

面向分块压缩感知的交叉子集导引自适应观测

田伟¹ 刘浩^{1,2} 陈根龙¹ 宫晓蕙¹

1 东华大学信息科学与技术学院 上海 201620

2 人工智能教育部重点实验室 上海 200240

(2903502388@qq.com)

摘要 相比传统的图像信号处理方法,分块压缩感知能够以较低的复杂度实现图像信号的采集与编码,这为功耗受限的无线传感设备提供了一种较为理想的选择方案。针对传感图像的分块压缩感知,提出了一种结合螺旋顺序的交叉子集导引自适应观测方法,通过为不同区域分配与其内容大小相适应的采样率,并且融入观测块预测,可以在提高图像重构质量的同时提升观测块的编码效率。所提方法以一幅图像的中心块为起点,采用螺旋式扫描顺序,将图像平均分成内区、中区、外区3个区域,将每个区域每隔若干块放入交叉子集,3个区域的交叉子集块以基本采样率进行采样观测,根据得到的观测数据结果按权重自适应分配不同的采样率给3个区域的剩余子集,剩余子集分别采用给定的自适应采样率进行采样观测。此外,对于每一个剩余子集中的观测块,所提方法自适应地扩大该观测块的周围邻域来寻找最佳预测块,对预测差值进行标量量化。实验结果表明,与目前比较流行的观测方法相比,所提方法不仅可以在主观上改善图像重构质量,还可以在客观上将图像重构的平均率失真性能至少提升3.2%。

关键词:分块压缩感知;自适应采样率;交叉子集;剩余子集;块预测;率失真

中图分类号 TN919.8

Cross Subset-guided Adaptive Measurement for Block Compressive Sensing

TIAN Wei¹, LIU Hao^{1,2}, CHEN Gen-long¹ and GONG Xiao-hui¹

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

2 Key Laboratory of Artificial Intelligence, Ministry of Education, Shanghai 200240, China

Abstract Compared with traditional image processing methods, the block compressive sensing can concurrently finish both acquisition and compression with a very low complexity, which will be an ideal choice for some wireless sensors with limited power. For block compressive sensing of any image, this paper proposes a cross subset-guided adaptive measurement method. The proposed method can adaptively allocate its sampling subrate to different regions, and also introduce the spatial prediction of measurement blocks, which effectively improves the quality of image reconstruction and the coding efficiency of measurement blocks. Specifically, starting from the center block in the spiral scanning order, all blocks of any image are divided into three regions: inner region, middle region, and outer region. Every few blocks of each region are put into a cross subset. Firstly, these blocks of each cross subset are measured by the same measurement matrix at a basic sampling subrate. Secondly, according to the cross-subset measurement values of three regions, their weights are used to assign different sampling subrates for the remaining subset. Thirdly, the remaining-subset blocks of the three regions are measured by different sampling subrates, which are proportional to their weights. For each measurement block, the optimal predictive block is found from the surrounding area of the measurement block, and the difference between them is quantized by scalar quantization. The experimental results show that compared with the existing measurement methods, the proposed method not only improves the subjective quality of reconstructed image, but also improves the average rate-distortion performance of image reconstruction by at least 3.2%.

Keywords Block compressive sensing, Adaptive sampling subrate, Cross subset, Remaining subset, Block prediction, Rate distortion

到稿日期:2020-08-28 返修日期:2020-09-25 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:上海市自然科学基金项目(18ZR1400300);人工智能教育部重点实验室开放基金

This work was supported by the Natural Science Foundation of Shanghai (18ZR1400300) and Foundation of Key Laboratory of Artificial Intelligence, Ministry of Education, P. R. China.

通信作者:刘浩(liuhao@dhu.edu.cn)

1 引言

众所周知,在以奈奎斯特(Nyquist)采样定理为基础的传统数字信号处理框架下,若要从采样得到的离散信号中无失真地恢复模拟信号,采样速率必须是信号带宽的两倍以上。然而,随着人们对信息需求量的不断增加,用以携带信息的信号具有越来越大的带宽。因此,根据 Nyquist 采样定理对信号进行采样,要求的采样率也变得越来越高,而信号离散化后产生的大量数据给存储、传输、处理也带来了巨大的压力。

压缩感知(Compressed Sensing, CS)理论^[1-3]是近年来信号处理领域出现的一种新的信号处理理论,用于解决大数据量数字信号处理带来的难题,极大地吸引了相关研究人员的关注。

压缩感知理论指出,对于稀疏的或可压缩的信号,采用线性随机观测方法获取少量的观测数据,再利用非线性的优化计算方法就可以精确地重构信号。对于稀疏信号,可以先以低采样率观测再优化重构的本质原因在于:相比待恢复信号的维度,该信号在某一个空间中的自由度较小(或具有稀疏性)^[3]。

