

核偏最小二乘算法的图像超分辨率算法

吴 炜, 杨晓敏, 余艳梅, 石一兴, 何小海

(四川大学电子信息学院 成都 610064)

【摘要】提出了基于核偏最小二乘算法(KPLS)回归的超分辨率复原算法。该算法首先将高低分辨率图像块的高频信息和中频信息作为建立回归关系的特征,并对图像进行分块;依据相应的高低分辨率图像块的关系,使用KPLS建立起回归模型;在复原时,依据该模型回归得到高分辨率的图像块,将图像块拼接为高分辨率的图像。通过对人脸图像和车牌图像的实验结果,表明该算法无论是对人脸图像还是车牌图像都能取得较好的复原效果。

关键词 图像复原; 核偏最小二乘法(KPLS); 基于学习的超分辨率; 回归算法

中图分类号 TP391.1

文献标识码 A

doi:10.3969/j.issn.1001-0548.2011.01.020

Image Super-Resolution Using KPLS

WU Wei, YANG Xiao-min, YU Yan-mei, SHI Yi-xing, and HE Xiao-hai

(College of Electronics and Information Engineering, Sichuan University Chengdu 610064)

Abstract A learning-based super-resolution algorithm based on Kernel Partial Least Squares (KPLS) regression is proposed. First, KPLS regression algorithm is introduced. Then a super-resolution algorithm based on KPLS regression is analyzed. High resolution images use the high-frequency information as their feature, while low resolution images use middle-frequency as their features. Based on the relationship of the high and low resolution images, KPLS is used to set up regression model. The regression model is applied to infer high-resolution image. The experimental results show that our method can achieve very good results to face images and car plate images. The results of our method are closer to the real images.

Key words image restoration; Kernel partial least squares (KPLS); learning-based super-resolution; regression algorithm

图像的超分辨率技术^[1-3]是指由低分辨率图像复原出高分辨率图像,是一种十分重要的图像分析与计算机视觉技术,近年来已成为国际上图像复原领域最为活跃的研究课题,在自动目标识别、计算机视觉、遥感以及军事等领域有着非常广泛的应用前景。

目前常用的图像超分辨率技术主要是基于重建的超分辨率技术^[4],但其存在先验知识少、重建效果改进潜力不大等问题。基于学习的超分辨率技术是在基于重建的方法遇到困难的情况下发展起来的,它能够弥补基于重建方法的很多不足,只需要输入单幅图像,通过一个事先建立的图像库进行超分辨率复原。

文献[5-12]提出一些基于学习的超分辨率算法,其中有基于高斯金字塔和拉普拉斯金字塔模型的方法^[5,10-11]和基于多尺度和多方向特征的人脸超分辨率算法^[6],以及基于小波变换^[7,12]和Contourlet变

换^[8]的超分辨率复原方法。但是这些算法都使用类似于的“识别分类算法”,即在训练库中寻找最相似的特征,然后将最相似特征对应的高频信息作为高分辨率图像的估计,不可避免地造成一些“量化”误差。针对该问题,文献[9]提出基于支撑向量回归(support vector regression, SVR)方法的回归算法,虽然能够在一定程度上弥补“识别分类算法”造成的“量化”误差问题,但是SVR主要针对单值回归问题,将其应用于多值回归问题时没有充分考虑各个单值之间的相关性(相邻图像像素间存在较大的相关性),存在较多的需要调节的参数。

由于实际超分辨率回归问题本质上是一个多值回归问题(回归时必须考虑相邻像素值之间的相关性),使用SVR回归方法对其进行研究存在一定的缺陷。核偏最小二乘法(KPLS)^[13-14]是一种典型的多值非线性回归方法,回归时考虑多值之间的相关性,并只有少量参数需要调节。

收稿日期: 2009-08-08; 修回日期: 2010-05-19

基金项目: 教育部重点项目(107094); 国家自然科学基金(61071161)

作者简介: 吴 炜(1975-), 男, 博士后, 主要从事图像处理、图像识别和图像通信方面的研究。

本文提出了基于核偏最小二乘法(KPLS)回归的超分辨率复原算法。在研究和分析了基于KPLS回归的超分辨率复原算法的基础上,提出将高低分辨率图像块的高频信息和中频信息作为建立回归关系的特征,并对图像进行分块。然后依据相应的高低分辨率图像块的关系,使用KPLS建立回归模型。最后在复原时,依据该模型回归得到高分辨率的图像块,最终将图像块拼接为高分辨率的图像。

