

支持向量机多特征分类学习的超分辨率复原

汤嘉立¹, 朱广萍¹, 杜卓明^{1,2}

(1.江苏理工学院计算机工程学院, 江苏 常州 213001)

(2.南京师范大学数学科学学院, 江苏 南京 210023)

[摘要] 支持向量机(SVM)单一特征分类学习的超分辨率复原算法通过离线建立分类模型和减少样本库规模,降低了传统基于范例学习算法的样本块误匹配情况,增强了图像质量和计算速度.但由于图像特征的多样性,此类算法易造成复原结果的不稳定.本文给出一种以支持向量机多特征分类学习为基础的复原算法,将图像对应的颜色和纹理分类信息存储在样本库中,经过预分类筛选出样本子集,在高频预测时段直接从多特征相似的样本子集里实施准确的匹配检索.实验结果表明,相比于传统算法,本文算法的 *PSNR* 和 *SSIM* 值均有了一定提升,进一步精确匹配了低分辨率图像样本库,提高了复原效果.

[关键词] 超分辨率复原,支持向量机,多特征分类,样本学习

[中图分类号] TP391 [文献标志码] A [文章编号] 1001-4616(2018)03-0028-07

Super-resolution Restoration Algorithm Based on SVM Multi-figure Classification Learning

Tang Jiali¹, Zhu Guangping¹, Du Zhuoming^{1,2}

(1.College of Computer Engineering, Jiangsu University of Technology, Changzhou 213001, China)

(2.School of Mathematical Sciences, Nanjing Normal University, Nanjing 210023, China)

Abstract: The SVM pre-classified super-resolution algorithm is based on single image feature and builds off-line disaggregated models. It reduces the mis-matching of traditional example-based restoration algorithms, improves the image quality and running speed. However, the SVM-based algorithm easily leads to unstable recovered results because of the diversity of image features. For such problems, we propose a super-resolution restoration algorithm based on multi-figure classification learning. The algorithm saves the corresponding color-texture information into the sample set and selects object subset by SVM pre-classified learning. Then in the high frequency prediction process it makes precise matching search from the subset of sample database which has similar color and texture features with the object image. Experimental results show that compared with traditional algorithms, *PSNR* and *SSIM* are improved respectively. In addition, the proposed algorithm further reduces the matching range of low resolution image blocks and promotes the restoration effectiveness.

Key words: super-resolution restoration, support vector machine, multi-figure classification, sample learning

图像超分辨率(super resolution, SR)复原作为一种图像后处理手段,以数字信号处理理论为技术基础,是一种不需要改变硬件设备而能有效提高图像分辨率的方法.近年来,超分辨率复原算法已成为一种提高图像空间分辨率的有效途径,在各种领域应用广泛^[1-4].

现在主要的超分辨率复原算法通常分为基于重建和基于学习两类.基于重建的超分辨率技术将其复原难题看作为具有一定约束条件的数学优化问题.首先,建立低分辨率图像生成环节中的数学模型,其中,复原图像的约束条件通过正则化手段来表示;再者,从记录到的低分辨率图像来预测和复原高分辨率图像.基于重建的算法在图像上采样的病态问题中引入先验知识,从而将其转化为良态问题,其算法都存

收稿日期:2018-04-16.

基金项目:国家自然科学基金(61402206)、中国博士后科学基金(2016M601845)、住房城乡建设部研究开发项目(2016-K8-028).

通讯联系人:汤嘉立,博士,副教授,研究方向:图像处理、模式识别. E-mail: tangjl@jstn.edu.cn

在着一定的运算局限性^[5-7];目前来说,以学习为基础的超分辨率算法逐渐得到学术界的关注. Freeman^[8]首先给出以学习为基础的超分辨率复原算法概念,即为通过学习的手段来获取先验知识参与重构过程中的优化,经过学习训练汇集成对高分辨率(HR)与低分辨率(LR)图像的相应讯息获取先验知识,再经过学习到的对应联系估计图像的高频讯息,从而获得更好的复原效果.但是现在此种手段在处理小样本、高维特征等方面问题时特别难以得到人们想要的结果,或是泛化能力差,亦或是学习速度不快、很难收敛,致使没有办法得到较好的图像质量.因为当前学习方法一般也是以样本数量趋向于无穷大时的渐近思想为基础的^[8-10],可是在实践过程中,样本数量通常非常少,所以在实践运用中的表现不尽如人意.