压缩感知中信号的稀疏性也同样适用于可压缩的数字图像信号^[4]。假设采集到的图像信号数据 $\mathbf{x} \in \mathbf{R}^N$ (N 为图像像素总数),在压缩感知观测端,只需要线性观测获取 M 个观测数据 $\mathbf{y} \in \mathbf{R}^M$ ($M \ll N$) 即可,观测过程如下:

$$\mathbf{y}_{M \times 1} = \Phi_{M \times N} \mathbf{x}_{N \times 1} = \Phi_{M \times N} \Psi_{N \times N} \mathbf{s}_{N \times 1} \quad (1)$$

其中, \mathbf{s} 是数字图像 \mathbf{x} 在某个稀疏基 Ψ 中的系数表示,这个稀疏基可以是 DCT 域或小波变换域等。随着图像尺寸的增大,图像压缩感知的观测和重构的复杂度也会迅速增大,一种有效的解决方法是将整幅图像分为多个非重叠图像子块^[5],对它们分别进行观测和重构,最后合成一幅完整的全局图像。

很多研究认为应分配给每一个图像子块固定相同的采样率,但是图像不同区域所包含信息的丰富程度不同,分配相同的采样率显然是缺乏考虑的。理论上来说,应当给包含信息更丰富的图像区域分配更大的采样率,而为那些信息较为缺乏的区域分配较小的采样率,这样就能在保持分配大致相同的观测块数目的同时,获取质量更优的全局图像。

在前面的工作中,很多人认为观测过程发生在一个观测硬件设备中,输入高维的原始数据,输出得到低维的观测数据。因此,观测过程可以看作同时对数据进行采集和压缩。然而,从严格的信息理论分析来看,该观测过程并不能算是真正的数据压缩,因为观测设备并没有获取到低维数据的数据比特流,所以这只能算是一种数据降维方法^[6]。在真正的压缩感知中,观测硬件设备可以从观测端输入的高维数据中获取最终的输出数据比特流,而这个过程需要结合量化器和熵编码器。如果缺乏量化这个步骤,那么得到的观测数据将无法进行有效的存储、传输和处理。目前有大量的工作致力于提升观测数据的量化表现。一种最简单的解决方案是直接对标量量化器应用于压缩感知传感设备来获取观测数据。然而,这种简单的解决方案忽略了压缩感知特性和数据特性,在恢复信号率失真性能上表现得很糟糕^[6-7]。

为解决上述问题, Mun 等^[6]提出了一种将简单的均匀标量量化(Scalar Quantization, SQ)与压缩感知观测的差分脉冲编码调制(Differential Pulse code Modulation, DPCM)结合的量化框架,它适用于基于图像分块的压缩感知^[5]。具体来说, DPCM 将先前的图像块视为预测块,并在观测域中用当前观测块减去预测块,但并不是直接将标量量化器应用于观测过程来获取观测块,而是对所得到的残差结果进行标量量化。实验结果证明,用于量化压缩感知的简单 DPCM 加上 SQ 方法可以大幅度提高重构图像的率失真性能。但是,由于其只利用上一个图像块作为当前图像块的预测块,并没有充分利用到自然图像的空间相关性。

受视频流编码中帧内预测的启发, Zhang 等^[7]和 Dinh 等^[8]极大地扩展了先前的工作,并提出了一种新的基于块的图像压缩感知编码策略,称为空间定向预测编码(Spatially Directional Predictive Coding, SDPC),它有效地利用了自然图像内在的空间相关性。对于压缩感知中采样观测得到的每个观测图像子块,其最佳预测块是从一组多个候选预测块中选择的。这些候选预测块是由当前图像块周围 4 个指定方向的预测模式生成的。

