

DOI:10.11918/202310010

融合自适应阈值与 α -ML核函数的双稀疏空域错误隐藏

刘浩, 丘茂基, 周镭, 陈根龙, 燕帅

(东华大学 信息科学与技术学院, 上海 201620)

摘要: 在实时视频流的解码端, 恢复压缩视频时经常出现块丢失现象。空域错误隐藏利用在当前帧中块与块之间的相关性进行受损图像的恢复, 无需其他帧的信息。在众多空域错误隐藏算法中, 稀疏表达机制进一步利用了图像的稀疏性, 与逐点插值机制相比恢复质量更好。当前的稀疏表达算法仍面临候选子区域选取不准、相关模型参数较敏感的难题。为此, 对基于稀疏表达的对偶空间正则框架进行研究, 重点对其中的局部区域匹配和局部线性相关建模两个阶段进行优化, 提出一种融合自适应阈值与 α -ML核函数的双稀疏空域错误隐藏算法。在局部区域匹配阶段, 所提算法设计了一种基于自适应阈值的局部区域匹配方法, 能够灵活地适应特征各异的丢失子区域, 为字典构建和局部线性相关建模提供更准确的观测空间和潜在空间。在局部线性相关建模阶段, 所提算法使用了一种基于 α -ML核函数的核岭回归方法作为局部线性相关模型, 与现有的高斯核函数相比, α -ML核函数参数敏感性更低、灵活性更好。实验结果表明, 在典型的块丢失模式下, 所提算法在恢复质量上高于其他现有的空域错误隐藏算法。

关键词: 错误隐藏; 自适应阈值; 核函数; 区域匹配; 相关模型

中图分类号: TN919.8

文献标志码: A

文章编号: 0367-6234(2025)10-0154-11

Double-sparse spatial error concealment with adaptive threshold and α -ML kernel functions

LIU Hao, QIU Maoji, ZHOU Lei, CHEN Genlong, YAN Shuai

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

Abstract: In the decoder of live video streaming, compressed video often suffers from block loss during recovery. The spatial error concealment utilizes the correlation between blocks in the current frame for the recovery of error image, without requiring information from other frames. Among many spatial error concealment algorithms, sparse representation mechanism further utilizes the sparsity of an image and achieve better recovery quality than pixel-wise interpolation mechanism. The current sparse representation algorithms still face challenges such as inaccurate selection of candidate subregions and parameter sensitivity of correlation model. Therefore, this paper studies the dual space regularization framework according to sparse representation, and focuses on optimizing such two stages as local region matching and local linear correlation modeling in this framework. We proposes a double-sparse spatial error concealment algorithm with adaptive threshold and α -ML kernel function. During the stage of local region matching, the proposed algorithm designs a local region matching method with adaptive threshold, which can flexibly adapt to the missing subregions with different characteristics, and provide more accurate observation space and potential space for dictionary construction and local linear correlation modeling. During the stage of local linear correlation modeling, the proposed algorithm utilizes a kernel ridge regression method with α -ML kernel function as the local linear correlation model. Compared with the Gaussian kernel function, the α -ML kernel function has low parameter sensitivity and good flexibility. Experimental results show that in typical block loss modes, the proposed algorithm outperforms other existing spatial error concealment algorithms in terms of recovery quality.

Keywords: error concealment; adaptive threshold; kernel function; region matching; correlation model

在实时视频流中, 块丢失是常见的现象。与编码端的抗误码技术相比, 解码端的错误隐藏技术无需对编码器作任何调整, 也不增加传输延时, 因而受

到广泛关注^[1]。在错误隐藏技术中, 空域错误隐藏利用当前帧块与块之间的相关性进行受损图像的恢复^[2]; 时域错误隐藏根据视频序列中帧与帧之间的

收稿日期: 2023-10-09; 录用日期: 2023-12-13; 网络首发日期: 2024-06-24

网络首发地址: <https://link.cnki.net/urlid/23.1235.T.20240623.1147.002>

作者简介: 刘浩(1977—), 男, 副教授, 硕士生导师

通信作者: 刘浩, liuhao@dhu.edu.cn

运动连续性来进行图像修复^[3];时空域错误隐藏则是根据当前场景的差异,自适应地选择空域错误隐藏或时域错误隐藏^[4]。空域错误隐藏仅需利用当前帧中正确接收的像素对丢失块进行修复,既适用于单帧图像的修复,也适用于视频的逐帧修复。

现有的空域错误隐藏算法主要分为逐点插值机制和稀疏表达机制。逐点插值机制利用图像特征的局部相关性来恢复缺失像素,如 H. 264 标准就推荐了基于插值的(advanced video coding, AVC)空域错误隐藏算法^[5]。通过改进马尔科夫随机场,王冰等^[6]提出一种基于迭代自适应终止的马尔可夫错误隐藏算法,采用多次迭代的插值方式完成对缺失像素的掩盖。进一步地,王凯巡等^[7]提出一种非迭代收缩多方向预测(non-iterative shrinkage multi-direction, NSM)的空域错误隐藏算法,快速地利用邻域边缘信息来隐藏丢失块。总体而言,这类逐点插值机制对于图像纹理区域的恢复质量较差。

随着信号处理技术的发展,多媒体信号的稀疏表达也被引入空域错误隐藏问题的解决中。通过分层逼近与稀疏约束,Koloda 等^[8]提出了一种基于最小均方误差(kernel-based minimum mean square error, KMMSE)的稀疏线性预测器,使用从核密度估计中获得的概率密度函数来恢复缺失像素。进一步地,Liu 等^[9]采用对偶空间正则(dual space regularization, DSR)算法来恢复丢失区域,为观测空间和潜在空间单独学习自适应字典,训练数据通过自适应局部区域匹配的收集机制,学习一个局部相关模型来桥接上述对偶空间的稀疏表达,但其中的局部区域匹配采用基于固定阈值的欧氏距离方式进行选取,存在候选子区域选取不够准确、降低模型精度的问题。

空域错误隐藏面临的挑战是恢复质量、通用性与算法复杂度的高效折中。近年来,空域错误隐藏在算法复杂度的优化方面取得了一些新的进展。由于逐点插值机制具有较低的复杂度,Hwang 等^[10]提出了一种基于相邻块预测的多方向插值(NEW multi-directional interpolation, NEW-MDI)算法,通过自适应的线性预测器对丢失块进行连续恢复,并根据相邻块上下文自动调整预测方向。此外,低秩矩阵补全也被用于空域错误隐藏,Zhou 等^[11]提出了一种基于动量梯度下降的截断核范数最小化模型优化方法(truncated kernel norm minimization with momentum gradient descend, TKNM-MGD),在迭代

