设预测算法的预测和生成过程进行联合优化,并在初始阶段添加了基于块的预处理,算法复杂度的增加较小。相比之下, HSSE 和 GSC-WLP 算法利用了复杂的基于块的非局部自相似性先验和外部数据分布拟合机制,导致算法复杂度显著增加。因此,在

算法复杂度方面,所提 OAMH 算法显著优于 HSSE 和 GSC-WLP 算法。所提算法的额外运行时间主要由 WALP 的计算决定,且比 HSSE 和 GSC-WLP 基于外部或内部图像先验进行多次迭代最优化的计算复杂度低得多。

表 1 和表 2 列出了各采样率下图像集的图均运行时间。相比 HSSE 和 GSC-WLP 算法,所提算法在自然图像集上的运行时间分别减少了 17.5% 与 28.7%,在胸片图像集上的运行时间分别减少了 36.1% 与 21.5%。

表 1 Set11 图像集的图均运行时间

Table 1 Average runtime of Set11 image set

采样率	MH ^[5]	GSC-WLP ^[15]	HSSE ^[16]	OAMH
0.1	77	106	117	84
0.2	69	98	116	78
0.3	60	96	122	80
0.4	81	113	123	99
0.5	79	106	122	87

表 2 Tawsifur 图像集的图均运行时间

Table 2 Average runtime of Tawsifur image set

采样率	MH ^[5]	GSC-WLP ^[15]	HSSE ^[16]	OAMH
0.1	102	192	131	112
0.2	80	175	153	100
0.3	67	137	166	71
0.4	68	141	158	89
0.5	90	135	126	97

从算法复杂度来看, MH 算法作为其余 3 种算法的基础架构,算法复杂度最低,其重构利用了 Tikhonov 正则化,算法复杂度为 $O(pkn^3)$, p 代表算法迭代次数, n 为块数量,而 k 为假设块数量; HSSE 在 MH 重构图像的基础上使用内部和外部先验进行再次重构,复杂度达到 $O(pkn^3 + qm^2)$, q 代表 HSSE 算法迭代次数, m 为片数量; GSC-WLP 算法复杂度为 $O(pkn^3 + rm^2)$, r 为其迭代次数; 所提 OAMH 算法仅在 MH 基础上添加了 WALP 预处理,遍历各块进行较少次数的迭代优化以生成评估,算法复杂度为 $O(pkn^3 + sm)$, s 代表 WALP 模块迭代次数,且远少于 HSSE 与 GSC-WLP 的迭代次数。综上所述, OAMH 算法复杂度低于 HSSE 与 GSC-WLP, 相比 MH 仅略有提升,这与各算法运行的实验结果一致。

4.4 实验结论

表 3 中列出了 Set11 图像采样率在 0.1~0.5 之间的平均峰值信噪比 (PSNR) 的实验结果。OAMH 算法的 PSNR 优于 MH 算法,但低于 HSSE 与 GSC-WLP。表 4 列出了 tawsifur 图像集在 0.3 采样率下各算法的平均 PSNR。我们对 tawsifur 图像集内 600 幅图像进行了实验,结果表明,在 tawsifur 异构图像集下, HSSE 和 GSC-WLP 算法 3 类图像的恢复质量均出现明显下降,远低于 MH 与 OAMH 算法。本文所提算法体现出具有竞争力的恢复质量,验证了对于异构图像集,基于内部或外部先验学习的压缩感知重构算法有明显的性能限制。MH 与 OAMH 算法展现出了面向异构图像集的良好泛化性, OAMH 相较于 MH 拥有更好的重构效果,体现了阶数自适应机制的性能增益。图 8 展示了对于图像“Peppers”,采样率为 0.3 时各算法性能的主观比较。可以看到,与 MH 算法相比,所提算法具有更高的视觉质量,在图像