1 核偏最小二乘法(KPLS)^[14]

偏最小二乘法(PLS)不同于一般的数据分析方法,它集多元线性回归分析、典型相关分析和主成分分析的基本功能于一体,可以实现多种数据分析方法的综合应用,因此也被称为第二代回归方法。目前偏最小二乘法被广泛用于许多领域。

作为一个多元线性回归方法,偏最小二乘法的主要目的是要建立一个线性模型:

$$Y = XB + E \quad (1)$$

式中, $X = \{x_1, x_2, \dots, x_n\}$ 是一个由 n 个输入变量构成的 $n \times M$ 矩阵,其每一个元素 $x_i \in R^M$ 表示一个输入向量; $Y = \{y_1, y_2, \dots, y_n\}$ 是一个由 n 个输出向量构成的 $n \times L$ 的矩阵,其每一个元素 $y_i \in R^L$ 表示一个输出向量; B 是回归系数矩阵; E 为噪音校正模型,与 Y 具有相同的维数。

虽然PLS存在多种变种形式,但基本形式都是NIPALS (nonlinear iterative partial least squares)^[14]。NIPALS通过迭代的方法对成分 t 、 u 以及权重向量 w 、 c 进行求解。NIPALS算法寻找权重向量 w 、 c , 使得式(2)最大,即:

$$\max \|\text{cov}(t, u)\|^2 = \max [\text{cov}(Xw, Yc)]^2 \quad (2)$$

通过NIPALS算法提取一个成分后,对矩阵 X 、 Y 进行退化,并继续提取成分。如此往复,直到提取的成分进行回归能达到一个较为满意的精度为止。

回归矩阵 B 可表示为:

$$B = X^T U (T^T X X^T U)^{-1} T^T Y \quad (3)$$

式中,矩阵 T 和 U 分别是由成分 t 和 u 构成。设提取了 m 次成分, T 和 U 可分别表示为 $T = \{t_i\}_{i=1,2,\dots,m}$ 和 $U = \{u_i\}_{i=1,2,\dots,m}$, t_i 和 u_i 分别表示第 i 次提取的成分。

由于偏最小二乘法是一种线性方法,不能对非线性问题进行分析,而在实际中求解问题大多是非线性问题,因此在线性PLS算法基础上发展了许多非线性偏最小二乘(nonlinear PLS, NLPLS)方法。KPLS是利用核方法发展起来的非线性偏最小二乘法,是特征空间中的PLS算法,通过非线性映射 $\phi(\cdot)$

将原空间数据映射到高维特征空间,然后在特征空间中建立线性PLS模型,能够有效地改善PLS算法在非线性场合的效果,因此得到广泛研究。

通常不需要知道非线性映射 $\phi(\cdot)$ 的形式和特征空间的维数 H , 只需选择合适的核函数 K 即可。依靠线性变换 $\phi(\cdot)$ 能将原始输入空间映射到特征空间,特征空间的维数很高,并且可能是无穷维(当使用高斯核时)。这就需要使用核技巧解决 $\phi(\cdot)$ 映射问题。只要函数 $K(\cdot)$ 满足Mercer条件,都可以作为核函数。如果核函数 $K(x, y)$ 选择得当,就可以将输入空间的非线性问题转化为特征空间的线性问题。

假设存在一个非线性映射 ϕ 将输入变量 x_i 映射到特征空间 F :

$$\phi: x_i \in R^M \rightarrow \phi(x_i) \in F \quad (4)$$

KPLS的目标是在特征空间 F 建立线性PLS回归,就可以在原始的输入空间实现非线性回归。

如前所述, NIPALS算法的核形式就是将原空间数据通过非线性映射 $\phi(\cdot)$ 映射到高维特征空间,然后再在高维特征空间运用NIPALS算法建立PLS回归模型。设 Φ 为 $n \times H$ 的矩阵,其中第 i 行是向量 $\phi(x_i)$ 。NIPALS核形式的具体步骤为:

- 1) 随机初始化向量 u ;
- 2) $t = \Phi \Phi^T u$, $t \leftarrow t / \|t\|$;
- 3) $c = Y^T t$;
- 4) $u = Yc$, $u \leftarrow u / \|u\|$;
- 5) 重复步骤2)~4),直到收敛;