对于以学习手段为基础的复原方法具有泛化能力差、学习速度慢、误匹配概率大等问题,本文给出以颜色和纹理支持向量机多特征分类学习为基础的超分辨率复原.该算法将SVM当做分类器,依据图像的颜色和纹理综合特点对样本库实施相应的预分类,从而高效地选择出和重建目标图像两种特点类似的样本子库,减少算法的计算时间,很大程度上减少误匹配概率,达到增强图像复原质量的目标.

1 支持向量机分类原理

Vapnik等学者提出了一种符合小数量的机器学习理论——统计学习理论,并慢慢使这个理论得以完备^[11].建立在该理论上的支持向量机已经成为构造预算规则的通用手段.Vapnik以VC维(Vapnik-Chervonenkis Dimension)理论与结构风险最小原理为基础构建统计学习理论.VC维是形容学习器的庞杂性及学习能力的一个关键内容,依据结构风险最小化原则进行推理则可以避免过学习现象.在此之前,机器学习的理论核心是经验风险最小化原则,但是这种原则无法兼顾模型对特定训练样本的学习精度以及正确识别其他任何样本的能力,常常会导致学习器过学习.支持向量机手段以统计学习理论为条件,依据很少的样本信息在模拟的学习能力与庞杂性中间找到最优平衡,以创立具有最优扩展能力的学习器.

Vapnik的SVM方法具有以下特点:

(1)把很少样本上的学习问题转变成对偶寻优策略,避免出现局部极值问题,学习结果将收敛到全局最优.

(2)对于线性不可分的分类问题,将低维特征空间线性不可分的难题变化成高维空间线性可分的方法,从而使得线性学习器实现非线性拓展,并具有很好的推广能力.

自从Vapnik提出以来,学者们对SVM算法给出了很多创新,使其实际运用领域不断拓展.但是,尽管能很好地完成许多实际任务,它在计算上依然存在需要克服的困难,支持向量机的训练算法速度是限制其应用的主要方面.训练算法慢的关键原因在于处理对偶问题时使用标准二次型优化手段.首先,核函数矩阵计算所需的内存空间特别大(尤其是样本点数比较大时);再者,在二次型寻优环节里矩阵计算需要花费很多时间,因此寻优在大部分状态下占了算法时间的很大一部分.

为了处理支持向量机的对偶寻优问题,学者们对于SVM的特点给出了非常多算法.大部分算法都基于分治和迭代策略,首先将原始问题转化成一些子问题,然后经过反复循环迭代解决子问题,最后让结果收敛到起始问题的最优化结果.

2 SVM多特征分类学习的超分辨率算法

为了进一步增加超分辨率复原的样本分类计算速率和匹配精度,指出以支持向量机多特征分类学习为基础的超分辨率复原解决方案,本文采用支持向量机对样本库归类,为输入的LR块快速确定其所属类别.以支持向量机多特征分类学习为基础的超分辨率复原算法见图1.在Freeman提出的算法^[8]中引入了支持向量机多特征分类过程,即图1中虚线框内部分.事先根据某种图像特征离线建立分类模型,在复原过程中对输入LR样本块由SVM

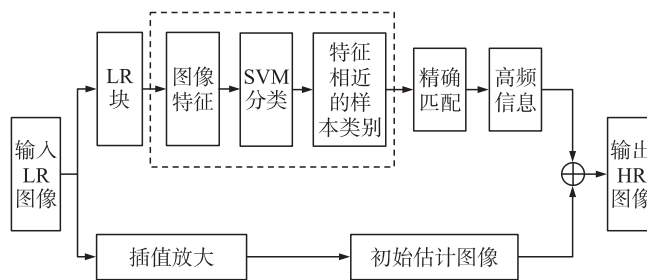


图1 支持向量机多特征分类学习的超分辨率复原过程

Fig. 1 Super-resolution restoration based on SVM multi-figure classification learning

分类模型直接确定其所属类别,完成样本预分类.