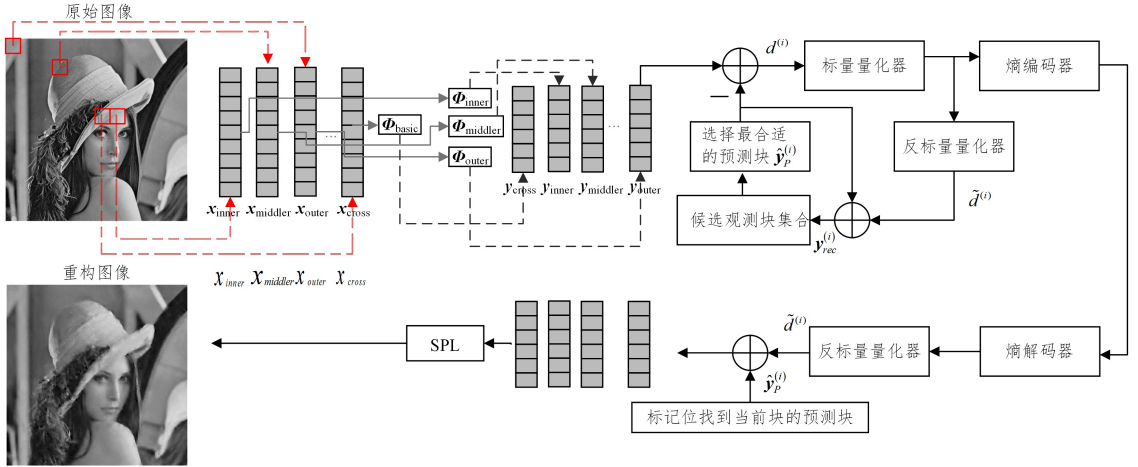
接着, Li 等^[9]提出了一种中值滤波器预测量化(Median Filter based Predictive Quantization, MFPQ)方法,它将当前观测图像块周围邻域几个观测块的中值,作为当前观测块的最佳预测块。尽管该方法的重构图像率失真性能略低于 SDPC,但 MFPQ 的计算复杂度也低于 SDPC,并且考虑到了实际传输过程中可能出现的丢包问题,因此在重构端可以实现更好的错误恢复能力。

考虑到实际工程中的应用, Zhou 等^[10]提出了一种压缩感知观测算法,可以生成一系列与当前基于压缩感知的 CMOS 图像传感器体系结构兼容的确定性三元观测矩阵^[11]。其生成的观测矩阵由近似 DCT 推导而来,因此观测得到的数据可以保持能量紧凑特性。与随机性的二进制或三进制观测矩阵相比,该观测矩阵显著提高了图像重构质量并大大降低了传输比特率。他们同时提出了适用于确定性三元观测矩阵的矩阵行操作,用于压缩感知中观测块的预测。这种行操作能够在保持帧内预测模式^[12-14]的同时,无需构造新的行,这样就可以进一步压缩观测数据而不会降低重构图像质量。

近年来,随着神经网络深度学习的发展,不少人尝试将压缩感知与深度学习模型相结合。Chen 等^[15]提出了一种渐进式多层残差神经网络量化方案,通过将压缩感知观测数据划分为多层神经网络,并根据其先前所有层的观测数据预测特定层的观测数据,将压缩感知观测数据转换为更易于压缩的多层神经网络残差系数。通过计算量化的真实压缩感知观测数据与其对应的量化预测观测值之间的残差,并使用霍夫曼编码将每个残差量化值与二进制码字相关联,来有效地减少压缩感知观测数据之间的冗余。但是,该方法存在的弊端是很难有效训练出适用于所有图像的泛化的残差网络系数,并且相比传统的观测端算法,计算复杂度较大。

Tian 等^[16]提出了一种螺旋预测编码(Spiral Predictive Coding, SPC)算法,即以图像块的中心为起点,采用螺旋式扫

描顺序进行多方向预测编码。在 SPC 算法的基础上,本文进一步提出了交叉子集引导自适应观测(Cross Subset-guided Adaptive Measurement, CSAM)算法,并从以下两个方面进一步提升了图像压缩感知观测端的性能:1)给不同的图像子块分配更加合理的采样率,即给图像中信息度丰富的区域分配更大的采样率,反之,给图像中信息度贫乏的区域分配较小的采样率。2)自适应地扩大搜索每一个观测块的周围邻域,分为模式 I 与模式 II。基于模式 I 的 CSAM 算法从当前图像块的周围邻域 8 个可能的观测块中寻找最佳预测块,称为



注: Φ_{basic} 是观测矩阵, Φ_{inner} , Φ_{mid} , Φ_{outer} 分别是自适应计算得到的内区、中区、外区剩余子集的观测矩阵, SPL 是图像重构算法

图 1 基于观测块预测的分块压缩感知的整体架构

Fig. 1 Overall architecture of block compressed sensing based on measurement block prediction

本文第 2 节简要介绍图像分块压缩感知;第 3 节详细描述本文提出的结合螺旋顺序的图像分块压缩感知的交叉子集自适应观测和扩大图像块预测域的预测方法;第 4 节用实验结果验证本文方法的优越性;最后总结全文。