6) 退化 $\Phi \Phi^T$ 以及 Y 矩阵: $\Phi \Phi^T \leftarrow (\Phi - tt^T \Phi)(\Phi - tt^T \Phi)^T$, $Y \leftarrow Y - tt^T Y$, $\Phi \Phi^T$ 表示 $n \times n$ 的核矩阵 K ; $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ 。提取 m 个成分后,回归系数矩阵为:

$$B = \Phi^T U (T^T K U)^{-1} T^T Y \quad (5)$$

其中矩阵 T 、 U 与式(3)相同,是由成分 t 、 u 构成的。

使用 x_i 预测 y_i 为:

$$\hat{y}_i = \Phi_i^T B = K_i U (T^T K U)^{-1} T^T Y \quad (6)$$

式中, Φ_i 是测试样本的映射; K_i 为 $1 \times n$ 的矩阵; 元素 $K_j = K(x_i, x_j)$, 其中 $\{x_j\}$ 为训练样本, $j=1, 2, \dots, n$ 。

核函数的选取算法对回归性能有一定的影响。本文中,选取应用较为广泛的径向基核函数:

$$K(x, x_i) = \exp\{-|x - x_i|^2 / 2\sigma^2\} \quad (7)$$

2 基于KPLS超分辨率的基本原理

理想的高分辨率图像退化为低分辨率图像,其退化模型可表示为:

$$g(x, y) = \downarrow [f(x, y) * h(x, y)] + n(x, y) \quad (8)$$

式中, $f(x, y)$ 、 $g(x, y)$ 、 $n(x, y)$ 分别为原始清晰图像、退化图像和加性噪声; $h(x, y)$ 为成像系统的点扩展函数PSF; \downarrow 表示下采样。图像的超分辨率复原是上述过程的逆过程, 即从给定的退化低分辨率图像 $g(x, y)$ 获得高分辨率图像 $f(x, y)$ 的过程。

基于KPLS算法的超分辨率复原算法是将训练库中的高分辨率图像和低分辨率图像的关系看作为一种函数关系, 将低分辨率图像作为KPLS回归模型的输入, 高分辨率图像作为KPLS回归模型的输出, 建立回归模型; 然后利用训练后的回归模型对实际低分辨率图像进行复原。

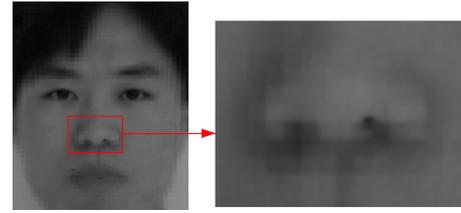
2.1 特征表示

设一幅高分辨率图像可由高频信息 H 、中频信息 M 、低频信息 L 组成, 其对应的低分辨率图像由中频信息 H 、低频信息 L 组成。超分辨率技术是在已知低分辨率图像的情况下, 复原(预测)其丢失的高频信息 H 。低分辨率图像的低频部分提供的信息有限, 而中频部分(在本文中指的是低分辨率图像的高频信息)能提供更多的有用信息, 根据文献[15]可认为最高频信息条件独立于最低频信息, 有:

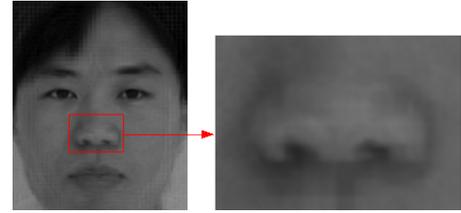
$$P(H|M, L) = P(H|M) \quad (9)$$

为了验证中频信息的有效性, 分别使用中频信息、低频信息(即图像的灰度值信息)以及单独使用中频信息进行高频信息的预测, 即图像的复原。实验结果如图1和图2所示, 通过比较可以看出, 使用中频信息和低频信息的复原结果细节容易模糊, 而单独使用中频特征的复原结果较好, 能够复原更多细节。这样超分辨率的任务就转为已知图像的中频信息, 恢复成高频信息。为了获得高频信息, 将训练库中的低分辨率图像进行插值(例如通过最近邻插值)放大为与高分辨率图像相同的分辨率, 然后将与其对应的高分辨率图像进行差分, 获得的差值图像即为高频信息。在超分辨率复原时, 只需要复原出其差值部分(即高频信息)。而对中频信息的提取, 本文采用先对训练库中的低分辨率图像进行插值(例如通过最近邻插值)放大, 然后通过放大后的图像提取拉普拉斯特征获取中频信息。