首先按颜色与纹理特点离线建立 SVM 分类模型,在 LR 块精确匹配前采用 SVM 归类模型实施归类,得到 LR 块所属的颜色、纹理特征的相关类别,然后在相关类别的样本中进行精确匹配.

2.1 图像客观质量评价标准

实验采用两种客观质量评价标准对目标 HR 图像进行评价.

(1) 峰值信噪比 PSNR

图像客观质量评估一般采用复原图像和初始图像的偏离误差来比较图像还原的效果,最常用的评价标准是均方差(mean squared error, MSE)和峰值信噪比(peak signal-to-noise ratio, $PSNR$).

假设当前图像,即复原图像为 X ,参考图像为 Y ,图像的高度为 H ,图像的宽度为 W ,对于 $H \times W$ 大小的两幅图像 X 和 Y ,均方误差 MSE 的表达式为:

$$MSE = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (X(i,j) - Y(i,j))^2, \quad (1)$$

式中, $1 \leq i \leq H, 1 \leq j \leq W$.

峰值信噪比 $PSNR$ 是一项全参考的图像效果评估方法. 其表达式为:

$$PSNR = 10 \log_{10} \frac{(2^n - 1)^2}{MSN}. \quad (2)$$

$PSNR$ 以 dB 为单位,其值愈大则失真愈小. 式(2)里, n 是每像素的比特数,通常取 8,也就是像素灰阶数是 256. n 取 8 时, $PSNR$ 表达式为:

$$PSNR = 10 \times \lg \frac{255 \times 255}{MSE}. \quad (3)$$

(2) 结构相似性 SSIM

作为最常用的图像客观评估手段, $PSNR$ 是针对两幅图像相应像素点间的偏差进而评价图像质量,是误差敏感的评估手段. 但是,人对图像的视觉感知受多方面因素的影响,而并不仅限于图像的 $PSNR$ 值,比如,人眼对亮度比对色度更为敏感,对一个区域的感觉会受其邻近区域的影响等等. $PSNR$ 评价指标中并没有考虑到这些因素,从而常常得到评估结果和主观认识不同的状况. 为了克服 $PSNR$ 指标的局限性, Zhou Wang 提出了一种结构相似性评价指标(structural similarity, $SSIM$)^[12].

$SSIM$ 从对比度、亮度、结构这 3 个因素来衡量图像的类似性. 假设 $l(X, Y)$ 、 $c(X, Y)$ 和 $s(X, Y)$ 分别代表图像 X 和 Y 的亮度相似性、对比度相似性和结构相似性,其表达式为:

$$l(X, Y) = \frac{2\mu_X \mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1}, \quad (4)$$

$$c(X, Y) = \frac{2\sigma_X \sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2}, \quad (5)$$

$$s(X, Y) = \frac{\sigma_{XY} + C_3}{\sigma_X \sigma_Y + C_3}, \quad (6)$$

式(4)、(5)、(6)中, μ_X, μ_Y 依次代表 X 与 Y 的平均数, σ_X, σ_Y 依次代表 X 与 Y 的方差, σ_{XY} 代表 X 与 Y 的协方差. 其中, C_1, C_2, C_3 为常数,为了避免分母为 0 的情况,通常取 $C_1 = (K_1 \times L)^2, C_2 = (K_2 \times L)^2, C_3 = C_2/2$,一般地 $K_1 = 0.01, K_2 = 0.03, L = 255$ ^[13]. 则有:

$$SSIM(X, Y) = l(X, Y) \cdot c(X, Y) \cdot s(X, Y). \quad (7)$$

$SSIM$ 的大小在 $[0, 1]$ 之间,其值愈大,代表图像失真愈小. 该指标能较好地客观反映图像的视觉效果.

2.2 样本的颜色和纹理特征提取

(1) 颜色特征提取

颜色特征说明了图像与图像区域的表面特性,是图像本身重要的全局特点,也是图像最直观的视觉特征^[14]. 相对于其他各种图像特点,颜色特征拥有两个显著优势:一是稳定,针对图像的比如平移、旋转等不同类的改变敏感度不高,鲁棒性非常强;二是计算复杂度低,将图像中的像素值进行转换,用对应的数值表现便得到图像特征.