2 图像分块压缩感知

如果一个信号在它的频域或其他相关域是稀疏的,压缩感知理论认为这个信号可以从它的线性观测数据中精准重构得到,并且该信号的观测数据量要远远少于原始信号数据量。具体来说,假设有一个原始图像 $x \in \mathbf{R}^N$ (N 为图像像素总数),通过观测矩阵获得它的观测数据如式(1)所示:

$$y = \Phi x \quad (1)$$

其中, Φ 是一个 $M \times N$ 大小的观测矩阵,其中 M 远远小于 N 。在重构端,可以通过重构算法从少量观测数据中重构恢复到原始信号^[6]。

在实际应用中,为了避免观测矩阵存储空间较大,并且降低压缩感知中观测和重构的复杂度,一般将图像分成多个互不重叠的图像子块,那么观测端中使用的观测矩阵数据量将会相应减少,每一个图像子块逐一通过这个轻量级观测矩阵进行采样观测。具体来说,一幅图像 $x \in \mathbf{R}^N$ 首先沿横向或纵向被逐个划分成 n 个大小为 $B \times B$ 的图像子块,将图像子块用向量表示为 $x^{(i)} \in \mathbf{R}^{B^2}$, $i=1, 2, \dots, n$ 。然后,执行式(2)所示的观测过程,得到相应的观测块数据 $y^{(i)}$ 。

$$y^{(i)} = \Phi_B x^{(i)} \quad (2)$$

其中, $y^{(i)} \in \mathbf{R}^{M_B}$, Φ_B 是一个大小为 $M_B \times B^2$ 的观测矩阵,观测

CSAM-I 算法;基于模式 II 的 CSAM 算法从当前图像块的周围邻域 16 个可能的观测块中寻找最佳预测块,称为 CSAM-II 算法。

本文提出的 CSAM 方法的总体架构如图 1 所示,其中包括压缩感知中观测端的采样率计算、观测采样、量化、编码。在重构端中,通过解码、反量化、重构恢复得到重构图像。本文的重点在于自适应观测采样和改善观测块的量化表现,可以在提高重构图像质量的同时,提升重构图像的率失真性能。

过程中采样率为 $S = M_B / B^2$ 。因此,容易得出结论:将小数数据量的观测矩阵 Φ_B 应用到每一个图像子块等同于整幅图像被观测矩阵 Φ 观测, Φ 可以由 n 个观测矩阵 Φ_B 沿对角矩阵组合得到。

3 交叉子集引导自适应观测

本文方法是对文献[15]的拓展,即基于螺旋式扫描顺序的分块图像压缩感知。文献[15]从一幅图像的中心图像块出发,以螺旋式扫描顺序获得整幅图像的非重叠子块。相比传统的光栅扫描顺序,该方法可以显著减小图像边缘块对重构图像质量的影响。

3.1 剩余块集的采样率分配

由于图像块的各个区域包含信息的丰富度不同,可以考虑给不同的区域分配不同的采样率,即为信息度较为丰富的图像区域分配较大的采样率,而为信息度贫乏的图像区域分配较小的采样率,具体步骤如下:

步骤 1 如图 1 所示,输入一幅图像 $x \in \mathbf{R}^N$, 其被分成 n 个非重叠图像子块,子块大小为 $B \times B$ 。将按螺旋式扫描顺序得到的图像子块 $Image = \{x^1, x^2, x^3, \dots, x^n\}$ 平均分成内区 $Inner = \{x^1, x^2, x^3, \dots, x^{\frac{n}{3}}\}$ 、中区 $Middler = \{x^{\frac{n}{3}+1}, \dots, x^{\frac{2n}{3}}\}$ 、外区 $outer = \{x^{\frac{2n}{3}+1}, \dots, x^n\}$ 这 3 个区域,在每个区域中每隔 K 块取出图像子块,放入交叉子集 $InnerCross = \{x^1, x^4, x^{2k}, \dots, x^{\frac{n}{3}}\}$, $MiddlerCross = \{x^{\frac{n}{3}+1}, x^{\frac{n}{3}+k}, x^{\frac{n}{3}+2k}, \dots, x^{\frac{2n}{3}}\}$, $OuterCross = \{x^{\frac{2n}{3}+1}, x^{\frac{2n}{3}+k}, x^{\frac{2n}{3}+2k}, \dots, x^n\}$, 并将剩下的各个区域图像子块

放入各个区域的剩余子集。

步骤2 为3个交叉子集中的图像子块分配相同的基本采样率 S_0 。经过相同观测矩阵 Φ_0 观测,得到各个区域交叉子集的观测块。

步骤3 在采样观测完交叉子集的所有块之后,采样率分配器保持固定的总观测数目,为3个不同区域分别分配其自适应采样率,即分别计算3种块类别(内区、中区、外区)交叉子集观测值向量的均值,得到均值向量矩阵 $\delta = [\delta_1, \delta_2, \delta_3]$ 。其中, δ_j 为交叉子集中第 j 种类别的所有观测值向量的均值向量, $j \in \{1, 2, 3\}$ 。由于各个区域交叉子集块与剩余子集块具有近似的统计特性,观测端可以根据交叉子集中观测值向量的统计情况为剩余子集块设置不同的优化采样率。根据内区、中区、外区3种块类别的均值加权,每种块类别对应的区域中剩余子集块按 $S_j = \min \left\{ \max \left(\frac{\|\delta_j\|_1}{\sum \|\delta_j\|_1} \times S_0, S_{\min} \right), 1.00 \right\}$ 新分配优化的自适应采样率,其中 $\|\cdot\|_1$ 是 l_1 范式,用于计算一个向量中所有元素的绝对值之和, S_{\min} 是允许的最小采样率。

