

基于加权Boosting的核偏最小二乘图像超分辨率重建

李小燕 和红杰* 尹忠科 陈帆

(西南交通大学信号与信息处理四川省重点实验室 成都 610031)

摘要: 核偏最小二乘(KPLS)算法对每个图像块选用全部主元成分进行图像重建, 导致图像超分辨率算法的计算量大。兼顾图像重建质量和时间效率, 该文提出一种加权 Boosting 的图像超分辨率重建算法。为自适应地选取每个图像块主元成分的最佳数目, 利用加权 Boosting 原理对 KPLS 回归预测量进行补偿, 推导给出补偿权重系数的数学表达式。讨论不同 Boosting 阈值 δ 情况下的重建性能, 在合适的 δ 下, 选取出主元成分的最佳数目 m 更好地满足 KPLS 回归模型的精度要求。实验结果表明, 该文算法的超分辨率重建质量优于传统算法。

关键词: 图像超分辨率重建; 加权 Boosting; 核偏最小二乘(KPLS); Boosting 阈值; 主元成分

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2012)07-1525-06

DOI: 10.3724/SP.J.1146.2011.01191

Image Super-resolution Reconstruction Based on Kernel Partial Least Squares and Weighted Boosting

Li Xiao-yan He Hong-jie Yin Zhong-ke Chen Fan

(Sichuan Key Laboratory of Signal and Information Processing, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: The Kernel Partial Least Squares (KPLS) method has a large calculation since it uses all the principal components for each image block. To consider reconstruction quality and time efficiency, a weighted Boosting based algorithm is proposed in this paper. To choose adaptively the best number of principal components for each image block, the estimator in KPLS prediction model is performed for compensation. The weight coefficient expression of compensation is deduced. The reconstruction effects in different Boosting threshold are discussed. With an appropriate threshold, the chosen best number of principal components can better satisfy KPLS regression model accuracy. Experimental results demonstrate that the proposed method outperforms the conventional methods in super-resolution reconstructed quality.

Key words: Image super-resolution reconstruction; Weighted Boosting; Kernel Partial Least Squares (KPLS); Boosting threshold; Principal component

1 引言

图像超分辨率(Super Resolution, SR)重建^[1]是利用一帧或多帧^[2]低分辨率(Low Resolution, LR)图像的相关和互补信息, 综合估计出 LR 图像丢失的高频信息, 从而重建出一幅高分辨率(High Resolution, HR)图像。SR 重建技术能一定程度上克服传感器和光学制造技术的限制, 在遥感卫星、军事侦察、医学成像以及安全监控等领域具有实用性。

学习法是目前图像 SR 重建技术的研究热点。

这一概念是 Freeman 等人^[3]于 2002 年首次提出的, 这类方法不仅能克服分辨率提高倍数方面的局限性, 而且不需对图像进行配准, 具有一定的优势^[4]。文献[5]提出利用对数-小波变换(Log-WT)方法来实现人脸图像超分辨率重建, 但这些方法在重建过程中会引入较大的量化误差。文献[6]提出一种基于边缘检测和特征选取的邻域嵌入算法来实现图像 SR 重建, 然而在模糊区域会出现混叠现象。文献[7]用稀疏编码(Sparse Coding, SC)的方法来自适应地选取邻域块, 文献[8]在 SC 方法的基础上提出非局部联合稀疏近似的超分辨率方法。文献[9]提出用偏最小二乘(Partial Least Squares, PLS)方法来表征 LR 和 HR 图像间的关系, 但 PLS 是线性回归模型。文献[10]指出核偏最小二乘(Kernel Partial Least Squares, KPLS)方法比 PLS 更能表征非线性关系, 得到较好的重建质量。然而这种方法对每一测试图像块选用全部的主元成分, 计算量大。事实上, 当