耗时与通用性方面具有一定的优势。

然而近年来,空域错误隐藏在恢复质量方面的提升并不明显。基于稀疏表达的空域错误隐藏算法利用了信号固有的稀疏性,核心步骤是建立合适字典,求解字典的相关稀疏,并最终通过稀疏表达来重建图像。DSR 空域错误隐藏是目前基于稀疏表达算法中效果较好的一种,其框架主要包括子区域划分、恢复顺序确定、局部区域匹配、字典构建、局部线性相关建模和稀疏重构等阶段。本文重点对稀疏表达中的局部区域匹配和局部线性相关模型阶段进行改进,提出了基于自适应阈值的局部区域匹配方法和基于 α -ML 核函数的局部线性相关模型,并总结了融合自适应阈值与 α -ML 核函数的双稀疏(adaptive Minkowski dual sparsity, AM-DS)空域错误隐藏算法的主要流程。最后开展比较实验并对实验结果进行了分析,证明所提 AM-DS 算法在各类块丢失模式下恢复质量的优越性。

1 所提算法

1.1 基于自适应阈值的局部区域匹配

稀疏表达机制通常利用欧氏距离作为衡量子区域之间相似度的指标,由满足阈值条件的潜在子区域组成的潜在空间 ϕ_x ,由满足阈值条件的观测子区域组成的观测空间 ϕ_y ,其定义分别如下:

$$\phi_x = \{ \mathbf{x}_{ij} \mid \|\mathbf{y}_i - \mathbf{y}_{ij}\|^2 < \tau, \mathbf{x}_{ij}, \mathbf{y}_{ij} \in (S \cup L) \} \quad (1)$$

$$\phi_y = \{ \mathbf{y}_{ij} \mid \|\mathbf{y}_i - \mathbf{y}_{ij}\|^2 < \tau, \mathbf{x}_{ij}, \mathbf{y}_{ij} \in (S \cup L) \} \quad (2)$$

式中: \mathbf{x}_{ij} 表示潜在子区域, \mathbf{y}_i 表示丢失子区域的相邻子区域, \mathbf{y}_{ij} 表示观测子区域, τ 表示阈值, S 表示可用的观测区域, L 表示可用的潜在区域。在当前的 DSR 算法中, τ 是一个固定值,受损图像往往存在多个丢失块,一个丢失块又被分为多个丢失子区域。每个丢失子区域周围区域的像素变化情况不同,使用固定阈值进行筛选,存在筛选得到的各集合元素数差异较大的问题。当筛选得到的潜在子区域过少时,在求解后续局部线性相关模型参数的过程中,存在求解的模型包含有效信息过少的问题;当筛选得到的潜在子区域过多时,则存在模型过拟合、引入较多噪声的问题。基于固定阈值的欧氏距离方式受阈值的影响较大,难以得到最佳阈值,影响了后续字典构建和局部线性相关建模的精度。

如图 1 所示,以 16×16 丢失块大小、规则间隔丢失下的 Lena 图像(256×256)为例,记录执行基于固定阈值的欧氏距离局部区域匹配方式后,各丢失

子区域筛选后得到的潜在子区域数目统计表。实验设置的丢失子区域大小为 2×2 , 前 64 个丢失子区域对应的潜在子区域数目统计情况如图 2 所示, 可以看出, 各丢失子区域筛选后得到的潜在子区域数目差距较大, 某些丢失子区域对应的潜在子区域数目只有一个, 而另一些丢失子区域对应的潜在子区域数目高达数百个。



图 1 规则间隔丢失下的 Lena 图像

Fig. 1 Lena image in regular interval loss




图 2 各丢失子区域对应潜在子区域数目对比图

Fig. 2 Comparison of the number of latent subregions corresponding to each missing subregion

基于以上实验现象, 将第 n 个欧氏距离最小的子区域的像素值作为计算自适应阈值的重要组成部分。其次, 对以相关性系数作为相似度指标的局部区域匹配方法进行性能探究, 计算丢失子区域的相邻子区域和观测子区域之间的相关性系数, 其计算公式如下:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3)$$

式中: \bar{x} 、 \bar{y} 分别为观测子区域和丢失子区域的相邻子区域的像素值的均值。将各组相关性系数从大到小进行排序, 选取前 n 个观测子区域组成观测空间, 对应的前 n 个潜在子区域组成潜在空间。进一步选择 Lena、Leaves 等 7 幅图像, 以选取前 n 个欧氏距离最小的子区域为标准, 建立潜在空间和观测空间, 并以峰值信噪比 (PSNR) 作为恢复质量的客观评价测度^[12], 记录各图像在 16×16 规则间隔丢失下的恢复情况, 如表 1 所示。

表 1 不同子区域数目下图像的 PSNR 值 (相关性系数)

Tab. 1 PSNR values of images with different numbers of subregions (correlation coefficient)

n	PSNR/dB						
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera
10	NaN	NaN	33.08	NaN	NaN	NaN	34.18
20	31.58	NaN	33.54	NaN	28.04	31.03	35.19
30	31.76	NaN	34.39	NaN	28.51	31.18	35.11
40	31.49	NaN	34.12	NaN	28.30	31.00	35.66
50	31.74	24.78	34.09	NaN	28.44	31.08	35.85
60	31.76	NaN	34.15	NaN	28.54	30.99	35.74
70	32.02	NaN	34.14	NaN	28.51	30.98	35.82
80	31.95	NaN	34.23	26.30	28.61	30.92	35.84
90	31.83	24.79	34.24	26.37	28.57	30.94	35.91
100	31.74	24.92	34.35	26.32	28.60	31.00	35.92

由表 1 可知, 当以相关性系数作为相似度指标时, 在大部分场景下仍有较好的恢复质量, 与基于固定阈值的欧氏距离方式相比, 在恢复质量上有一定优势。但是, 基于固定子区域数目的相关性系数方式面临在不同测试集、不同子区域数 n 情况下, 恢复效果不稳定的问题。表 1 中标注为 NaN 的数据代表在该组实验中, 当前算法未能修复所有的丢失子区域, 存在未修复的丢失子区域。结合以上分析, 所提算法设计了如下的自适应阈值公式:

$$\tau = D_{\text{Euc}}(y_i, y, k) - \frac{\sum_{i=1}^n r_{y_i y}}{n} \times w \quad (4)$$