颜色直方图阐述了不同颜色在一幅图像里所具有的比例. 有的应用场合中不必分析物体在图像中的位置,或者图像很难自动分割,此时颜色直方图尤其可以发挥作用. 所以,使用颜色直方图法来对样本颜色实施特征定义.

通过彩色图像中 RGB 颜色通道的联合概率密度函数来定义颜色直方图^[15]:

$$h_{R,G,B}(a,b,c) = N \cdot P(R=a, G=b, B=c), \quad (8)$$

式中, R, G, B 代表颜色通道, N 代表像素大小, h 代表直方图函数, P 代表概率密度函数. 对于某一颜色,它在图像里所具有的比例是一种重要度量. 综合考虑,本文定义其为一个四维特征向量 $\mathbf{H}(H_R, H_G, H_B, \mu)$, RGB 的 3 个颜色通道分别由第 1 维 H_R 、第 2 维 H_G 和第 3 维 H_B 表示,第 4 维 μ 则指颜色比例. 将该四维特征向量作为 SVM 的颜色输入向量.

代表颜色直方图需使用高维向量数组. 而且,对于 RGB 空间,直接表示它共需 $256 \times 256 \times 256$ 个向量. 更进一步地,处理图像时需要直方图进行相关计算,将会耗费大量计算资源. 一种常用的解决途径是通过量化直方图以使需要的向量数目极大地减少. 本文使用的量化级是 8,进而将颜色量化为 $8 \times 8 \times 8 = 512$ 个,从而保证算法性能与计算量的平衡.

(2) 纹理特征提取

纹理为图像的一种低层物理特点,为表现物体表面特性中重复性结构的内在特征. 通常指出,纹理为目标图像灰度亦或是色彩在空间通过某种形式的改变而出现的图案与模式^[16]. 从感觉上来看,纹理图像大致可分为三种情况:第一,灰度分布拥有一定的周期性,就算灰度改变是随机的,其也拥有某种统计特点,可能在更大的区域里反复出现;第二,构成序列的基本成分是有一定规则而不是随机的;第三,纹理区域里的各部分纹理显示出大体相同的尺寸、结构和形象,整体上分布均匀. 当然,主观感觉还不可以取代对纹理的精确测量. 由于纹理给人们的感觉是各式各样的,对纹理特点的描述手段同样具有多变性.

根据文献[17]的计算方法,定义一个纹理的四维特征向量 $\mathbf{T}(M, C, A, E)$. 其中,统计任一像素点灰度差值 s 的直方图, M 是均值, C 是对比度, A 是角度方向二阶矩, E 是熵.

2.3 SVM 多特征分类和高分辨率图像复原

国内外已经有很多 SVM 的软件包,其中比较知名的有 LibSVM 与 LibLinear 等. LibSVM (<https://www.csie.ntu.edu.tw/~cjlin/libsvm/>) 由林智仁教授等设计开发,它不仅提供可执行文件,而且提供源代码,以便用户根据实际任务的需求来修改、利用源代码. LibSVM 软件包提供了诸多默认参数以及交叉验证的功能,具有简单易用和快速有效的优点,得到了广泛应用.

实验采用 LibSVM 软件根据多特征向量对样本库进行 SVM 分类. 核函数有许多种,常用的有径向基核函数、Sigmoid 核函数、拉普拉斯核函数、线性核函数和多项式核函数等等. 由于事先并不知道何种核函数合适,而核函数也只是隐式地定义再生的特征空间,选择核函数及其合适的参数成为设计支持向量机的主要内容. 已有研究表明,支持向量机分类器效果好坏的重点并不在于核函数,而是在于核函数参数及惩罚系数 C ^[18]. 本文使用式(9)定义的径向基核函数:

$$K(x, x_i) = \exp(-\gamma |x - x_i|^2). \quad (9)$$

使用网格搜索交叉确认 C 和 γ 的取值. 网格搜索具有直接、简单的优点. 尝试每个 (C, γ) 的参数对,接着选择在交叉确认里精确性最好的一个,并以此作为参数取值. 主要过程包括以下 4 步^[18]:

(1) 计算发现合适的核参数集与正则化参数集. 两种参数集可以按指数增长的方式产生,例如, C 的参数集为 $\{2^{-10}, 2^{-9}, 2^{-8}, \dots, 2^1, \dots, 2^{10}\}$, γ 的参数集为 $\{2^{-10}, 2^{-9}, 2^{-8}, \dots, 2^{-1}\}$;

(2) 使用网格搜索选择某个参数对 (C, γ) , 实施交叉验证,并计算其分类准确率;

(3) 反复执行(2)直至网格搜索停止;

(4) 将最优参数对 (C, γ) 作为 C 与 γ 的取值.