2011-11-16 收到, 2012-03-26 改回

国家自然科学基金(60970122), 教育部博士点基金(20090184120021), 中央高校基本科研业务专项基金(SWJTU09CX039, SWJTU10CX09)和四川省科技创新苗子工程项目(2011-013)资助课题

*通信作者: 和红杰 lixiaoyan7015@yahoo.cn; hehojie@126.com

后续的主元成分不再提供有用的信息时,采用过多的主元成分不会改善重建效果。

本文提出一种加权 Boosting 的图像 SR 重建算法,在不降低图像重建质量的前提下,自适应地选取出图像块所需主元成分的最佳数目。在建立 KPLS 回归模型时引入加权 Boosting 补偿方案,给出权重系数的数学表达式。在最佳 Boosting 阈值 δ 下,只需提取前 m 个主元成分,即可使回归模型达到精度要求。对比实验结果表明,在相同计算环境下,本文算法既能得到比 KPLS 算法较好的重建质量,又能提高运算速度。

2 加权 Boosting 的图像 SR 重建算法

2.1 KPLS 回归模型

KPLS 是一种多元非线性回归方法^[11],重建向量 $\mathbf{h}_k \in \mathcal{R}^{1 \times M}$ 的计算公式为^[12]

$$\mathbf{h}_k = \mathbf{G}_k \mathbf{V} (\mathbf{U}^T \mathbf{F} \mathbf{V})^{-1} \mathbf{U}^T \mathbf{Y} \quad (1)$$

由式(1)可知, \mathbf{h}_k 与 \mathbf{G}_k , \mathbf{F} , \mathbf{Y} , \mathbf{U} 和 \mathbf{V} 有关。其中输出矩阵 \mathbf{Y} 可以由图像训练库来确定,测试向量 $\mathbf{l}_k \in \mathcal{R}^{1 \times M}$ 与输入矩阵 \mathbf{X} 之间的核函数矩阵 \mathbf{G}_k 和 \mathbf{X} 自身的核函数矩阵 \mathbf{F} 由核函数计算得出,而成分矩阵 \mathbf{U} 和 \mathbf{V} 则需通过 KPLS 回归模型来得到的。

在建立 KPLS 回归模型时,第 $i (1 \leq i \leq M)$ 次迭代后的成分矩阵为

$$\begin{cases} \mathbf{U}_i = \{\mathbf{u}_j \mid \mathbf{u}_j \in \mathcal{R}^{n \times 1}, 1 \leq j \leq i\} \\ \mathbf{V}_i = \{\mathbf{v}_j \mid \mathbf{v}_j \in \mathcal{R}^{n \times 1}, 1 \leq j \leq i\} \end{cases} \quad (2)$$

其中 i 为提取的主元成分数目,成分矩阵 \mathbf{U} 和 \mathbf{V} 中的向量个数随着 i 的增大而增多。

然而 KPLS 回归时并不需要选用全部的主元成分 M 。 i 越小,估计 \mathbf{h}_k 的复杂度就会越小。如何减少提取的主元成分数目同时保证得到较精确的 \mathbf{h}_k , 是改善重建效果的关键问题。

2.2 主元成分的最佳数目

针对上述的问题,本文提出一种加权 Boosting 的改进方案,利用 Boosting 算法原理^[13,14]来对 KPLS 回归模型进行补偿,在每次迭代中引入权重系数。在最佳 Boosting 阈值 δ 下,对每一测试向量 \mathbf{l}_k 构造 KPLS 回归模型时,自适应地选取出主元成分的最佳数目 m 。本文算法能以较快的速度学习得到最佳成分矩阵 \mathbf{U}_m 和 \mathbf{V}_m ,从而更快更准确地计算出估计量 \mathbf{h}_k 。

假设真实量矩阵 \mathbf{Y} 与 KPLS 回归模型残差量矩阵集合 $\Delta \mathbf{Y} = \{\Delta \mathbf{Y}_i\}_{i=1}^M$ 之间呈线性加权的的关系,则有

$$\mathbf{Y} = \beta_1 \Delta \mathbf{Y}_1 + \beta_2 \Delta \mathbf{Y}_2 + \cdots + \beta_M \Delta \mathbf{Y}_M + \varepsilon \quad (3)$$