由于对整幅图像做回归会使计算量太大, 并且维数(100 pixel×100 pixel的图像为10 000维)远远大于样本数(样本数通常为100左右), 造成预测可能存在较大的误差。因此本文采用对图像进行分块, 然后分别复原各个分块图像的方法。



a. 复原结果图 b. 局部放大图
图1 使用中频信息和低频信息的复原结果



a. 复原结果图 b. 局部放大图

图2 使用中频信息的复原结果

本文将分别对采用位置相关方法和位置无关方法对人脸图像和车牌图像进行基于学习的超分辨率复原。正面人脸图像相对于其他图像具有一些特殊性, 它具有全局约束, 即不同人的鼻子、嘴、眼睛的位置相对于正面人脸来说, 基本上是固定不变的。在建立回归模型时, 本文利用这种位置相关的性质, 对不同位置的分块建立不同的回归模型, 既加快了运算速度, 又可以使回归模型建立得更为准确。

而对于车牌图像复原的信息是位置无关的, 在建立回归模型时, 需要将训练库中所有的不同位置的图像块建立一个单一的回归模型。考虑到对训练库中所有的不同位置的图像块建立一个单一的回归模型运算量太大(核矩阵的大小为训练样本数×图像的分块数, 如果训练样本为100, 图像为120 pixel×120 pixel大小, 分为6×6大小的块, 不考虑块与块之间的重叠, 则核矩阵大小为40 000×40 000的矩阵。将导致运算量巨大, 为了减少运算量, 本文在训练库中寻找与每个待复原的图像块最相似的 K (例如 $K=300$)个图像块。然后根据 K 个图像块建立相应的回归模型, 再依据该回归模型对相应的图像块进行复原。

2.2 基于KPLS的图像超分辨率复原算法

算法流程如图3所示。

算法可分为训练部分和学习部分。训练部分使用KPLS回归算法对训练库中的图像进行训练, 获得回归模型。为了获取高低分辨率图像的特征, 首先将每一幅低分辨率训练样本图像进行插值(使用最近邻插值)放大, 提取插值放大后图像的拉普拉斯特征, 即中频信息图像。然后将上一步生成的中频信息图像划分成多个 $n \times n$ (例如6×6)的中频信息块, 对于每一个块, 可以将其表示为一个向量 $\mathbf{x} \in \mathbb{R}^{36}$ 。