步骤4 分别计算得到内区、中区、外区剩余子集块的采样率,将不同区域剩余子集块按照其分配的自适应采样率采样观测得到图像观测块。对于不同的区域,每个剩余子集观测块均采用下文的方法,来扩大当前观测块的周围邻域搜索范围,搜索得到最佳预测块,从而提高观测端的编码效率。

3.2 扩大范围的观测块预测

由于图像子块之间并不是独立的,单个图像子块与其周围邻域存在某种空间联系关系,很容易联想到每一个图像子块的观测数据与它周围邻域图像子块的观测数据也存在某种联系。进一步地,由于图像的静态特性,每一个图像子块与它周围图像子块相联系的关系或大或小。在之前的工作中,一般是当前图像子块的周围邻域4个图像子块中选择最佳预测块,这也许并不合适,因为最合适的预测块可能并不存在于当前图像子块的周围邻域的4个观测块中。通过自适应地扩大搜索当前图像子块的周围邻域范围,使当前图像子块获取到更加准确的预测块,必然会提高编码的效率,详细步骤如图2所示。

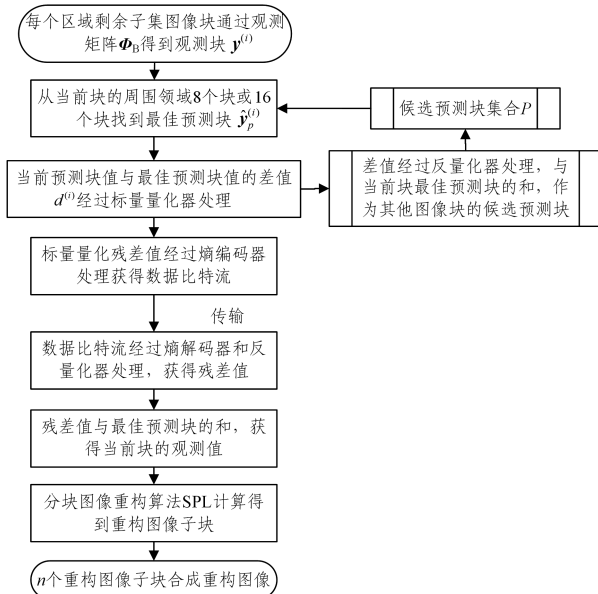


图2 扩大范围的观测块的预测方法详细流程图

Fig. 2 Detailed flow chart of prediction method for extended measurement block

步骤1 对于从不同区域剩余子集块中得到的观测块,借鉴H.264视频流中帧内预测的思想,本文方法从当前图像子块的周围8个块或16个块中寻找最佳预测块。它们的预测模式如图3和图4所示。




图3 从当前子块的周围8个方向选择最佳预测块模式

Fig. 3 Selecting the best prediction block mode from 8 directions around current image sub block




图4 从当前子块的周围16个方向选择最佳预测块模式

Fig. 4 Selecting the best prediction block mode from 16 directions around current image sub block

如果选择从当前图像子块的周围邻域的8个块中选择最佳预测块,则定义候选预测块集合 $P = \{\hat{y}_1^{(i)}, \hat{y}_2^{(i)}, \hat{y}_3^{(i)}, \dots, \hat{y}_8^{(i)}\}$ 。如果选择从当前图像子块周围邻域的16个块中选择最佳预测块,则定义候选预测块集合 $P = \{\hat{y}_1^{(i)}, \hat{y}_2^{(i)}, \hat{y}_3^{(i)}, \hat{y}_4^{(i)}, \dots, \hat{y}_{16}^{(i)}\}$ 。无论选择哪种模式,如式(3)所示,我们在每个候选预测块与当前观测块的差值绝对值中,选择绝对值最小的预测块作为当前图像子块的最佳预测块 $\hat{y}_p^{(i)}$ 。