第 $i (1 \leq i \leq M)$ 次迭代后,模型预测量为

$$\hat{\mathbf{Y}}_i = \sum_{j=1}^i \beta_j \Delta \mathbf{Y}_j \quad (4)$$

\mathbf{Y} 与第 i 次模型预测量矩阵 $\hat{\mathbf{Y}}_i$ 之间的平方损失函数 R 表达式为^[15]

$$R(\mathbf{Y}, \hat{\mathbf{Y}}_i) = \frac{1}{n} \sum_{j=1}^n \|\mathbf{y}_j - \hat{\mathbf{y}}_{ij}\|^2 \quad (5)$$

其中 $\mathbf{y}_j, \hat{\mathbf{y}}_{ij} \in \mathcal{R}^{1 \times M}$ 。

根据数学归纳法,假设已通过 $i-1 (i \geq 2)$ 次迭代得到的第 $i-1$ 次模型预测量 $\hat{\mathbf{Y}}_{i-1}$,则下次预测量应为 $\hat{\mathbf{Y}}_i = \hat{\mathbf{Y}}_{i-1} + \beta_i \Delta \mathbf{Y}_i$,根据式(5),此时 $R(\mathbf{Y}, \hat{\mathbf{Y}}_i)$ 变为

$$R(\mathbf{Y}, \hat{\mathbf{Y}}_{i-1} + \beta_i \Delta \mathbf{Y}_i) = \frac{1}{n} \sum_{j=1}^n \|\mathbf{y}_j - (\hat{\mathbf{y}}_{(i-1)j} + \beta_i \Delta \mathbf{y}_{ij})\|^2 \quad (6)$$

其中 $\hat{\mathbf{y}}_{(i-1)j}, \Delta \mathbf{y}_{ij} \in \mathcal{R}^{1 \times M}$, β_i 为第 i 次模型补偿时的权重系数。

$\hat{\mathbf{Y}}_{i-1}$ 和 $\Delta \mathbf{Y}_i$ 可以通过 KPLS 回归方程计算得到,当 $R(\mathbf{Y}, \hat{\mathbf{Y}}_i)$ 取得最小值时,即对式(6)求关于 β_i 的一阶导数,并令其为 0,就可以得出第 $i (i \geq 2)$ 次迭代的权重系数 β_i 为

$$\beta_i = \frac{\sum_{j=1}^n (\mathbf{y}_j - \hat{\mathbf{y}}_{(i-1)j}) (\Delta \mathbf{y}_{ij})^T}{\sum_{j=1}^n \|\Delta \mathbf{y}_{ij}\|^2} \quad (7)$$

将式(7)代入式(6)中,整理得

$$R(\mathbf{Y}, \hat{\mathbf{Y}}_i) = (1 - \lambda) R(\mathbf{Y}, \hat{\mathbf{Y}}_{i-1}) \quad (8)$$

其中

$$\lambda = \frac{\left[\sum_{j=1}^n (\mathbf{y}_j - \hat{\mathbf{y}}_{(i-1)j}) (\Delta \mathbf{y}_{ij})^T \right]^2}{\sum_{j=1}^n \|\Delta \mathbf{y}_{ij}\|^2 \sum_{j=1}^n \|\mathbf{y}_j - \hat{\mathbf{y}}_{(i-1)j}\|^2} \quad (9)$$