的某些部分,所提算法比 MH, HSSE 和 GSC-WLP 算法具有更高的质量且噪声更少。例如在图 8 中的放大区域, HSSE 与 GSC-WLP 出现了明显的伪影与亮斑, MH 与 OAMH 效果较为良好, 并且 OAMH 并未出现明显的噪声亮斑, 这验证了所提算法的改进作用。图 9 展示了图像“tawsifur_covid19-66”在采样率为 0.1 时不同算法的主观质量对比, 所提算法在恢复 X 光胸片图像时具有更好的效果, HSSE 与 GSC-WLP 算法均出现了大范围模糊的情况, 图 9 中的放大区域边界不明显, X 光胸片的具体细节不清晰, 浅色部分与周围粘连, 大量的斑纹细节被算法隐去, 仅剩余大块同色像素, 表明它们对于各自所用图像集进行了大量优化与拟合, 无法有效提升异构图像集如 X 光胸片图像的重构效果。MH 针对图像自身进行多假设重构, 保留了较多细节。OAMH 效果最佳, 相较于 MH, 其图像分界边缘更加明显, 区域细节消失的问题得到明显缓解。

表 3 不同采样率下 Set11 图像集各算法平均 PSNR

采样率	MH ^[5]	GSC-WLP ^[15]	HSSE ^[16]	OAMH
0.1	24.6465	25.1609	24.84413	24.78269
0.2	28.2716	28.5498	28.53829	28.32808
0.3	30.24411	30.7249	30.61680	30.32516
0.4	31.94079	32.3512	32.39257	32.11741
0.5	33.54771	34.0491	34.03625	33.62347

表 4 Tawsifur 图像集在 0.3 采样率各算法平均 PSNR

methods	tawsifur_covid19	tawsifur_Normal	tawsifur_Viral Pneumonia
MH ^[5]	46.5022	45.6062	45.7509
GSC-WLP ^[15]	45.7079	43.3181	44.7902
HSSE ^[16]	45.9362	43.9163	45.7555
OAMH	46.6127	45.6856	45.8709

表 5 不同采样率下 Tawsifur 代表图像各算法 PSNR/SSIM

Table 5 PSNR/SSIM of various algorithms for Tawsifur representative images at different sampling rates

采样率	算法	tawsifur_covid19				tawsifur_Normal			tawsifur_Viral Pneumonia		
		10	13	23	34	25	34	38	43	103	118
0.1	MH ^[5]	40.4390	42.7279	42.1695	42.4533	37.5733	37.4945	36.1263	36.5011	36.6969	36.8407
		0.9628	0.9714	0.9798	0.9723	0.9574	0.9550	0.9432	0.94710	0.9451	0.9471
	GSC-WLP ^[15]	38.9803	41.3443	40.9435	40.9936	36.4862	36.3436	35.0932	35.5355	35.6042	35.8337
		0.9505	0.9624	0.9733	0.9639	0.9453	0.9422	0.9268	0.9322	0.9291	0.9320
	HSSE ^[16]	40.5136	42.6678	42.1795	42.5192	37.7082	37.3559	36.2084	36.7352	36.8244	36.9124
		0.9627	0.9706	0.9797	0.9724	0.9583	0.9563	0.9483	0.9484	0.9464	0.9476
	OAMH	40.6490	42.7916	42.1824	42.6089	37.7924	37.4161	36.2213	36.8012	36.8912	37.0763
		0.9640	0.9717	0.9803	0.9729	0.9588	0.9559	0.9483	0.9491	0.9466	0.9482
0.2	MH ^[5]	44.5310	46.2922	45.9684	46.1156	41.7184	41.5486	40.3451	40.8135	40.8778	40.8815
		0.9821	0.9853	0.9890	0.9858	0.9793	0.9782	0.9726	0.9760	0.9741	0.9740
	GSC-WLP ^[15]	41.6398	43.1341	43.664	43.2684	40.2934	40.0079	38.7415	39.2768	39.1369	39.2639
		0.9723	0.9741	0.9841	0.9785	0.9692	0.9671	0.9574	0.9615	0.9590	0.9597
	HSSE ^[16]	44.2093	45.5365	45.9963	45.7243	41.2351	40.0144	39.8362	40.4645	40.2229	39.3951
		0.9797	0.9820	0.9882	0.9839	0.9801	0.9794	0.9739	0.9759	0.9750	0.9753
	OAMH	44.6926	46.4434	46.1046	46.1756	41.7942	41.6187	40.4433	40.9512	40.9862	41.0034
		0.9823	0.9875	0.9892	0.9861	0.9794	0.9785	0.9730	0.9770	0.9747	0.9741




图 8 “Peppers”重构图像的主观对比

Fig. 8 Subjective comparison of reconstructed image for “Peppers”