值得注意的是,由于每个参数对 (C, γ) 均是独立的,网络搜索可以并行地执行,从而提高时间效率. LibSVM 实现了 grid.py 程序来对参数进行优化,并能以图形形式显示优化的过程和结果.

对每个图像类,将颜色特征向量 $\mathbf{H}(H_R, H_G, H_B, \mu)$ 和纹理特征向量 $\mathbf{T}(M, C, A, E)$ 组合,得到的新组合向量 $\mathbf{Z}(H_R, H_G, H_B, M, C, A, E, \mu)$ 可以作为 SVM 的输入向量开始学习. 预分类完成后,依据测试图像归类在相应的样本子集里对所有图像样本进行检索匹配. 算法预测获得的图像块在边界上重叠. 当在样本库

里检索时,也需使用初始预测时获得的高分辨率数据. 可以使用自定义的加权系数 α 来调节高分辨率和低分辨率图像块重叠性的相对重要度. 依据文献[8]的研究结果,假如高分辨率块是 $N \times N$,低分辨率块是 $M \times M$,通过公式 $\alpha = 0.1M^2 / (2N - 1)$ 计算可以得到较好的图像超分辨率复原效果. 本实验使用 $M = 7, N = 5$,得出加权系数 α 为 0.54.

SVM 分类器找到匹配图像块后,将对应 HR 图像块的高频信息加入插值放大后的图像上,从而输出复原的 HR 图像.

3 实验结果与分析

实验图像选自国外常用标准测试图像库,选择 Airplane、Baboon、Mountain、Peppers 等 20 幅图像作为实验测试图像. 对原始图像进行高斯模糊后再 2 倍下采样,使其成为低分辨率测试图像. 将低分辨率测试图像放大到原来高分辨率图像的大小来进行客观性能测试和主观效果分析. 采用 Matlab 程序来实现复原算法.

3.1 样本库的建立

训练样本库对基于学习的超分辨率图像复原结果影响很大. 实验采用与文献[9]类似的方法建立样本库. 练习样本从成对的 HR 和 LR 图像中通过三级拉普拉斯分解提取,每个样本由 HR 信息块与对应的 LR 信息块组成. 首先对用于练习的 HR 样本图像 P_0 实施高斯模糊及下采样,获得 LR 图像 P_1 ;接着对 P_1 实施双线性插值,把它放大至 P_0 的尺寸,相减得到 P_0 中具有的高频信息 P_0 ;再同样处理 P_1 和更低分辨率的 P_2 ,得到它们的差图像 P_1 ;最后,从差图像 P_0 和 P_1 中提取训练样本.

P_0 中的任何 HR 图像块在 P_1 中都有一个对应的 LR 图像块. 当下采样系数为 2 时, P_0 中 HR 图像块则是 4×4 ,在 P_1 中相应的 LR 图像块就为 2×2 . 由于图像块与其相邻块间常常出现内容不连续的情况,故将 P_1 中的 LR 图像块向四周扩展一个像素. 练习样本组成样本库,某个样本则可以依据两幅差图像里相应位置的图像块组成,其中图像块的坐标可以为任意.

3.2 PSNR、SSIM 和算法运行时间测试结果

对 20 幅图像进行超分辨率复原,通过 PSNR 与 SSIM 值来分析图像的客观性能. 该算法的 PSNR 和 SSIM 测试结果见表 1 所示.