根据柯西不等式可知, $\lambda \in [0, 1]$, 则由式(8)可以得出第 $i (i \geq 2)$ 次迭代的平方损失函数 R_i 随着模型残差量 $\Delta \mathbf{Y}_i$ 的添加,以 $(1 - \lambda)$ 的速度减小,也即第 $i (i \geq 2)$ 次迭代后的平方损失函数值 R_i 都比第 1 次平方损失函数值 R_1 要小。为了控制迭代结束条件,计算 R_i 与 R_1 的比值平方根,设置一个 Boosting 阈值 δ , 通过这个阈值 δ 来减少主元成分数目。当 $\sqrt{R_i / R_1} \leq \delta$ 时,认为迭代 i 次后的 KPLS 回归模型已经达到精度要求,停止提取后续的主元成分,此时的 i 即为自适应地选取主元成分的最佳数目 m 。Boosting 阈值 δ 的大小会影响到提取的主元成分数目,为了保证得到较为精确的高分辨率估计量 \mathbf{h}_k , 要选取适当的 δ 。若 δ 太小,SR 重建效果改善很小;

若 δ 太大, 高频信息很难被估计出来。不降低图像重建质量的前提下, 兼顾时间效率, 最佳 Boosting 阈值 δ 的选取将在实验部分进行讨论和分析。

2.3 本文算法步骤

本文提出的算法流程框图如图 1 所示。

步骤 1 预处理 经文献[10]预处理后, 得到训练 LR, HR 特征向量矩阵 $\mathbf{X}_s = \{\mathbf{x}_i | 1 \leq i \leq N\}$ 和 $\mathbf{Y}_s = \{\mathbf{y}_i | 1 \leq i \leq N\}$, 以及测试向量矩阵 $\mathbf{X}_t = \{\mathbf{l}_k | 1 \leq k \leq C\}$, $\mathbf{x}_i, \mathbf{y}_i$ 和 $\mathbf{l}_k \in \mathcal{R}^{1 \times M}$, N 和 C 分别是训练样本数目和测试向量数目, M 为向量维数。

步骤 2 学习过程

(1)寻找相似样本对 对于每一个测试向量 \mathbf{l}_k , 根据欧氏距离最小原则, 在 \mathbf{X}_s 中寻找与 \mathbf{l}_k 相似的 n 个 LR/HR 训练样本对, 以它们作为 KPLS 回归模型的输入输出矩阵 $\mathbf{X} = \{\mathbf{x}_i | i \in A_k, 1 \leq i \leq n\}$ 和 $\mathbf{Y} = \{\mathbf{y}_i | i \in A_k, 1 \leq i \leq n\}$, A_k 为 \mathbf{l}_k 的索引集。

(2)初始化处理 对 \mathbf{X}, \mathbf{Y} 和 \mathbf{l}_k 进行标准化处理^[11], 本文选用径向基核函数 $f(\mathbf{x}_i, \mathbf{x}_j) = \exp\{-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\sigma^2\}$, 计算出 \mathbf{X} 自身的核函数矩阵 \mathbf{F} , 以及 \mathbf{l}_k 与 \mathbf{X} 的核函数矩阵 \mathbf{G}_k , 令 $i=1, \mathbf{E}_1 = \mathbf{Y}, \mathbf{F}_1 = \mathbf{F}$ 。

(3)计算成分矩阵

(a)初始化 \mathbf{Y} 的成分向量 \mathbf{v}_i 为全为 1 的列向量;

(b)计算 \mathbf{X} 的成分向量 $\mathbf{u}_i = \mathbf{F}_i \mathbf{v}_i / \sqrt{\mathbf{v}_i^T \mathbf{F}_i \mathbf{v}_i}$;

(c)计算 \mathbf{Y} 的权重向量 $\mathbf{c}_i = \mathbf{E}_i^T \mathbf{u}_i / \mathbf{u}_i^T \mathbf{u}_i$;

(d)更新 \mathbf{Y} 的成分向量 $\mathbf{v}_i = \mathbf{E}_i \mathbf{c}_i / \mathbf{c}_i^T \mathbf{c}_i$;