$$\hat{y}_p^{(i)} = \arg \min_{y \in P} \|y - y^{(i)}\|_{l_1} \quad (3)$$

其中, $\|\cdot\|_{l_1}$ 是 l_1 范式,将向量中每个值取绝对值求和得到。与文献[7-10]相比,我们可以获得更加准确的预测块。

步骤2 获得当前图像子块的最佳预测块 $\hat{y}_p^{(i)}$ 后,将当前观测块与最佳预测块相减得到差值 $d^{(i)} = y^{(i)} - \hat{y}_p^{(i)}$ 。将差值用标量化器处理,得到差值的量化值 $s^{(i)}$,如式(4)所示:

$$s^{(i)} = Q[d^{(i)}] \quad (4)$$

使用观测域差值进行量化而不是直接将图像子块的观测数据进行量化,肯定会减少观测数据量的处理次数。若当前观测块的预测值越准确,差值越小,则编码效率就越高。差值量化值 $s^{(i)}$ 进一步经过熵编码器的编码处理,减少了观测域数据冗余,获得最终的数据比特流,以便传输到重构端进行重构处理。

步骤3 将差值量化值 $s^{(i)}$ 反量化得到的差值 $\tilde{d}^{(i)}$,与当前图像子块的最佳预测块 $\hat{y}_p^{(i)}$ 相加的和 y_{rec} ,用于其他图像子块预测编码。

步骤4 将在观测端中获得的数据比特流传输到重构端。传输的数据分为两部分:1)当前图像子块的标志位,它可以告诉重构端,当前图像子块的观测块可由它周围的哪一个预测块恢复得到;2)差值 $d^{(i)}$ 经过标量化器、熵编码器得到的数据比特流。

步骤5 与观测端相反,重构端通过解码和反量化数据

比特流获得残差,加上当前图像子块的最佳预测块值,获得图像子块的压缩感知观测数据,采用压缩感知重构算法获得最终的重构图像。

为了验证提出的扩大范围的观测块预测方法的优越性,我们可以用当前图像子块的观测数据与最佳预测块的相关系数来证明。与压缩感知中其他的观测算法(MFPQ, DPCM, SDPC)相比,本文方法能够得到更加准确的预测块,相关系数如式(5)所示:

$$\rho(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \frac{\mathbf{x}^{(i)T} \mathbf{x}^{(j)}}{\|\mathbf{x}^{(i)}\| \|\mathbf{x}^{(j)}\|} \quad (5)$$

对于每一个图像子块, MFPQ 算法计算周围邻域块的中值作为当前图像子块的最佳预测块; DPCM 算法将当前图像子块的上一个图像子块作为当前图像子块的最佳预测块; SDPC 算法从当前图像子块的周围邻域的 4 个观测块中寻找最佳预测块; 本文方法则是扩大当前图像块的领域搜寻范围, 从当前图像子块的周围邻域的 8 个观测块或 16 个观测块中寻找最佳预测块。在本文的验证实验中, 采用 3 幅 512×512 大小的测试图像(Lenna, Peppers, Clown), 图像子块的大小为 8×8 , 平均观测采样率分别设置为 0.1, 0.3, 0.5。对于本文方法(CSAM-I, CSAM-II), 在实验中每隔 K 个图像块将该块放入交叉子集中, K 值设为 16, 交叉子集中的图像块以相同的固定采样率 $S_0 = 0.1$ 进行采样观测。在验证过程中, 分别计算本文方法(CSAM-I, CSAM-II)和其他 3 种观测方法(MFPQ, DPCM, SDPC)的图像观测块和其最佳预测块的平均相关系数, 实验结果如表 1—表 3 所列, 各种方法的计算复杂度如表 4 所列。本文方法在牺牲常量级的计算复杂度下, 可以在不同的采样率下均获得最佳的平均相关系数, 相比其他流行的观测方法, 至少提高了 1% 的预测准确性。

表 1 采样率为 0.1 时, 不同的观测算法下图像子块的相关系数

Table 1 Correlation coefficients of image sub blocks under different measurement algorithms when sampling rate is 0.1

	Lenna	Peppers	Clown	平均相关系数
DPCM	0.9382	0.9167	0.7662	0.8737
MFPQ	0.9439	0.9218	0.8402	0.9020
SDPC	0.9607	0.9402	0.8154	0.9054
CSAM-I	0.9745	0.9625	0.8382	0.9251
CSAM-II	0.9791	0.9664	0.8429	0.9295

表 2 采样率为 0.3 时, 在不同的观测算法下图像子块的相关系数

Table 2 Correlation coefficients of image sub blocks under different measurement algorithms when sampling rate is 0.3

	Lenna	Peppers	Clown	平均相关系数
DPCM	0.9667	0.9467	0.8217	0.9120
MFPQ	0.9742	0.9549	0.8713	0.9335
SDPC	0.9772	0.9611	0.8615	0.9333
CSAM-I	0.9869	0.9735	0.8833	0.9479
CSAM-II	0.9887	0.9757	0.8928	0.9524