式中: $D_{\text{Euc}}(y_i, y, k)$ 表示第 k 个欧氏距离最小的观测子区域对应的欧氏距离, $\sum_{i=1}^n r_{y_i y}$ 表示丢失子区域的相邻子区域和所有观测子区域间的相关性系数的和, w 为常量。该自适应阈值通过 $D_{\text{Euc}}(y_i, y, k)$ 项对

局部区域匹配得到的候选子区域的数量进行约束, 避免局部区域匹配得到的候选子区域的数量过少或过多, 影响后续字典构建和局部线性相关建模的精度。当 w 为 0 时, 该局部区域匹配方法等价于选取

前 k 个欧氏距离最小的子区域。 $\frac{\sum_{i=1}^n r_{y_i y'}}{n}$ 表示丢失块

附近区域和潜在子区域间的平均相关性系数。当呈负相关时, 说明丢失子区域附近区域与潜在子区域间差异较大, 应适当放宽阈值, 增加候选子区域数

量, 此时 $-\frac{\sum_{i=1}^n r_{y_i y'}}{n} \times w$ 为正, $\tau > D_{\text{Euc}}(y_i, y, k)$ 。反

之, 当呈正相关时, 说明丢失子区域附近区域与潜在子区域相似度较高, 应适当收缩阈值, 减少候选子区

域数量, 此时 $-\frac{\sum_{i=1}^n r_{y_i y'}}{n} \times w$ 为负, $\tau < D_{\text{Euc}}(y_i, y, k)$ 。

至此, 局部区域匹配方法通过衡量区域相关性, 为当前丢失子区域和其相邻子区域寻找相似度最高的若干个潜在子区域和观测子区域。采用欧氏距离作为子区域间的相似度指标, 因丢失子区域的像素值缺失, 无法计算丢失子区域和潜在子区域之间的欧氏距离, 通过先计算丢失子区域的相邻子区域和观测子区域间的欧氏距离, 筛选符合要求的观测子区域组成观测空间, 从而确定对应的潜在子区域, 组成潜在空间。通过计算自适应阈值 τ , 筛选满足要求的潜在子区域和观测子区域组成潜在空间和观测空间, 基于自适应阈值的局部区域匹配方法灵活的适应性质各异的丢失子区域, 为字典构建和局部线性相关建模提供更合适的观测空间和潜在空间, 提高受损图像的恢复质量。

基于自适应阈值的局部区域匹配方法的主要流程如图 3 所示。输入丢失子区域, 对于当前丢失子区域和其对应的相邻子区域, 遍历搜索所有的潜在子区域和观测子区域, 计算每个观测子区域和丢失子区域的相邻子区域间的欧氏距离并进行排序, 记录第 k 个欧氏距离最小的观测子区域的欧氏距离 $D_{\text{Euc}}(y_i, y, k)$, 计算观测子区域与丢失子区域的相邻子区域间的平均相关性系数, 根据自适应阈值公式计算当前丢失子区域的对应自适应阈值, 选取满足阈值条件的观测子区域和潜在子区域, 组成观测空间和潜在空间。最后, 输出当前丢失子区域的观测空间和潜在空间。

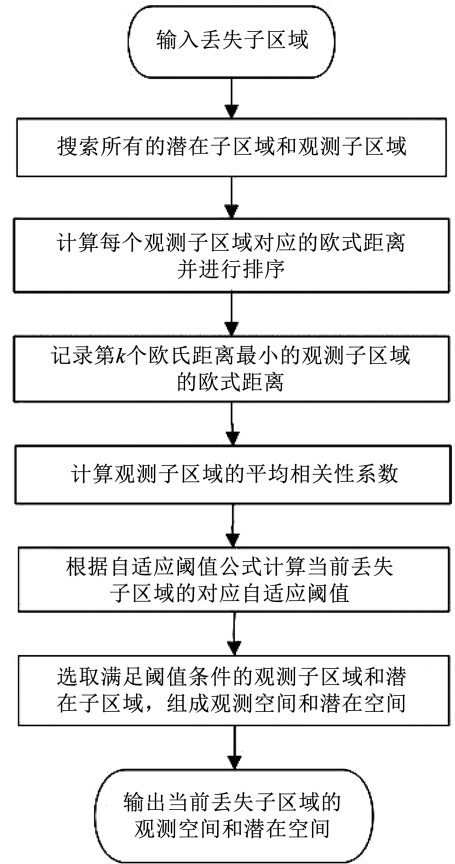


图 3 基于自适应阈值的局部区域匹配流程

Fig. 3 Flowchart of local region matching based on adaptive threshold

1.2 基于 α -ML 核函数的局部线性相关建模

普通的线性回归通过最小化平方误差损失函数得到训练模型, 而核回归通过将核函数作为权重函数建立非线性回归模型。利用核函数计算 x_i 在 x 处的权重, 其中, x_i 为观测数据点, x 为预测的点。DSR 算法采用了核函数中最为常见的高斯核函数。相比高斯核函数, 拉普拉斯核函数对参数的依赖性和敏感性较低。而参数设置敏感正是核岭回归方法的一大缺点, 当参数设置较小时又会为了模型的稳定性而牺牲一定的无偏性。因此, 采用拉普拉斯核函数代替高斯核函数。

在采用基于自适应阈值的局部区域匹配方法的基础上, 对默认参数下分别以拉普拉斯核函数和高斯核函数作为核函数的核岭回归方法在典型场景下的性能进行实验, 分析拉普拉斯核函数和高斯核函数的形式差异, 可以推测与高斯核函数相比, 拉普拉斯核函数对于参数的敏感性较低、模型的鲁棒性较好。除此之外, 当前的核函数的分子大多默认采用欧氏距离。欧氏距离可以看作是闵可夫斯基距离的一种特殊形式, 闵可夫斯基距离并不是一种距离, 而是一类距离, 其定义如下:

$$D_{\text{Euc}}(x, y, \alpha) = \| \mathbf{x}_i - \mathbf{y}_i \|_{\text{M}} = \left(\sum_{i=1}^d | \mathbf{x}_i - \mathbf{y}_i |^{\alpha} \right)^{\frac{1}{\alpha}} \quad (5)$$

当 α 不同时, 闵可夫斯基距离有不同的形式: 当 α 为 1 时, 表示曼哈顿距离; α 为 2 时, 表示欧氏距离; α 趋近于无穷时, 则表示切比雪夫距离。当 α 不同时, 对应的内核也有不同的表现形式。为了增强模型在不同场景下的灵活性, 所提算法采用闵可夫斯基距离代替固定阈值的欧氏距离, 将闵可夫斯基 (Minkowski) 距离形式下的拉普拉斯核函数称为 α -ML 核函数, 其定义如下:

$$\mathbf{k}(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|_{\text{M}}}{\sigma}\right) \quad (6)$$