(e)重复第(b)-(d)步, 直至 \mathbf{v}_i 收敛, 得到 \mathbf{u}_i 和 \mathbf{v}_i 列向量, 则成分矩阵 $\mathbf{U}_i = \{\mathbf{u}_1, \dots, \mathbf{u}_i\}$ 和 $\mathbf{V}_i = \{\mathbf{v}_1, \dots, \mathbf{v}_i\}$ 。

(4)用加权 Boosting 方法对第 i 次模型预测量进行补偿

$$\hat{\mathbf{Y}}_i = \begin{cases} \mathbf{F}_1 \mathbf{V}_1 (\mathbf{U}_1^T \mathbf{F}_1 \mathbf{V}_1)^{-1} \mathbf{U}_1^T \mathbf{E}_1, & i = 1 \\ \hat{\mathbf{Y}}_{i-1} + \beta_i \Delta \mathbf{Y}_i, & i \geq 2 \end{cases} \quad (10)$$

$$\Delta \mathbf{Y}_i = \mathbf{F}_i \mathbf{V}_i (\mathbf{U}_i^T \mathbf{F}_i \mathbf{V}_i)^{-1} \mathbf{U}_i^T \mathbf{E}_i \quad (11)$$

其中 β_i 的值是根据式(7)计算得到的。

(5)计算平方损失函数 根据式(8)计算出 \mathbf{Y} 与 $\hat{\mathbf{Y}}_i$ 间的平方损失函数值 R_i 。

(6)确定主元成分的最佳数目

(a) $\sqrt{R_i / R_1} \leq \delta$, KPLS 回归模型达到精度要求, 停止提取后续的主元成分, 此时的 i 即为主元成分的最佳数目 m ; 当 $i=M$ 时, 则 $m=M$ 。

(b) $\sqrt{R_i / R_1} > \delta$, 回到第(2)步重新计算成分矩阵, 则

$$\left. \begin{aligned} \mathbf{E}_{i+1} &= \mathbf{Y} - \hat{\mathbf{Y}}_i \\ \mathbf{F}_{i+1} &= \mathbf{Q}_i^T \mathbf{F}_i \mathbf{Q}_i \\ \mathbf{Q}_i &= \mathbf{I} - \mathbf{u}_i \mathbf{u}_i^T / \mathbf{u}_i^T \mathbf{u}_i \end{aligned} \right\} \quad (12)$$

其中 \mathbf{I} 为 $n \times n$ 的单位矩阵。

(7)计算估计量 \mathbf{h}_k 根据主元成分的最佳数目 m , 得到相应的 \mathbf{U}_m 和 \mathbf{V}_m , 将它们代入到式(13)中即可计算出估计量 \mathbf{h}_k :

$$\mathbf{h}_k = \mathbf{G}_k \mathbf{V}_m (\mathbf{U}_m^T \mathbf{F}_m \mathbf{V}_m)^{-1} \mathbf{U}_m^T \mathbf{Y} \cdot \mathbf{s}_y + \mathbf{v}_y \quad (13)$$

其中 \mathbf{s}_y 和 \mathbf{v}_y 分别是 \mathbf{Y} 的标准差向量和均值向量。

(8)判断是否满足结束条件

(a)当 $k=C$ 时, 说明已完成对整幅测试图像的学习过程;

(b)否则, 回到第(1)步, 继续对下一个测试向量进行学习。

步骤 3 重建 将所有 $\mathbf{h}_k (1 \leq k \leq C)$ 转化为图像块形式, 并按顺序拼接成高频特征图像, 再加上测试图像的最近邻插值, 即可得到 SR 重建的初始图像 \mathbf{H}_0 。

步骤 4 IBP 增强 为了增强 \mathbf{H}_0 的质量, 本文采用迭代后投影 (Iterative Back-Projection, IBP) 算法^[16]来对 \mathbf{H}_0 做进一步处理。根据梯度下降法, 使用的迭代公式为

$$\mathbf{H}_{p+1} = \mathbf{H}_p + \alpha [\mathbf{B}^T \mathbf{D}^T (\mathbf{D} \mathbf{B} \mathbf{H}_p - \mathbf{L}) + \gamma (\mathbf{H}_p - \mathbf{H}_0)] \quad (14)$$