表 3 采样率为 0.5 时, 在不同的观测算法下图像子块的相关系数

Table 3 Correlation coefficients of image sub blocks under different measurement algorithms when sampling rate is 0.5

	Lenna	Peppers	Clown	平均相关系数
DPCM	0.9777	0.9657	0.8828	0.9421
MFPQ	0.9808	0.9649	0.8940	0.9481
SDPC	0.9839	0.9733	0.9046	0.9539
CSAM-I	0.9880	0.9811	0.9271	0.9654
CSAM-II	0.9897	0.9827	0.9350	0.9691

表 4 不同的预测算法下, 每一个图像块找到最佳预测块的计算时间复杂度

Table 4 Under different prediction algorithms, the computing time complexity of each image block to find the best prediction block

Prediction scheme	Multiplications	Additions	Comparisons
DPCM	0	0	0
MFPQ	0	0	$6M$
SDPC	$9M-4$	M	3
CASM-I	$64M-8$	M	8
CASM-II	$256M-16$	M	16

注: M 表示每个图像块的观测数据矢量的长度

4 实验结果

为了验证本文提出的交叉子集导引自适应采样率同时扩大观测域范围的方法, 不仅能够提高重构图像质量, 而且能够提升重构图像的率失真性能, 将本文方法(CSAM-I, CSAM-II)与其他主流观测算法(MFPQ, DPCM, SDPC)进行实验比较, 从主观的重构图像质量视觉评价和客观的重构图像率失真曲线两方面进行比较。为公平起见, 所有观测端的算法计算得到的观测数据在重构端都使用 SPL^[6] 重构算法, 该算法能够提供较为快速的图像重构速度。

在具体的实验实施过程中, 本文方法(CSAM-I, CSAM-II)与其他主流观测算法(MFPQ, DPCM, SDPC)同时测试了 3 幅 512×512 大小的灰度像素值图像(Lenna, Peppers, Clown)。在实验中每种观测算法的图像子块大小设置为 8×8 , 平均观测采样率设置为 0.10~0.50, 间隔为 0.05, 采样观测矩阵均使用正交高斯随机矩阵。特殊地, 对于本文提出的两种方法(CSAM-I, CSAM-II), 需要通过交叉子集导引给剩余子集自适应地分配采样率, 在具体实验中 K 值设为 16, 即每隔 K 个图像块将当前图像块(1, K , $2K$, ...)放入交叉子集块集合, 而对于交叉子集中的图像块, 统一分配基本固定采样率 $S_0 = 0.1$ 进行采样观测, 采样观测矩阵均使用正交高斯随机矩阵。通过在不同比特率(Bitrate)下计算重构图像的峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)^[6], 可以得到率失真曲线。

图 5—图 7 分别是 3 幅灰度图像在采样率为 0.2 时, 利用本文方法(CSAM-I, CSAM-II)和其他主流观测算法(MFPQ, DPCM, SDPC)生成的重构图像。



注: 从上到下、从左到右依次为 DPCM, MFPQ, SDPC, CSAM-I, CSAM-II

图 5 不同观测算法的 Lenna 重构图

Fig. 5 Lenna reconstruction map of different measurement algorithms



注:从上到下、从左到右依次为 DPCM, MFPQ, SDPC, CSAM-I, CSAM-II

图 6 不同观测算法的 Peppers 重构图

Fig. 6 Peppers reconstruction map of different measurement algorithms



注:从上到下、从左到右依次为 DPCM, MFPQ, SDPC, CSAM-I, CSAM-II

图 7 不同观测算法的 Clown 重构图

Fig. 7 Clown reconstruction map of different measurement algorithms

通过直观对比可以看出,在分配大致相同的观测数目时,加入了交叉子集导引自适应采样率的方法后得到的重构图像明显优于未采用自适应采样率的方法。

图 8—图 10 分别是采用本文方法(CSAM-I, CSAM-II)和其他主流观测算法(MFPQ, DPCM, SDPC)时 3 幅灰度图像的重构图像的率失真曲线,其中数据比特率由量化的图像观测块的数据经过熵编码器计算得到。从图中可以看出,在 3 幅实验图像中,本文提出的方法生成的率失真曲线的性能都比主流观测算法的率失真曲线的性能要好。本文算法根据实验数据计算得出,从周围邻域的 8 个观测块中选择最佳预测块的方法能够比当前主流算法的性能至少提升 0.83 dB,而从周围邻域 16 个观测块中选择最佳预测块的方法能够至少提升 1.03 dB。




图 8 不同观测端算法下, Lenna 图像的率失真曲线

Fig. 8 Rate distortion curve of Lenna image under different measurement algorithms