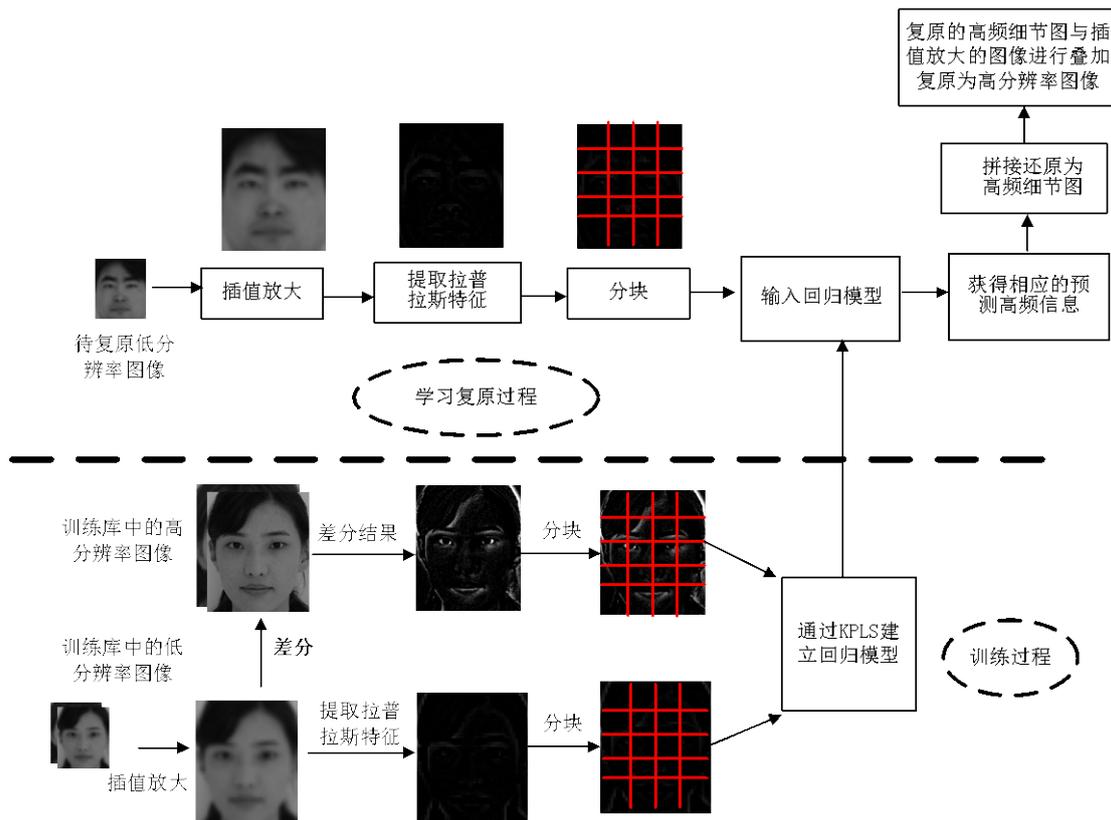


图3 基于KPLS的超分辨率算法流程图

对于人脸图像,考虑到位置相关性,将每一个训练样本的中频信息图像中位置为 (a,b) 的中频信息块构成一个向量矩阵 $\mathbf{X}^{a,b}=\{\mathbf{x}_i\}$, $i=1,2,\dots,N$, N 为样本数。其中 \mathbf{x}_i 为第 i 个训练样本的中频信息图像中位置为 (a,b) 的中频信息块。

将高分辨率图像与低分辨率插值放大的图像进行差分,得到一个差分图像,即高频信息图像。同样,将高频信息图像划分为多个 $n\times n$ (例如 6×6)的块。可将每一个块表示为一个向量 $\mathbf{y}\in R^{36}$ 。每幅生成的高频信息图像位置为 (a,b) 的高频信息块都可以构成一个向量矩阵 $\mathbf{Y}^{a,b}=\{\mathbf{y}_i\}$, $i=1,2,\dots,N$ 。其中 \mathbf{y}_i 为第 i 个训练样本高频信息图像位置为 (a,b) 的高频信息块。最后将位置为 (a,b) 的向量矩阵 $\mathbf{X}^{a,b}$ 和 $\mathbf{Y}^{a,b}$ 作为回归输入和回归输出代入KPLS回归算法进行计算,以获得位置为 (a,b) 上的KPLS回归模型。

而车牌图像复原是位置无关的,在建立回归模型时,为了减少运算量,本文在训练库中寻找与每个待复原图像的中频信息块(设图像块的位置为 (a,b))最相似的 K (如 $K=300$)个中频信息块 $\mathbf{X}^{a,b}=\{\mathbf{x}_v\}$, $v=1,2,\dots,K$,以及其对应的高频信息块 $\mathbf{Y}^{a,b}=\{\mathbf{y}_v\}$ 。然后根据 $\mathbf{X}^{a,b}$ 和 $\mathbf{Y}^{a,b}$ 建立相应的回归模型,获得相应的KPLS回归模型。

学习部分是利用训练部分获取的回归模型对待复原的低分辨率图像进行复原。首先将输入的待复原的低分辨率图像进行插值(使用最近邻插值)放大,提取插值放大后图像的高频信息(即拉普拉斯特征);然后将上一步生成的特征图像划分成多个 $n\times n$ (例如 6×6)的图像块,对于位置为 (i,j) 的块,将其表示为一个向量。通过式(6)计算KPLS回归结果。

将每一个图像块的回归结果向量还原为二维图像块,并按照顺序拼接为复原需要的高频信息。最后将该高频信息和待复原的低分辨率图像进行插值放大后的图像求和,复原出最终的高分辨率图像。