其中 α 和 γ 分别是迭代步长和规整化参数, \mathbf{D}, \mathbf{B} 和 \mathbf{L} 分别是下采样矩阵、模糊矩阵和测试图像, p 为迭代次数, $1 \leq p \leq P$, P 是最大迭代次数。

2.4 复杂度分析

为了分析本文算法的复杂度, 主要考虑算法的 4 个步骤运算, 如表 1 所示, 其中 \bar{m} 是用本文算法对测试图像进行 SR 重建时主元成分的平均数目, N_1 和 N_2 分别是重建图像的行和列数。与 KPLS 算




图 1 本文算法的流程框图

表1 本文算法的复杂度

步骤	时间复杂度	空间复杂度
1	$O(N+C)$	$O(2MN+MC)$
2	$O(\bar{m}Cn^3)$	$O(2nM+MC+2\bar{m}n)$
3	$O(C)$	$O(MC)$
4	$O(P)$	$O(N_1N_2)$

法相比, 主要区别在于步骤2训练KPLS回归模型时所用的主元成分数目, 本文算法能自适应地选取每个测试向量主元成分的最佳数目 m , 时间复杂度为 $O(\bar{m}Cn^3)$, 平均数目 \bar{m} 比 M 小, 只需KPLS算法的 \bar{m}/M 倍运算时间, 空间复杂度也有所减小。

3 实验结果

实验中选用61幅HR图像¹⁾作为训练图像, 下采样因子为4, 经双三次插值下采样得到对应的LR训练图像, 分块大小为 6×6 , 即 $M=36$, 不重叠分块出84250个LR-HR样本对。在训练库中选取的样本对数目为 $n=30$, 径向基核函数中的标准差 $\sigma=1$ 。最大迭代次数 $P=20$, 迭代步长 α 和规整化参数 γ 均为1。选用Grape和Wall测试图像, 经双三次插值下采样得到对应的模拟LR图像, 按文献[10]的方法提取测试图像的高频信息, 对高频图像进行分块, 相邻块重叠2个像素。本实验是在CPU为2.33 GHz、内存为2 GB的PC机上进行的, 编程环境为Matlab R2010a。

每个测试图像块在相同的主元成分数目情况下, 采用本文算法对模拟LR图像进行SR重建, 图2是本文算法的SR重建图像与原始HR图像之间的结构相似性(Structural SIMilarity, SSIM)^[17]平均值在不同主元成分数目下的变化曲线。由图2可以看出, 当主元成分数目为2~15时变化曲线呈波动趋势; 当主元成分数目介于16到36时, 算法的SR重建效果趋于平稳。每个测试图像块所需主元成分的最佳数目不尽相同, Boosting阈值 δ 可以自适应选取 m 值。

基于2.2节的理论分析, 在不降低SR重建质量的前提下, 选取合适的Boosting阈值 δ , 图3是两幅模拟LR图像在不同Boosting阈值 δ 下SSIM平均值的变化曲线。从图3可以看出, 当 $\delta=0.05$ 时, SSIM值最大, SR重建效果最佳, 故仿真实验中选取 $\delta=0.05$ 。

图4给出Grape和Wall两幅测试图像在 $\delta=0.05$ 下主元成分的最佳数目 m 的统计结果。从图4的统计曲线来看, m 主要集中在12~20之间,

而 $m=36$ 的比重很小, 自适应地选取 m 的方案更适用于实时的图像SR重建。表2给出SC, KPLS和本文算法运行时间的比较结果, 其中 C 为测试图像分得图像块的数目。SC算法针对具体的放大倍数和训练图像库, 需要构造完备原子库, 往往要消耗10~12 h。本文算法不需事先构建原子库, 生成训练数据集只需几秒时间就能完成, 然后针对每个测试图像块来进行实时SR重建, 本文算法在训练和重建阶段所需的总时间比SC算法少很多。