表 1 基于 SVM 多特征分类学习复原算法的 PSNR 和 SSIM
Table 1 PSNR and SSIM of SVM multi-figure classification learning

	图像									
	1 Airplane	2 Cathedral	3 Elaine	4 Flower	5 Snow	6 Baboon	7 Food	8 Horse	9 Lena	10 Mountain
PSNR	24.51	23.79	22.82	25.19	25.72	22.89	25.17	24.76	23.76	23.03
SSIM	0.751 8	0.831 1	0.804 5	0.785 7	0.793 6	0.773 4	0.833 6	0.845 5	0.782 6	0.851 3
	图像									
	11 Peppers	12 Sea	13 Tree	14 Boat	15 Hat	16 Bus	17 House	18 Man	19 Parrot	20 Plants
PSNR	24.64	24.92	24.09	22.53	23.87	24.34	24.18	22.12	24.77	24.15
SSIM	0.839 2	0.837 3	0.851 2	0.796 2	0.810 2	0.807 5	0.850 8	0.870 4	0.791 9	0.817 3

该算法的运行时间测试结果见表 2.

表 2 SVM 复原算法的运行时间
Table 2 Running time of SVM restoration algorithm

	图像									
	1 Airplane	2 Cathedral	3 Elaine	4 Flower	5 Snow	6 Baboon	7 Food	8 Horse	9 Lena	10 Mountain
时间/s	203.77	204.05	186.69	193.47	200.17	197.06	163.58	162.39	186.41	179.54
	图像									
	11 Peppers	12 Sea	13 Tree	14 Boat	15 Hat	16 Bus	17 House	18 Man	19 Parrot	20 Plants
时间/s	195.04	157.84	205.84	180.73	180.44	191.27	172.89	174.42	221.37	188.26

3.3 图像复原结果

图 2 列出了 5 幅图像的支持向量机多特征分类学习算法等 4 种算法的复原情况. 5 幅图像从上到下依次是 Airplane、Cathedral、Elaine、Flower、Snow, 从左到右依次是双线性插值算法、Freeman 算法、文献[17]算法、SVM 多特征分类学习算法的复原结果.




图 2 SVM 学习的复原算法等 4 种算法的复原结果

Fig. 2 Restoration results of four algorithms of SVM learning, etc.

3.4 结果分析讨论

根据表 1 得到 SVM 多特征分类学习的复原算法结果, 分别与其余 3 种算法进行比较. $PSNR$ 和 $SSIM$ 比较曲线分别见图 3 和图 4.

由图 3 可以直观地看出, 在客观性能 $PSNR$ 方面, SVM 多特征分类学习的复原算法性能最佳, 在各幅图像上普遍大于其余 3 种算法, 而文献[17]算法普遍略比 Freeman 算法大, 使用双线性插值的 $PSNR$ 结果一般比较小.




图 3 SVM 学习的复原算法等 4 种算法的 PSNR 曲线
Fig. 3 PSNR Curves of four algorithms of SVM learning, etc.




图 4 SVM 学习的复原算法等 4 种算法的 SSIM 曲线
Fig. 4 SSIM Curves of four algorithms of SVM learning, etc.

由图 4 能够得出,在客观性能 *SSIM* 方面,双线性插值的总体性能较差,SVM 多特征分类学习的复原算法性能最佳,在各幅图像上普遍大于其余 3 种算法,而文献[17]算法普遍略比 Freeman 算法大,使用双线性插值的 *SSIM* 结果一般比较小。

根据表 2,统计 SVM 多特征分类学习的复原算法和 Freeman 算法、文献[17]算法运行时间的平均值、最大值、最小值,计算结果见表 3。在平均运行时间上,SVM 分类学习的复原算法是 Freeman 算法的 26.76%,是文献[17]算法的 75.11%。

4 结语

本文提出一种以 SVM 多特征分类学习为基础的超分辨率复原算法,使用支持向量机分类器进行颜色和纹理多特征分类,从而很好地减少图像块的误匹配现象,减少样本子库容量,节省算法运算时间,得到主客观质量更高的图像复原效果。该算法将图像颜色和纹理特征向量通过归一化过后得到组合特征,有效筛选出与复原目标图像类似的样本子库。实验结果证明,基于 SVM 多特征分类学习方法的复原效果优于 Freeman 经典算法,并且优于基于颜色或者纹理单一特征的分类改进算法。

表 3 3 种算法的运行时间比较

Table 3 Running time contrast of three algorithms

		Freeman 算法	文献[17]算法	SVM 学习的复原算法
运行时间	平均值	699.83	249.3	187.26
	最大值	748.44	286.27	221.37
	最小值	643.21	218.03	157.84

[参考文献]

[1] WANG J J,ZHU S,GONG Y. Resolution enhancement based on learning the sparse association of image patches[J]. Pattern recognition letters,2010,31(1) :1-10.