进一步探究不同 α 时, 闵可夫斯基距离形式下的拉普拉斯核函数对受损图像的恢复作用, 分析核函数对核岭回归以及模型整体性能的影响, 提高算法的灵活性。对 $\alpha = 1, 2, 3, 4, 5, 6$ 下的基于 α -ML 核函数模型的恢复质量进行实验。当 α 为奇数时, 模型的恢复质量较差, 且迭代时间很长。当 α 为偶数时, 实验结果如表 2 所示。可以看出, 在不同图像下有不同的最优 α 值。因此, α -ML 核函数的引入提高了原模型的灵活性, 可在错误隐藏中寻找典型场景下最优的 α 值, 从而提升模型的泛化性能。

表 2 α -ML 核函数不同 α 下图像的 PSNR 值

Tab. 2 PSNR values of images with different α of α -ML kernel functions

α	PSNR/dB						
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera
2	33.07	25.66	33.67	26.24	28.46	31.05	27.24
4	32.50	25.88	34.18	26.35	28.11	31.22	27.11
6	32.29	25.67	34.31	26.33	28.55	30.92	26.99

为了将潜在空间与观测空间之间的关系应用到丢失子区域与丢失子区域相邻的子区域, 需要建立观测空间和潜在空间之间的联系。因为观测空间中任一观测子区域和潜在空间中任一与之对应的潜在子区域在位置上是几何相邻的, 选用局部线性相关模型来建立二者之间的联系。核函数是核岭回归方法中的重要一环, 将闵可夫斯基距离与拉普拉斯核函数结合, 提出了闵可夫斯基距离形式下的拉普拉斯核函数, 即上述 α -ML 核函数。采用 α -ML 核函数代替原有的高斯核函数, 降低了模型对参数的依赖性和敏感性。通过控制自变量 α , 可以灵活控制 α -ML 核函数的形式, 使局部线性相关模型更加灵活, 从而适应各类复杂场景。具体来说, 通过求解以下

的优化问题, 找到最优矩阵 \mathbf{W}_i^* :

$$\mathbf{W}_i^* = \min_{\mathbf{W}_i} \left(\sum_{j=1}^n \mathbf{k}_{ij} \| \mathbf{x}_{ij} - \mathbf{W}_i^T \mathbf{y}_{ij} \|_2^2 + u \| \mathbf{W}_i \|_F^2 \right) \quad (7)$$

式中: $\| \mathbf{W}_i \|_F^2$ 表示 \mathbf{W}_i 的 Frobenius 范数; \mathbf{k}_{ij} 为权重, 反应了丢失子区域的相邻子区域 \mathbf{y}_j 和观测子区域 \mathbf{y}_{ij} 之间的相似性。 \mathbf{k}_{ij} 采用 α -ML 核函数, 具体定义如下:

$$\mathbf{k}_{ij} = \exp\left(-\frac{\|\mathbf{y}_i - \mathbf{y}_{ij}\|_{\text{M}}}{\sigma}\right) \quad (8)$$

通过 \mathbf{k}_{ij} 权重, 与 \mathbf{y}_i 更相似的样本会对 \mathbf{W}_i^* 提供更大的估计贡献。模型的封闭形式解如下:

$$\mathbf{W}_i^* = (\mathbf{Y}_i^T \mathbf{K}_i \mathbf{Y}_i + u\mathbf{I})^{-1} \mathbf{Y}_i^T \mathbf{K}_i \mathbf{Z}_i^T \quad (9)$$

式中: $\mathbf{Z}_i = [\mathbf{x}_{i1}, \mathbf{x}_{i2}, \mathbf{x}_{i3}, \dots, \mathbf{x}_{in}]^T \in \mathbf{R}^{n \times d_x}$, $\mathbf{Y}_i = [\mathbf{y}_{i1}, \mathbf{y}_{i2}, \mathbf{y}_{i3}, \dots, \mathbf{y}_{in}]^T \in \mathbf{R}^{n \times d_y}$, $\mathbf{K}_i = \text{diag}(\mathbf{k}_{i1}, \mathbf{k}_{i2}, \mathbf{k}_{i3}, \dots, \mathbf{k}_{in}) \in \mathbf{R}^{n \times n}$, 正则化参数 u 设置为

$$u = \frac{\text{Tr}(\mathbf{Y}_i^T \mathbf{K}_i \mathbf{Y}_i)}{N} \quad (10)$$

式中 $\text{Tr}(\cdot)$ 表示求括号内矩阵的迹。在得到上述局部线性相关模型的封闭形式解后, 进一步求得丢失子区域的粗略估计值:

$$\mathbf{x}_i^* = \mathbf{W}_i^T \mathbf{y}_i \quad (11)$$

式中: \mathbf{W}_i^T 为观测空间和潜在空间之间线性映射矩阵的转置矩阵, \mathbf{y}_i 为丢失子区域的相邻子区域。

1.3 总体算法流程

综上所述, 在对偶空间正则框架下进行了改进。在局部区域匹配阶段, 采用了基于自适应阈值的欧氏距离准则, 其中, 自适应阈值的计算融合了丢失子区域的相邻子区域和所有观测子区域间的平均相关性系数, 以及第 k 个欧氏距离最小的观测子区域对应的欧氏距离, 提高了局部区域匹配阶段的匹配精度, 并对局部线性相关模型进行完善, 提出了参数敏感性更低、灵活性更好的基于 α -ML 核函数的核岭回归方法, 从而得到更精确的丢失块的粗略估计值, 作为后续稀疏重构环节的初值。

图 4 是融合自适应阈值与 α -ML 核函数的双稀疏 (AM-DS) 算法流程。所提 AM-DS 算法的流程如下: 对于每一个丢失块, 进行丢失子区域划分, 利用基于置信度指数的最佳优先策略执行丢失子区域的恢复顺序确定。对于每一个丢失子区域, 通过基于自适应阈值的局部区域匹配方法筛选得到符合条件的潜在子区域和观测子区域, 组成潜在空间和观测空间。随后, 利用主成分分析 (PCA) 方法构建潜在空间和观测空间对应的自适应字典, 利用基于 α -ML 核函数的核岭回归方法建立潜在空间和观测空间之间的局部线性相关模型, 并基于此得到当前丢失子