3 实验结果与分析

实验 1 人脸图像的超分辨率复原实验

a. SVR算法的结果

b. 本文算法的结果

c. 最近邻插值算法的结果 d. Cubic B-Spline算法的结果

e. 真实的高分辨率图像

图4 实验结果图

实验中使用亚洲人脸标准图像数据库IMDB^[16]中的人脸图像。本文提取人脸的面部图像, 并进行归一化, 将归一化为192×160的人脸图像作为高分辨率人脸图像, 对其进行降质处理, 降质为大小为48×40的图像, 作为低分辨率人脸图像。实验首先选取了所有不带眼镜的75人进行实验, 选每人正面中性表情人脸图像1幅, 共75幅。随机选择其中的8人, 其中4名男性和4名女性(8幅人脸图像)作为测试样本, 剩下的67人(67幅人脸图像)作为训练样本。将Cubic B-Spline插值方法和最近邻插值方法及基于SVR的超分辨率算法与本文提出的基于KPLS的超分辨率算法的实验结果进行了比较, 如图4所示。可以看出: 最近邻插值算法和Cubic B-Spline插值算法在插值复原放大时模糊了大部分的人脸细节, 基于SVR回归算法的结果复原出部分人脸图像的细节, 而本文算法的结果较为清楚地复原出了人脸图像的细节。

图5为不同方法的平均峰值信噪比图。平均峰值信噪比是指多幅测试图像峰值信噪比的平均。峰值信噪比定义为:

$$PSNR = 20 \times \lg \left(\frac{255}{\sqrt{\frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N [HR(x, y) - SR(x, y)]^2}} \right) \quad (10)$$

式中, HR为原始的高分辨率图像; SR为由低分辨率图像复原得到的超分辨率图像; HR(x,y)和SR(x,y)分

别为它们在像素点(x,y)上的灰度值。图像的长度和宽度以像素点数表征分别为M和N。

从图5可以看出, 基于KPLS的回归算法取得了最高的峰值信噪比; 基于SVR的回归算法取得了第二高的峰值信噪比, 比本文算法低1.3 dB; 插值算法的峰值信噪比最低, 比基于SVR的回归算法还低1 dB左右。

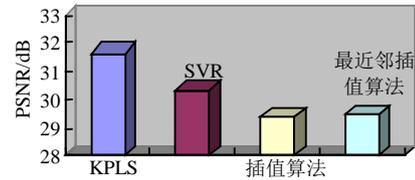


图5 不同方法的平均峰值信噪比的示意图

实验2 车牌图像的超分辨率复原实验

将车牌作为研究对象进行实验。收集105幅带有车牌的图像, 将其车牌部分图像提取出来, 大小为180 pixel×68 pixel。将提取的车牌图像作为高分辨率图像进行降质处理, 分别降质为45 pixel×17 pixel大小的图像。实验中随机选择其中的5幅车牌图像作为测试样本, 剩下的100幅车牌图像作为训练样本。图6为实验中的部分车牌图像。



图6 实验中的部分车牌图像

图7为车牌图像的实验结果图对比图。图7中第1行为最近邻插值算法的结果, 第2行为Cubic B-Spline插值算法的结果, 第3行为本文算法的结果, 第4行为真实的高分辨率车牌图像。从实验结果图中可以看出, 最近邻插值算法字符复原结果效果很差, 复原图像的某些英文字母不是很清楚。Cubic B-Spline方法插值效果稍好, 但是车牌中的汉字还是较模糊, 辨识出汉字较为困难。本文算法虽然与真实图像有差异, 但是无论是英文字母还是汉字都得到了较好的复原, 都有清晰的边缘。总的来说, 本文算法较好地复原出高频信息, 使得复原的图像结果在视觉上与真实的高分辨率图像较为接近。

图7 车牌图像的实验结果图对比图

表1为不同方法的平均峰值信噪比, 可以看出本

文算法复原的峰值信噪比远大于插值算法的峰值信噪比。

表1 不同算法的平均峰值信噪比

算法	平均峰值信噪比(PSNR)
本文算法	22.13
Cubic B-Spline方法插值	17.99
最近邻插值结果	17.89

分块大小的不同将影响复原结果。为了对分块大小进行分析,分别将人脸图像和车牌图像的分块设置为不同的大小,并评价在该分块条件下的峰值信噪比。图8和图9分别为人脸图像和车牌图像在分块为4×4、6×6、8×8、10×10、12×12、14×14、16×16条件下的峰值信噪比。在人脸图像的实验中,6×6的分块为最优;而在车牌图像实验中,10×10的分块为最优,分块太小或太大都会导致性能下降。人脸图像和车牌图像最优分块大小的不同主要是由于它们为不同类别的图像,存在不同的纹理信息,使得它们的中频以及高频信息的统计特性存在较大差异,导致最优分块大小的图像。