图 9 “tawsifur_covid19-66”重构图像的主观对比

Fig. 9 Subjective comparison of reconstructed image of “tawsifur_covid19-66”

表 5 列出了 0.1~0.5 采样率下, tawsifur 图像集内 3 类不同代表图像的重构 PSNR 值与 SSIM 值, 其中图像 10, 13, 23, 34 来自 tawsifur_covid19; 图像 25, 34, 38 来自 tawsifur_Normal; 图像 43, 103, 118 来自 tawsifur_Viral Pneumonia。每幅图像在 5 种不同采样率下的最大实验结果值用粗体标记。可以清楚地看到, 仅在少数情况下 HSSE 算法优于 MH 算法, 除此之外, HSSE 与 GSC-WLP 算法均较 MH 算法出现明显指标下降, 体现了它们在应对异构图像集方面的缺陷。最后, 所提算法在 tawsifur 图像集图像的重构中, 在所有采样率下均优于 MH, HSSE 与 GSC-WLP 算法, 其 PSNR 值较上述 3 种对比算法平均提升 0.13 dB, 1.16 dB, 1.43 dB, SSIM 值平均提升 0.00023, 0.005162, 0.01034。因此, 该实验验证了 GSC-WLP 和 HSSE 算法在处理异构图像集方面的局限性, 以及 OAMH 算法在异构图像集上的泛化性, 其能在保持较低的时间复杂度前提下, 提升图像恢复质量, 也印证本文的主要工作: 提升压缩感知重构的性能, 并保持 OAMH 算法对异构图像集的泛化性。

(续表)

采样率	算法	tawsifur_covid19				tawsifur_Normal			tawsifur_Viral Pneumonia		
		10	13	23	34	25	34	38	43	103	118
0.3	MH ^[5]	46.7986	48.4985	48.1267	48.2073	44.6214	45.0024	43.7734	45.1371	44.9817	45.3816
		0.9886	0.9905	0.9931	0.9907	0.9878	0.9883	0.9857	0.9881	0.9874	0.9880
	GSC-WLP ^[15]	44.5124	45.2990	46.7381	45.9895	44.6845	44.0763	42.9941	43.5214	43.3004	43.5706
		0.9793	0.9801	0.9883	0.9838	0.9839	0.9833	0.9801	0.9809	0.9797	0.9802
	HSSE ^[16]	46.2616	47.3179	47.9925	47.5850	43.8264	44.3528	45.9231	44.1789	43.8320	44.2221
		0.9861	0.9873	0.9919	0.9886	0.9873	0.9882	0.9863	0.9870	0.9863	0.9870
	OAMH	46.8701	48.5230	48.1457	48.2886	44.6912	45.1251	43.8441	45.1983	45.0531	45.4058
		0.9888	0.9906	0.9932	0.9910	0.9879	0.9893	0.9864	0.9884	0.9876	0.9882
0.4	MH ^[5]	49.3803	50.3635	51.4865	50.6154	48.9917	48.8606	47.5329	47.3793	47.1518	47.59180
		0.9929	0.9935	0.9958	0.9941	0.9943	0.9942	0.9928	0.9923	0.9920	0.99240
	GSC-WLP ^[15]	46.1126	46.6685	48.6715	47.5082	46.3615	46.2275	45.2732	45.2326	45.0194	45.26710
		0.9846	0.9848	0.9914	0.9878	0.9888	0.9885	0.9866	0.9862	0.9855	0.98857
	HSSE ^[16]	48.2266	48.8610	50.7906	49.3114	48.3526	47.2098	46.2612	46.1364	45.9142	46.30310
		0.9904	0.9906	0.9946	0.9918	0.9929	0.9928	0.9919	0.9912	0.9909	0.99140
	OAMH	49.4334	50.4040	51.5335	50.6739	49.0484	48.9325	47.6512	47.4275	47.2298	47.70420
		0.9934	0.9937	0.9960	0.9946	0.9944	0.9948	0.9933	0.9925	0.9922	0.99240
0.5	MH ^[5]	51.1865	52.0124	53.5821	52.3647	50.9844	50.8491	49.6004	49.4166	49.0903	49.58760
		0.9952	0.9954	0.9971	0.9959	0.9962	0.9961	0.9953	0.9950	0.9946	0.99500
	GSC-WLP ^[15]	47.5944	48.1301	50.2028	48.9923	47.9154	47.8163	47.0295	46.9897	47.7231	46.93010
		0.9887	0.9888	0.9936	0.9910	0.9918	0.9916	0.9907	0.9902	0.9897	0.98990
	HSSE ^[16]	49.7979	50.3060	52.3412	50.7721	49.0279	48.9227	48.1685	47.9985	47.7546	48.14750
		0.9931	0.9931	0.9960	0.9939	0.9949	0.9949	0.9945	0.9921	0.9938	0.99410
	OAMH	51.2769	52.0318	53.6376	52.4255	51.1193	50.9252	49.7423	49.4967	49.1578	49.66440
		0.9955	0.9955	0.9973	0.9960	0.9963	0.9964	0.9957	0.9950	0.9947	0.99250