区域的粗略估计值, 作为稀疏重构信号的初值。最后, 通过稀疏重构得到当前丢失块的精确估计值, 恢复所有丢失块后, 输出恢复图像。

据来展示结果。客观评价测度则是将图像质量相关的特性转化为具体的指标值来进行评价。实验选用 PSNR 作为恢复质量的客观评价测度。

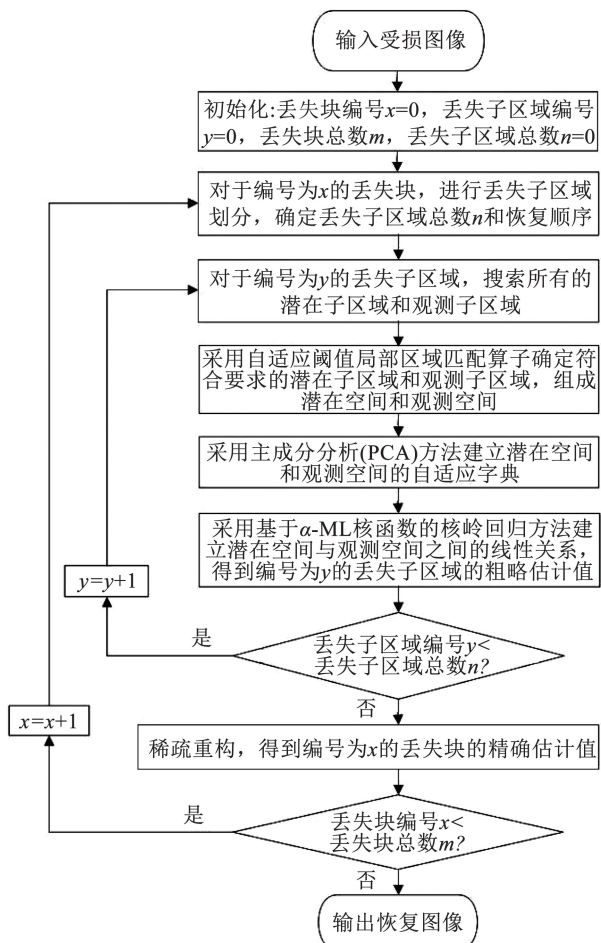


图 4 融合自适应阈值与 α -ML 核函数的双稀疏算法流程

Fig. 4 Flowchart of the dual sparsity algorithm based on adaptive threshold and α -ML kernel functions

2 结果与分析

本节进行典型块丢失模式下的测试实验, 来验证本文所提 AM-DS 算法的有效性。针对各种空域错误隐藏算法的综合性能, 采用当前代表性的 AVC^[5]、KMMSE^[8]、DSR^[9]、NSM^[7]、NEW-MDI^[10]、TKNM-MGD^[11] 等算法开展比较。

2.1 实验场景及评价指标

选取 12 幅经典的图像进行实验, 如图 5 所示, 图像分辨率均设置为 256×256 。对于块丢失, 设计了 4 种典型的块丢失模式进行实验, 分别为规则间隔丢失、规则连续丢失、随机突发丢失和随机行丢失, 如图 6 所示。丢失块尺寸设置为 16×16 , 丢失率分别设置为 25%、30%、35%、40%。图像质量评价测度分为主观评价测度和客观评价测度^[13]。主观评价测度通过肉眼主观感受来判断图像好坏, 评价结果受观看者的主观影响较大, 且没有精确的数

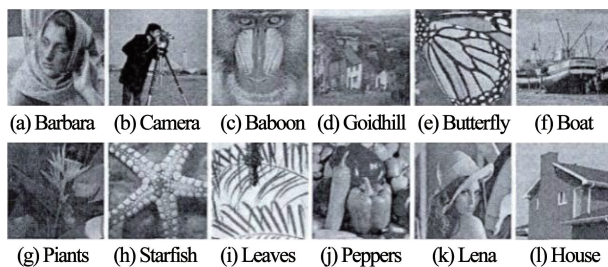


图 5 测试图像
Fig. 5 Test images

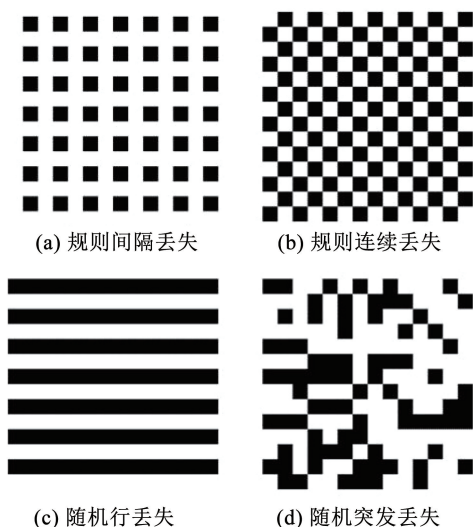


图 6 4 种典型的块丢失模式

Fig. 6 Four typical block loss modes

2.2 实验结果与分析

接下来将逐一给出规则间隔丢失、规则连续丢失、随机突发丢失和随机行丢失模式下的实验结果。由于篇幅有限, 每种场景只给出 1 组典型的主观评价结果图。

图 7 为规则间隔丢失模式下的主观评价结果。表 3 给出了不同算法在规则间隔丢失下的 PSNR, 表 4 给出了对应的耗时情况, 其中, Average 列是所有 12 幅图像实验数据的平均值。由表 3 可以看出, 在规则间隔丢失下, 所提 AM-DS 算法的 PSNR 平均值优于其他算法, 比 NEW-MDI 算法高 1.552 dB, 比 NSM 算法高 0.750 dB, 比 DSR 算法高 0.639 dB, 比 KMMSE 算法高 1.201 dB, 比 AVC 算法高 3.570 dB, 比 TKNM-MGD 算法高 5.381 dB。由表 4 可以看出, 在规则间隔丢失下, 所提 AM-DS 算法的耗时少于 KMMSE 算法, 多于 AVC、NSM、NEW-MDI、TKNM-MGD 算法, 相比 DSR 算法略有增加。