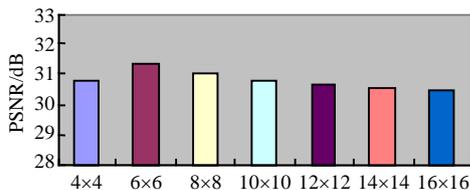


图8 不同分块条件下的复原的人脸图像的PSNR

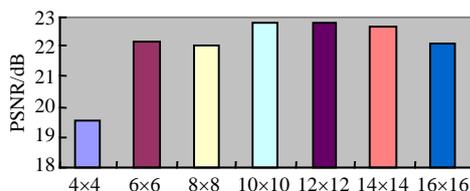


图9 不同分块条件下的复原的车牌图像的PSNR

4 总结

本文在国内外研究中首次提出了基于核偏最小二乘法(KPLS)回归的超分辨率复原算法。通过对人脸图像和车牌图像的实验结果表明,该方法能取得较好的复原效果;并且在放大倍数较大的情况下,仍然可取得较好的复原效果,复原出的图像更接近于真实图像,具有更高的峰值信噪比。

本文研究工作得到四川大学电子信息学院青年教师基金的资助,在此表示感谢。

参考文献

- [1] VAN J D. Image super-resolution survey[J]. Image and Vision Computing, 2006, 24(10): 1039-1052
- [2] AVOINNE C, RASHID T, CHOWDHURY V, et al. Second-order compensated bandgap reference with convex correction[J]. Electronic Letters, 2005, 41(5): 276-277.
- [3] 郑丽贤, 何小海, 吴炜, 等. 基于学习的超分辨率技术[J]. 计算机工程, 2008, 34(5): 193-195.
ZHENG Li-xian, HE Xiao-hai, WU Wei, et al. Learning-based super-resolution technique[J]. Computer Engineering, 2008, 34(5): 193-195.
- [4] QIN Feng-qing, HE Xiao-hai, WU Wei. Image super-resolution reconstruction based on sub-pixel registration and iterative back projection[C]//Proceedings of the International Conference 2007 on Information Computing and Automation ICICA. Chengdu: [s.n.], 2007.
- [5] BAKER S, KANADE T. Limits on super-resolution and how to break them[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(9): 1167-1183.
- [6] SU C, ZHUANG Y, HUANG L, et al. Steerable pyramid based face hallucination[J]. Pattern Recognition, 2005, 38(6): 813-824.
- [7] JIJI C V, CHAUDHURI S. Single frame super-resolution using learned wavelet coefficients[J]. International Journal of Imaging Systems and Technology, 2004, 14(3): 105-112.
- [8] JIJI C V, CHAUDHURI S. Single-frame images super-resolution through contourlet learning[J]. EURASIP Journal on Applied Signal Processing, 2006, (ID73767): 1-11.
- [9] NI K S, TRUONG Q N. Image superresolution using support vector regression[J]. IEEE Transactions on Image Processing, 2007, 16(6): 1596-1610.
- [10] 郑丽贤, 吴炜, 杨晓敏, 等. 基于多分辨率塔式结构的幻觉脸技术的研究[J]. 光电子激光, 2008, 19(9): 1244-1249.
ZHENG Li-xian, WU Wei, YANG Xiao-min, et al. The research of face hallucination based on multi-resolution pyramid structure[J]. Journal of Optoelectronics Laser, 2008, 19(9): 1244-1249.
- [11] 吴炜, 杨晓敏, 陈默, 等. 一种新颖的人脸图像超分辨率技术[J]. 光学精密工程, 2008, 16(5): 815-821.
WU Wei, YANG Xiao-min, CHEN Mo, et al. Novel method of face hallucination[J]. Optics and Precision Engineering, 2008, 16(5): 815-821.
- [12] 乔建苹, 刘璐, 闰华, 等. 基于Log-W T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.
- [13] ROMAN R, NICOLE K. Overview and recent advances in partial least squares[C]//Lecture Notes in Computer Science. Heidelberg: Springer, 2006.
- [14] ROMAN R. Kernel partial least squares regression in reproducing kernel hilbert space[J]. Journal of Machine Learning Research, 2001, 2(6): 97-123.
- [15] FREEMAN W T, PASZTOR E C, CARMICHAEL O T. Learning low-level vision[J]. International Journal of Computer Vision, 2000, 40(10): 25-47.
- [16] Dong H, GU N. Asian face image database PF01[DB/OL]. [2006-01-05]. <http://nava.postech.ac.kr/archives/irndb.html>.

编辑 税红