图 9 不同观测端算法下, Peppers 图像的率失真曲线

Fig. 9 Rate distortion curve of Peppers image under different measurement algorithms




图 10 不同观测端算法下, Clown 图像的率失真曲线

Fig. 10 Rate distortion curve of Clown image under different measurement algorithms

通过进一步分析发现,本文提出的自适应观测方法由于将更多的观测数目分配给信息较为丰富的图像区域,减少了分配给信息较为贫乏的图像区域的观测数目,因此能够在保持大致相同的观测数目的同时,提高重构图像的质量。此外,因为扩大了观测块的周围邻域范围来搜寻预测块,所以总是能够找到当前图像块的最准确的最佳预测块,提高了编码效率,从而毫无疑问地取得了最佳的重构图像率失真性能。

结束语 本文提出的面向分块压缩感知的交叉子集导引的自适应采样率和扩大范围搜寻最佳预测块的方法,相比之前压缩感知中主流的观测算法,能够更加合理地分配观测采样率,并且充分利用了图像的空间相关性,能够找到比已有方法更准确的观测预测块。实验结果证明,本文方法能够在保持大致相同的观测块数目的同时,有效提升图像重构质量,并且应用扩大范围的搜寻最佳预测块方法,能够提升预测的准确率,从而提高编码效率,并相应地提高重构图像的率失真性能。

参考文献

- [1] BARANIUK R G, GOLDSTEIN T, SANKARANARAYANAN A C, et al. Compressive video sensing: algorithms, architectures and applications [J]. IEEE Signal Process. Mag, 2017, 34(1): 52-66.
- [2] CANDÉ E J, WAKIN M B. An introduction to compressive sampling [J]. IEEE Signal Process. Mag, 2018, 25(2): 21-30.
- [3] DONOHO D L. Compressed sensing [J]. IEEE Transactions on Information Theory, 2016, 52(4): 1289-1306.
- [4] ZHU M, GAO W, GUO L Q. Application of compressed sensing theory in image processing [J]. Chinese Optics, 2011, 4(5): 441-447.
- [5] GAN L. Block compressed sensing of natural images [C]//

- Proc. International Conference on Digital Signal Processing, Cardiff, 2017; 403-406.
- [6] MUN S, FLOWER J E. Block compressed sensing of images using directional transforms [C] // Proc. International Conference on Image Processing (ICIP). Cairo, IEEE, 2009; 3021-3024.
- [7] ZHANG J, ZHAO D, JIANG F. Spatially directional predictive coding for block based compressive sensing of natural images [C] // International Conference on Image Processing, Melbourne, IEEE, 2013; 1021-1025.
- [8] DINH K Q, SHIM H J, JEON B. Measurement coding for compressive imaging using a structural measurement matrix [C] // 2013 IEEE International Conference on Image Processing, Melbourne, 2013; 10-13.
- [9] LI R, LIU H, HE W. Space-time quantization and motion-aligned reconstruction for block-based compressive video sensing [J]. KSII Trans. Internet Inf. Syst., 2017, 10(1); 321-340.
- [10] ZHOU J, ZHOU D, GUO L, et al. Approximate-DCT-derived measurement matrices with row-operation-based measurement compression and its VLSI architecture for compressed sensing [J]. IEICE Transactions on Electronics, 2018, 101(4); 263-272.
- [11] DADKHAH M, DEEN M J, SHIRANI S. CMOS image sensor with area-efficient block-based compressive sensing [J]. IEEE Sensors Journal, 2015, 15(7); 3699-3710.
- [12] ZHOU J, ZHOU D, GUO L, et al. Framework and VLSI architecture of measurement-domain intra prediction for compressively sensed visual contents [J]. IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, 2017, 100(12); 2869-2877.
- [13] ZHOU J, ZHOU D, GUO L, et al. Measurement-domain intra prediction framework for compressively sensed images [C] // Proc. International Symposium on Circuits and Systems, Baltimore, IEEE 2017; 168-171.
- [14] CHEN Z, HOU X S, SHAO L, et al. Compressive sensing multi-layer residual coefficients for image coding [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(4); 1109-1120.
- [15] CHEN Z, HOU X S, SHAO L, et al. A compressive sensing multi-layer residual coefficients for image coding [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(4); 1109-1120.
- [16] TIAN W, LIU H. Measurement-domain spiral predictive coding for block-based image compressive sensing [C] // 10th International Conference on Image and Graphics, Beijing, Springer, 2019; 3-12.



TIAN Wei, born in 1995, postgraduate, is a member of China Computer Federation. His main research interests include image compression sensing and so on.



LIU Hao, born in 1977, associate professor, is a member of China Computer Federation. His main research interests include multimedia signal processing and intelligent sensing system.