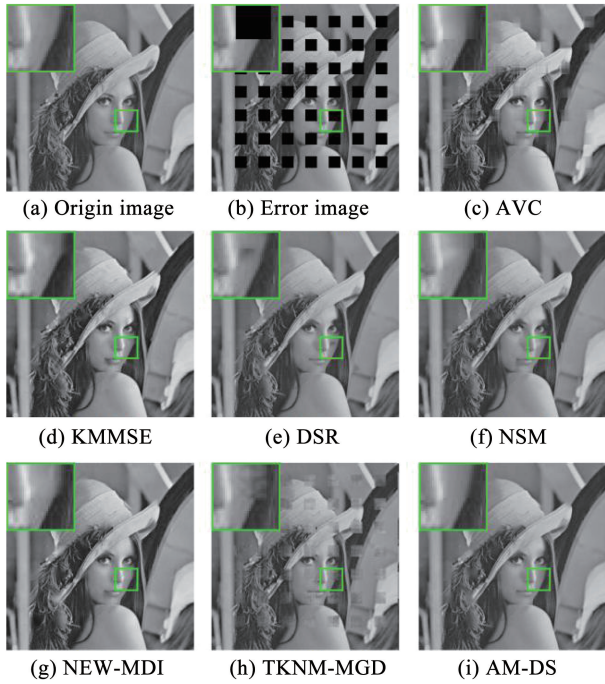


图 7 规则间隔丢失的恢复结果

Fig. 7 Recovery results in regular interval loss




图 8 规则连续丢失的恢复结果

Fig. 8 Recovery results in regular continuous loss

图 8 是规则连续丢失下的主观评价结果。表 5 给出了不同算法在规则连续丢失下的 PSNR,表 6 给出了对应的耗时情况。由表 5 可以看出,在规则连续丢失下,所提 AM-DS 算法的 PSNR 平均值优于其他算法,比 NEW-MDI 算法高 1.264 dB,比 NSM 算法高 0.667 dB,比 DSR 算法高 0.414 dB,比 KMMSE 算法高 1.312 dB,比 AVC 算法高 3.461 dB,比 TKNM-MGD 算法高 6.523 dB。由表 6 可以看出,在规则连续丢失下,所提 AM-DS 算法的耗时少于 KMMSE 算法,多于 AVC、NEW-MDI、NSM、TKNM-MGD 算法,相比 DSR 算法略有增加。

图 9 是随机突发丢失下的主观评价结果。表 7 给出了不同算法在随机突发丢失下的 PSNR,表 8 给出了对应的耗时情况。由表 7 可以看出,在随机突发丢失下,所提 AM-DS 算法的 PSNR 平均值优于其他算法,比 NEW-MDI 算法高 1.898 dB,比 NSM 算法高 1.069 dB,比 DSR 算法高 0.949 dB,比 KMMSE 算法高 1.001 dB,比 AVC 算法高 2.753 dB,比 TKNM-MGD 算法高 4.301 dB。由表 8 可以看出,在随机突发丢失下,所提 AM-DS 算法的耗时少于 KMMSE 算法,多于 AVC、NEW-MDI、NSM、TKNM-MGD 算法,相比 DSR 算法略有增加。

表 3 不同算法在规则间隔丢失下的 PSNR 值

Tab. 3 PSNR values for different algorithms in regular interval loss

算法	PSNR/dB							
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera	Average
AVC	28.001	21.526	29.227	22.598	26.883	27.418	26.152	25.972
KMMSE	30.945	25.056	31.883	24.819	28.051	30.737	26.902	28.342
DSR	31.821	24.832	33.751	25.956	28.347	30.346	27.269	28.903
NSM	32.431	24.267	32.941	26.202	28.701	29.389	27.610	28.792
NEW-MDI	30.577	25.162	31.451	24.817	27.894	28.668	27.392	27.994
TKNM-MGD	26.217	20.359	27.267	22.094	24.402	25.670	23.119	24.161
AM-DS	33.141	26.063	34.149	25.596	28.473	31.054	28.317	29.542

表 4 不同算法在规则间隔丢失下的耗时

Tab. 4 Runtime of different algorithms in regular interval loss

算法	耗时/s							
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera	Average
AVC	0.291	0.353	0.342	0.327	0.314	0.366	0.351	0.335
KMMSE	217.63	229.88	227.15	234.64	256.17	258.90	258.66	240.43
DSR	96.63	97.27	98.53	99.37	112.27	119.23	118.05	105.90
NSM	10.47	11.74	10.15	12.72	10.70	11.38	10.61	11.11
NEW-MDI	2.04	2.12	1.99	2.02	2.01	2.00	2.00	2.03
TKNM-MGD	0.506	0.475	0.497	0.529	0.525	0.506	0.565	0.515
AM-DS	104.84	109.47	109.41	106.34	107.94	108.73	109.72	108.06

表 5 不同算法在规则连续丢失下的 PSNR 值

Tab. 5 PSNR values for different algorithms in regular continuous loss

算法	PSNR/dB							
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera	Average
AVC	24.329	18.147	26.131	19.802	24.116	24.369	22.717	22.802
KMMSE	26.783	22.041	28.179	21.589	24.967	27.073	24.027	24.951
DSR	28.221	22.342	30.351	23.003	25.421	27.234	24.371	25.849
NSM	28.402	22.007	29.701	23.079	25.597	27.051	23.338	25.596
NEW-MDI	27.691	22.330	28.108	21.902	25.237	25.414	24.308	24.999
TKNM-MGD	21.695	16.270	22.847	18.118	20.446	21.114	17.690	19.740
AM-DS	29.181	22.667	31.292	23.128	25.654	27.789	24.133	26.263

表 6 不同算法在规则连续丢失下的耗时

Tab. 6 Runtime of different algorithms in regular continuous loss

算法	耗时/s							
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera	Average
AVC	0.50	1.06	0.69	0.67	0.66	0.65	0.64	0.70
KMMSE	439.12	421.65	448.19	450.90	431.73	433.88	441.36	438.12
DSR	165.34	159.34	169.30	171.27	164.47	165.83	168.62	166.31
NSM	20.22	19.99	16.90	21.61	20.06	21.02	19.15	19.85
NEW-MDI	3.82	3.84	3.77	3.82	3.80	3.76	3.78	3.80
TKNM-MGD	0.474	0.460	0.498	0.478	0.515	0.476	0.441	0.477
AM-DS	174.95	176.01	176.77	175.66	178.98	178.23	179.72	177.19

图 10 是随机行丢失下的主观评价结果。表 9 给出了不同算法在随机行丢失下的 PSNR, 表 10 给出了对应的耗时情况。由表 9 可以看出, 在随机行丢失下, 所提 AM-DS 算法的 PSNR 平均值优于其他算法, 比 NEW-MDI 算法高 1.709 dB, 比 NSM 算法高 0.398 dB, 比 DSR 算法高 0.238 dB, 比 KMMSE 算法高 1.171 dB, 比 AVC 算法高 2.589 dB, 比 TKNM-MGD 算法高 4.589 dB。由表 10 可以看出, 在随机行丢失下, 所提 AM-DS 算法的耗时少于 KMMSE 算法, 多于 AVC、NEW-MDI、NSM、TKNM-MGD, 与 DSR 算法相比略有增加。