为验证所提算法的泛化性,我们进一步使用 BrainMRI 异构图像集进行类似的实验。所提算法在所有采样率下较 MH, HSSE 与 GSC-WLP 算法的 PSNR 值分别提升 0.25 dB, 1.64 dB, 1.97 dB, 较两种新近提出的算法平均运行时间缩短 28.6%, 26.1%。这表明所提算法在两个异构图像集下均能保持低复杂度且提升恢复质量。

4.5 消融实验

由于本文提出的阶数自适应压缩感知重构 OAMH 算法含有自适应窗口预测 WALP 模块与 Poamh 模块,为了确定两个模块对最终实验结果的影响,需要进行消融实验。上述两个模块单独参与算法流程,分别进行重构实验。

1) 仅使用 WALP 对搜索窗口大小变化进行评估,获得需要改变窗口大小的预测块,并对其进行搜索窗口大小的改变。

2) 跳过 WALP 模块,直接增大 MH 算法中所有块的搜索窗口大小,并在增大后的搜索窗口大小内根据块间欧几里得距离搜索与原算法相同数量的高相似预测块,参与算法流程。

从 tawsifur 图像集中随机挑选 100 幅图像进行实验。由表 6 可知,消融实验 1 中的算法性能提升有限,在低采样率下性能虽有提升,但仍无法达到 OAMH 算法的恢复质量;在高采样率下趋近 MH 算法的 PSNR 值,但低于 OAMH 算法的 PSNR 值。这说明在运行到此模块后需要进一步对搜索窗口内的预测块进行挑选,以获取更精准的图像信号集合。而消融实验 2 扩大了预测块的搜索窗口,出现 PSNR 明显下降的情况,尤其在高采样率下性能远低于其他算法,原因是其引入了过多不必要的冗余像素,这也印证了 3.2 节中的理论分析:并没有过多的块需要进行窗口大小改变。综上所述,参与消融实验的两个模块是相辅相成的递进关系,在 WALP 模块进行初步判定后,使用 Poamh 模块对预测块进行选择才能达到最佳性能。

表 6 消融实验中不同算法的平均 PSNR

Table 6 Average PSNR of various algorithms in ablation experiments

采样率	MH ^[5]	消融实验 1	消融实验 2	OAMH
0.1	38.82395	39.02194	38.62395	39.09194
0.2	43.13885	43.21885	42.90885	43.27742
0.3	45.66947	45.66947	45.34947	45.84947
0.4	49.16988	49.16988	48.70880	49.25340
0.5	51.14850	51.14850	50.78432	51.20260

结束语 基于多假设预测的压缩感知重构算法通常利用图像内部或外部先验进行压缩感知信号的重构恢复,并对所用图像集进行了参数优化,在处理与自然图像异构的图像集时恢复质量可能会下降。而多假设预测机制使用块周围像素进行迭代重构恢复,具有较好的泛化性,不针对某一特定图像集,但也存在预测模型阶数固定的问题。所提 OAMH 算法通过窗口自适应线性预测器,改变搜索窗口和候选预测块,实现了比 MH 算法更高的图像恢复质量,时间复杂度仅略微增加。与新近提出的算法 HSSE 和 GSC-WLP 相比,所提算法具有较低的时间复杂度、较高的恢复质量,综合性能更佳。

参考文献

- [1] DO T T, TRAN T D, GAN L. Fast compressive sampling with structurally random matrices[C] // 2008 IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2008:3369-3372.
- [2] GAN L. Block compressed sensing of natural images[C] // 2007 15th International Conference on Digital Signal Processing. IEEE, 2007:403-406.
- [3] MUN S, FOWLER J E. Block compressed sensing of images using directional transforms[C] // 2009 16th IEEE International Conference on Image Processing (ICIP). IEEE, 2009:3021-3024.