表2 算法的运行时间比较

算法	Grape($C=7344$)			Wall($C=3950$)		
	训练	重建	重建	训练	重建	重建
	时间(s)	\bar{m}	时间(s)	时间(s)	\bar{m}	时间(s)
SC	32864.3	-	156.4	32864.3	-	79.9
KPLS	3.9	36.0	1251.2	3.9	36.0	681.9
本文方法	3.9	16.1	1225.1	3.9	16.7	670.0

图5给出了不同算法对Grape测试图像进行SR重建的对比结果, 中间框图为SR重建图像上的局部区域, 右上角框图为采用双三次算法对局部区域放大2倍的效果。从图5(a)~5(e)可以看出: NeedFS算法^[6]会平滑局部细节; SC算法^[7]较好地重建出细节信息; PLS算法^[9]在边缘区域上有混叠现象; KPLS算法^[10]的边缘轮廓不是很清晰; 本文算法在边缘和局部区域的细节都能得到增强, 更接近于原始HR图像。

为了评价各种SR算法对实际LR图像处理的性能, 从Macao实际图像中选取其中大小 85×85 的局部区域作为实际LR图像。采用4种方法分别对该局部图进行4倍放大, 重建出一幅大小为 340×340 的目标图像, 图6给出其局部区域比较结果, 中间框图为SR重建图像上的局部区域, 左下角框图为局部放大2倍的效果。由于没有真实HR图像作为参考, 本文采用平均梯度(Average Gradient, AG)来衡量算法的实际处理能力, AG值越大, 说明图像的相对清晰程度越高。本文算法的AG值为4.8580, 均比其他3种方法的高。从主观视觉来看, SC算法在尖顶等的边缘区域上产生伪影; PLS算法有毛刺边缘; KPLS算法和本文算法的重建效果较好, 但在运行时间上, 本文算法要优于KPLS算法, KPLS算法需要1261.9 s, 而本文算法只需1204.2 s。

4 结束语

本文提出一种加权Boosting改进方案来实现

1) <http://www.ifp.illinois.edu/~jyang29/>




图 2 不同主元成分数目下 SSIM 的变化曲线




图 3 不同阈值 δ 下 SSIM 的变化曲线




图 4 在 $\delta = 0.05$ 下 m 的统计结果




图 5 Grape 测试图像的 SR 重建效果比较




图 6 Macao 实际图像的 SR 重建效果比较

图像超分辨率重建，能很好地解决 KPLS 算法选用全部主元成分导致计算量大的问题，推导出模型补偿权重系数的数学表达式，讨论分析在不同的 Boosting 阈值 δ 下的 SR 重建效果，仿真实验从主元成分的最佳数目 m 和重建效果(主观视觉和客观评价指标)两方面来比较本文算法与传统算法的性能。理论分析和实验结果表明，本文算法的 SR 重建质量和时间效率都有所改善。将加权 Boosting 改进方案应用到遥感图像的超分辨率重建，最大限度地体现其优越性和实时性，是下一步的研究重点。

参考文献

[1] Park S C, Park M K, and Kang M G. Super-resolution image reconstruction: a technical overview[J]. *IEEE Signal Processing Magazine*, 2003, 20(3): 21-36.

[2] 杨浩, 高建坡, 吴镇扬. 一种新的图像配准和超分辨率重建算法[J]. *电子与信息学报*, 2008, 30(1): 168-171.