综合规则间隔丢失、规则连续丢失、随机突发丢失和随机行丢失下的情况, 可得出如下结论: 基于低

秩矩阵补全机制的 TKNM-MGD 算法在典型块丢失模式下, PSNR 平均值明显低于其他空域错误算法。而基于逐点插值机制的 NEW-MDI、AVC 算法复杂度较低, 耗时较少, 但 PSNR 平均值也明显低于其他算法; KMMSE 算法复杂度较高, PSNR 平均值处于中等层次; NSM、DSR 算法复杂度中等, 而所提 AM-DS 算法的 PSNR 平均值显著高于其他算法, 和 NEW-MDI、NSM 等近年的算法相比在图像恢复质量上也有显著的优势。AM-DS 算法在耗时上少于 HSR 算法和 KMMSE 算法, 与 DSR 相比仅略有增加, 在一个可接受范围内。综合恢复质量和耗时, AM-DS 算法具有较强的竞争力。

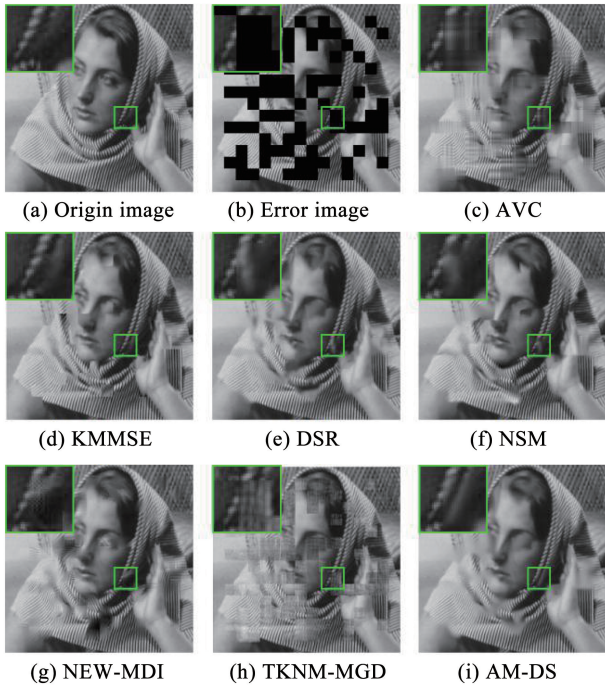


图 9 随机突发丢失的恢复结果

Fig. 9 Recovery results in random burst loss




图 10 随机行丢失的恢复结果

Fig. 10 Recovery results in random row loss

表 7 不同算法在随机突发丢失下的 PSNR 值

Tab. 7 PSNR values for different algorithms in random burst loss

算法	PSNR/dB							
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera	Average
AVC	23.151	18.130	26.407	19.767	23.321	22.912	21.071	22.108
KMMSE	25.901	21.017	27.571	21.124	24.219	25.501	21.694	23.861
DSR	27.328	20.396	27.738	22.661	23.129	24.862	21.270	23.912
NSM	27.701	20.134	28.235	21.234	23.021	24.348	21.871	23.792
NEW-MDI	25.128	19.602	26.220	20.661	23.796	23.259	22.072	22.963
TKNM-MGD	22.635	17.229	24.530	18.844	20.718	21.791	18.175	20.560
AM-DS	28.001	21.653	28.987	23.078	24.511	25.515	22.284	24.861

表 8 不同算法在随机突发丢失下的耗时

Tab. 8 Runtime of different algorithms in random burst loss

算法	耗时/s							
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera	Average
AVC	0.59	0.62	0.58	0.61	0.77	0.59	0.64	0.63
KMMSE	397.34	399.23	403.57	411.62	395.14	389.25	400.27	399.49
DSR	152.69	166.44	168.49	167.62	153.12	151.75	154.03	159.16
NSM	21.32	19.44	22.77	21.74	23.42	22.45	24.12	22.18
NEW-MDI	3.59	3.54	3.48	3.67	3.52	3.58	3.55	3.56
TKNM-MGD	0.505	0.465	0.544	0.534	0.515	0.536	0.432	0.504
AM-DS	163.47	169.88	176.04	173.02	172.9	173.14	173.53	171.71

表 9 不同算法在随机行丢失下的 PSNR 值

Tab. 9 PSNR values for different algorithms in random row loss

算法	PSNR/dB							
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera	Average
AVC	23.061	17.752	24.648	18.507	23.351	23.097	21.762	21.740
KMMSE	25.516	20.397	25.372	19.271	22.975	25.233	23.341	23.158
DSR	27.518	20.588	27.549	21.061	23.138	25.248	23.538	24.091
NSM	27.527	20.471	27.378	20.723	22.938	25.024	23.456	23.931
NEW-MDI	25.161	20.429	25.233	18.938	22.291	23.708	22.554	22.616
TKNM-MGD	21.695	16.270	22.847	18.118	20.446	21.114	17.690	19.740
AM-DS	28.501	21.087	26.643	21.194	23.489	26.064	23.322	24.329

表 10 不同算法在随机行丢失下的耗时

Tab. 10 Runtime of different algorithms in random row loss

算法	耗时/s							
	Lena	Leaves	Hat	Bike	Flower	Barbara	Camera	Average
AVC	0.58	0.54	0.61	0.57	0.61	0.68	0.64	0.60
KMMSE	402.7	405.1	426.5	421.8	424.9	423.5	421.1	417.94
DSR	164.71	165.42	167.83	166.31	168.45	167.32	166.24	166.59
NSM	18.51	21.30	15.93	20.34	21.22	22.33	17.64	19.61
NEW-MDI	3.68	4.08	3.83	3.70	3.67	3.68	3.66	3.76
TKNM-MGD	0.513	0.449	0.494	0.484	0.473	0.508	0.463	0.483
AM-DS	171.60	172.67	176.44	173.50	174.49	174.093	176.67	174.21