- [4] FOWLER J E, MUN S, TRAMEL E W. Multiscale block compressed sensing with smoothed projected landweber reconstruction[C]// 2011 19th European Signal Processing Conference. IEEE, 2011: 564-568.
- [5] CHEN C, TRAMEL E W, FOWLER J E. Compressed-sensing recovery of images and video using multihypothesis predictions [C]// 2011 Conference Record of the forty fifth Asilomar Conference on Signals, Systems and Computers (ASILOMAR). IEEE, 2011: 1193-1198.
- [6] LIU H, SUN R. Iterative progressive-hypothesis prediction for forward interframe reconstruction of video compressive sensing [C]// 2022 IEEE 24th International Workshop on Multimedia Signal Processing (MMSP). IEEE, 2022: 1-6.
- [7] GU H, YAMAN B, MOELLER S, et al. Revisiting ℓ_1 -wavelet compressed-sensing MRI in the era of deep learning[J]. Proceedings of the National Academy of Sciences, 2022, 119(33): e2201062119.
- [8] ZHA Z, WEN B, YUAN X, et al. Image restoration via reconciliation of group sparsity and low-rank models[J]. IEEE Transactions on Image Processing, 2021, 30: 5223-5238.
- [9] FENG Z, ZHOU Y, ZUO M J, et al. Atomic decomposition and sparse representation for complex signal analysis in machinery fault diagnosis: A review with examples [J]. Measurement, 2017, 103: 106-132.
- [10] ZHA Z, YUAN X, ZHOU J, et al. Image restoration via simultaneous nonlocal self-similarity priors[J]. IEEE Transactions on Image Processing, 2020, 29: 8561-8576.
- [11] ZHANG J, ZHAO D, GAO W. Group-based sparse representation for image restoration[J]. IEEE Transactions on Image Processing, 2014, 23(8): 3336-3351.
- [12] XU J, ZHANG L, ZUO W, et al. Patch group based nonlocal self-similarity prior learning for image denoising[C]// Proceedings of the IEEE International Conference on Computer Vision. IEEE, 2015: 244-252.
- [13] ZHA Z, YUAN X, WEN B, et al. From rank estimation to rank approximation: Rank residual constraint for image restoration [J]. IEEE Transactions on Image Processing, 2019, 29: 3254-3269.
- [14] GU S, ZHANG L, ZUO W, et al. Weighted nuclear norm minimization with application to image denoising[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2014: 2862-2869.
- [15] ZHA Z, YUAN X, WEN B, et al. A benchmark for sparse coding: When group sparsity meets rank minimization[J]. IEEE Transactions on Image Processing, 2020, 29: 5094-5109.
- [16] ZHA Z, WEN B, YUAN X, et al. A hybrid structural sparsification error model for image restoration[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(9): 4451-4465.
- [17] KALLUMMIL S, KALYANI S. Generalized residual ratio thresholding[J]. Signal Processing, 2022, 197: 108531.
- [18] KULKARNI K, LOHIT S, TURAGA P, et al. Reconnet: Non-iterative reconstruction of images from compressively sensed measurements[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 449-458.
- [19] CHOWDHURTY M E H, RAHMAN T, KHANDAKAR A, et al. Can AI help in screening viral and COVID-19 pneumonia? [J]. IEEE Access, 2020, 8: 132665-132676.
- [20] MENZE B H, JAKAB A, BAUER S, et al. The multimodal brain tumor image segmentation benchmark (BRATS) [J]. IEEE Transactions on Medical Imaging, 2014, 34(10): 1993-2024.



ZHENG Yongxian, born in 2000, post-graduate, is a member of CCF (No. P8454G). His main research interest is image compression sensing.



LIU Hao, born in 1977, associate professor, is a member of CCF (No. 26679M). His main research interests include multimedia signal processing and intelligent sensing system.

(责任编辑:杨雪敏)