Yang Hao, Gao Jian-po, and Wu Zhen-yang. A new algorithm for image registration and super-resolution

- reconstruction[J]. *Journal of Electronics & Information Technology*, 2008, 30(1): 168-171.
- [3] Freeman W T, Jones T R, and Pasztor E C. Example-based super-resolution[J]. *IEEE Computer Graphics and Applications*, 2002, 22(2): 56-65.
- [4] Glasner D, Bagon S, and Irani M. Super-resolution from a single image[C]. *IEEE 12th International Conference on Computer Vision*, Kyoto, Japan, 2009: 349-356.
- [5] 乔建苹, 刘璐, 闫华, 等. 基于 Log-WT 的人脸图像超分辨率重建[J]. *电子与信息学报*, 2008, 30(6): 1276-1280.
Qiao Jian-ping, Liu Ju, Yan Hua, *et al.* A Log-WT based super-resolution algorithm[J]. *Journal of Electronics & Information Technology*, 2008, 30(6): 1276-1280.
- [6] Chan T M, Zhang J, Pu J, *et al.* Neighbor embedding based super-resolution algorithm through edge detection and feature selection[J]. *Pattern Recognition Letters*, 2009, 30(5): 494-502.
- [7] Yang J, Wright J, Huang T, *et al.* Image super-resolution via sparse representation[J]. *IEEE Transactions on Image Processing*, 2010, 19(11): 2861-2873.
- [8] 李民, 李世华, 李小文, 等. 非局部联合稀疏近似的超分辨率重建算法[J]. *电子与信息学报*, 2011, 33(6): 1407-1412.
Li Min, Li Shi-hua, Li Xiao-wen, *et al.* Super-resolution reconstruction algorithm based on non-local simultaneous sparse approximation[J]. *Journal of Electronics & Information Technology*, 2011, 33(6): 1407-1412.
- [9] 胡宇, 赵保军, 沈庭芝, 等. 基于偏最小二乘的人脸超分辨率重构[J]. *北京理工大学学报*, 2010, 30(9): 1098-1101.
Hu Yu, Zhao Bao-jun, Shen Ting-zhi, *et al.* Facial image super-resolution reconstruction based on partial least squares[J]. *Transactions of Beijing Institute of Technology*, 2010, 30(9): 1098-1101.
- [10] Wu W, Liu Z, and He X. Learning-based super resolution using kernel partial least squares[J]. *Image and Vision Computing*, 2011, 29(6): 394-406.
- [11] 王惠文, 吴载斌, 孟洁. 偏最小二乘回归的线性与非线性方法[M]. 北京: 国防工业出版社, 2006: 97-104, 215-225.
Wang Hui-wen, Wu Zai-bin, and Meng Jie. *Partial Least-Squares Regression: Linear and Nonlinear Methods*[M]. Beijing: National Defense Industry Press, 2006: 97-104, 215-225.
- [12] Rosipal R and Krämer N. Overview and recent advances in partial least squares[J]. *Lecture Notes in Computer Science*, 2006, 3940: 34-51.
- [13] Chen S, Wang J, Ouyang Y, *et al.* Boosting part-sense multi-feature learners toward effective object detection[J]. *Computer Vision and Image Understanding*, 2011, 115(3): 364-374.
- [14] Chang C C. A boosting approach for supervised Mahalanobis distance metric learning[J]. *Pattern Recognition*, 2012, 45(2): 844-862.
- [15] Suresh S, Sundararajan N, and Saratchandran P. Risk-sensitive loss functions for sparse multi-category classification problems[J]. *Information Sciences*, 2008, 178(15): 2621-2638.
- [16] Gao X, Zhang K, Tao D, *et al.* Joint learning for single image super-resolution via coupled constraint[J]. *IEEE Transactions on Image Processing*, 2012, 21(2): 469-480.
- [17] Wang Z, Bovik A C, Sheikh H R, *et al.* Image quality assessment: from error measurement to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.
- 李小燕: 女, 1986 年生, 博士生, 研究方向为图像超分辨率重建.
和红杰: 女, 1971 年生, 副教授, 研究方向为数字图像处理、信息隐藏等.
尹忠科: 男, 1969 年生, 教授, 博士生导师, 研究领域为图像处理、信号和图像稀疏分解等.
陈帆: 男, 1971 年生, 副教授, 研究方向为多媒体信息安全、数字水印技术与应用.