最后采用全部 12 幅图像,测试基于自适应阈值的局部区域匹配机制和基于 α -ML 核函数的局部线性相关模型单独作用下的效果。设当前的 DSR 为基线算法(Baseline),在 Baseline 基础上增加了基于自适应阈值的局部区域匹配机制的算法为 Module1,在 Baseline 基础上增加了基于 α -ML 核函数的局部线性相关模型的算法为 Module2。基线算法 Baseline,单一改进的 Module1、Module2 算法,最终改进的 AM-DS 算法在各丢失模式下的平均 PSNR 值、平均耗时如表 11、12 所示。可以看出,在规则间隔丢失、规则连续丢失、随机行丢失、随机突发丢失下,本文所提基于自适应阈值的局部区域匹配机制的 Module1 算法和基于 α -ML 核函数的局部线性相关模型的 Module2 算法得到的 PSNR 值均高于基线 Baseline 算法得到的结果。而结合了 Module1 算法和 Module2 算法之后,本文提出的 AM-DS 算法在各丢失模式下得到的 PSNR 值均高于任一单一改进算法的结果。在主观评价方面,两模块的共同作用使得 AM-DS 算法的恢复效果更加平滑,如图 7~10 所示,均优于当前的 DSR 算法。在耗时方面,单一改进算法或最终改进 AM-DS 算法的结果均略微高于基线 Baseline 算法得到的结果,但相差较小,在一个可接受范围内。

表 11 单一改进算法和最终改进算法在各丢失模式下的平均 PSNR 值

Tab. 11 Average PSNR values of a single improved algorithm and a final improved algorithm in each loss mode

丢失模式	PSNR/dB			
	Baseline	Module1	Module2	AM-DS
规则间隔丢失	28.903	29.406	29.352	29.542
规则连续丢失	25.849	26.189	26.212	26.263
随机行丢失	24.091	24.201	24.101	24.329
随机突发丢失	23.912	24.506	24.653	24.861

表 12 单一改进算法和最终改进算法在各丢失模式下的平均耗时

Tab. 12 Average runtime of a single improved algorithm and a final improved algorithm in each loss mode

丢失模式	耗时/s			
	Baseline	Module1	Module2	AM-DS
规则间隔丢失	105.96	107.42	111.34	108.06
规则连续丢失	166.31	198.29	201.16	177.19
随机行丢失	166.59	201.80	221.12	174.21
随机突发丢失	159.16	178.49	198.52	171.71

3 结 论

针对当前对偶空间正则算法存在的候选子区域选取不准、相关模型参数较敏感问题,提出了一种融合自适应阈值与 α -ML 核函数的双稀疏空域错误隐藏算法。所提算法设计了基于自适应阈值的局部区域匹配阶段,能够灵活地适应特征各异的丢失子区域,为字典构建和局部线性相关建模提供更准确的观测空间和潜在空间。在局部线性相关建模阶段,所提算法使用了基于 α -ML 核函数的核岭回归方法,比现有高斯核函数的参数敏感性更低、灵活性更好。实验表明,所提算法在各类典型的块丢失模式下,与其他现有的空域错误隐藏算法相比,具有更好的恢复质量。在后续研究中,将对字典建立、稀疏重构等环节进行优化,进一步提高算法的恢复质量,并降低算法复杂度。

参考文献

- [1] CARREIRA J F M, ASSUNÇÃO P A, DE FARIA S M M, et al. Error concealment-aware encoding for robust video transmission[J]. IEEE Transactions on Broadcasting, 2019, 65(2): 282. DOI: 10.1109/TBC.2018.2865644
- [2] USMAN M, HE Xiangjian, XU Min, et al. Survey of error concealment techniques: research directions and open issues[C]//Proceedings of the 2015 Picture Coding Symposium (PCS). Cairns: IEEE, 2015: 233. DOI: 10.1109/PCS.2015.7170081
- [3] KAZEMI M, GHANBARI M, SHIRMOHAMMADI S. A review of temporal video error concealment techniques and their suitability for HEVC and VVC[J]. Multimedia Tools and Applications, 2021, 80(8): 12685. DOI: 10.1007/s11042-020-10333-6
- [4] HUNG T K, HUANG I C, COX S R, et al. Error concealment of dynamic 3D point cloud streaming[C]//Proceedings of the 30th ACM International Conference on Multimedia (MM' 22). Lisbon: ACM, 2022: 3134
- [5] KUMAR S, XU Liyang, MANDAL M K, et al. Error resiliency schemes in H. 264/AVC standard [J]. Journal of Visual Communication and Image Representation, 2006, 17(2): 425.

- DOI: 10.1016/j.jvcir.2005.04.006
- [6] 王冰, 刘浩, 李康达, 等. 基于迭代自适应终止的马尔科夫错误隐藏算法[J]. 计算机工程, 2018, 44(9): 230
WANG Bing, LIU Hao, LI Kangda, et al. Markov error concealment algorithm based on iterative adaptive termination [J]. Computer Engineering, 2018, 44(9): 230. DOI: 10.19678/j.issn.1000-3428.0047951
 - [7] 王凯巡, 刘浩. 非迭代收缩多方向预测的空域错误隐藏算法[J]. 哈尔滨工业大学学报, 2020, 52(10): 128
WANG Xunkai, LIU Hao. Spatial error concealment algorithm for non-iterative shrinkage multi-direction prediction [J]. Journal of Harbin Institute of Technology, 2020, 52(10): 128
 - [8] KOLODA J, SEILER J, PEINADO A M, et al. Scalable kernel-based minimum mean square error estimator for accelerated image error concealment[J]. IEEE Transactions on Broadcasting, 2017, 63(1): 59. DOI: 10.1109/TBC.2016.2619581
 - [9] LIU X, ZHAI D, ZHOU J, et al. Sparsity-based image error concealment via adaptive dual dictionary learning and regularization [J]. IEEE Transactions on Image Processing, 2017, 26(2): 782. DOI: 10.1109/TIP.2016.2623481
 - [10] HWANG P, RI J, YUN Y. Method for speeding up spatial error concealment using prediction mode of the neighboring blocks on H.264 video communication [J]. Multimedia Tools and Applications, 2023, 82: 4769. DOI: 10.1007/s11042-022-13950-5
 - [11] ZHOU L, LIU H. Truncated kernel norm minimization with extrapolative proximal gradient for multi-mask matrix completion [C]//Proceedings of the IEEE 24th International Workshop on Multimedia Signal Processing (MMSP). Shanghai: IEEE, 2022: 1. DOI: 10.1109/MMSP55362.2022.9949308
 - [12] KAZEMI M, GHANBARI M, SHIRMOHAMMADI S. The performance of quality metrics in assessing error-concealed video quality[J]. IEEE Transactions on Image Processing, 2020, 29: 5937. DOI: 10.1109/TIP.2020.2984356
 - [13] DING K, MA K, WANG S, et al. Image quality assessment: unifying structure and texture similarity[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(5): 2567. DOI: 10.1109/TPAMI.2020.3045810

(编辑 刘 彤)