[2] KURSUN O,FAVOROV O. Single-frame super resolution by inference from learned features[J]. Istanbul university journal of electrical and electronics engineering,2003,3(1) :673-681.

[3] KATSUKI T,TORII A,INOUE M. Posterior-mean super-resolution with a causal Gaussian Markov random field prior[J]. IEEE transactions on image processing,2012,21(7) :3182-3193.

[4] TANG Y,YAN P K,YUAN Y,et al. Single-image super-resolution via local learning[J]. International journal of machine learning and cybernetics,2011,2(1) :15-23.

[5] GAO X B,ZHANG K B,TAO D C,et al. Image super-resolution with sparse neighbor embedding[J]. IEEE transactions on image processing,2012,21(7) :3194-3205.

[6] BABACAN S D,MOLINA R,KATSAGGELOS A K. Variational bayesian super resolution[J]. IEEE transactions on image processing,2011,20(4) :984-999.

[7] YANG J C,WRIGHT J,HUANG T,et al. Image super-resolution via sparse representation[J]. IEEE Transactions on image processing,2010,19(11) :2861-2873.

[8] FREEMAN W T,JONES T R,PASZTOR E C. Example-based superresolution[J]. IEEE computer graphics and applications, 2002,22(2) :56-65.

[9] TRINH D H,LUONG M,DIBOS F,et al. Novel example-based method for super-resolution and denoising of medical images[J]. IEEE transactions on image processing,2014,23(4) :1882-1895.

(下转第 41 页)

- [8] YANG S H, LONG B, SMOLA A J, et al. Like alike: joint friendship and interest propagation in social networks[C]// WWW2011, ACM. New York, USA, WWW, 2011: 537–546.
- [9] XIAO R L, LI Y N, CHEN H T, et al. SRSP-PMF: a novel probabilistic matrix factorization recommendation algorithm using social reliable similarity propagation[J]. Lecture notes in computer science, 2015: 80–91.
- [10] JI K, SUN R Y, LI X, et al. Improving matrix approximation for recommendation via a clustering-based reconstructive method[J]. Neurocomputing, 2016(173) : 912–920.
- [11] SALAKHUTDINOV R, MNH A. Probabilistic matrix factorization[C]// Proc of the 21st Annual Conf on Neural Information Processing Systems. New York: Curran Associates Inc, 2008: 1257–1264.
- [12] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization[J]. Nature, 1999, 401(6755) : 788–791.

[责任编辑:顾晓天]

(上接第 34 页)

- [10] JEONG S, YOON I, JEON J, et al. Multi-frame example-based super-resolution using locally directional self-similarity[C]// Proc of IEEE International Conference on Consumer Electronics, LV: IEEE, 2015: 631–632.
- [11] VAPNIK V. Statistical learning theory[M]. New York: John Wiley and Sons, 1998.
- [12] 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.
- [13] 梅树立. 基于变分法和剪切波耦合算法的蝗虫切片保纹理图像降噪[J]. 农业工程学报, 2016, 32(17) : 152–159.
- [14] 朱志刚, 林学闾, 石定机. 数字图像处理[M]. 北京: 电子工业出版社, 2011.
- [15] 汤嘉立, 左健民, 黄陈蓉. 基于 SVM 预分类学习的图像超分辨率重建算法[J]. 计算机应用研究, 2012, 29(8) : 3151–3175.
- [16] 张卫国, 李景妹. 改进的基于纹理特征的图像配准算法[J]. 计算机工程与应用, 2016, 52(6) : 214–218.
- [17] 曹杨, 李晓光, 王素玉, 等. 基于预分类学习的超分辨率复原算法[J]. 数据采集与处理, 2009, 24(4) : 514–518.
- [18] 柳益君, 朱广萍, 钱进, 等. 基于支持向量机的绿色战略选择模型研究[J]. 计算机仿真, 2010, 27(11) : 307–310.

[责任编辑:顾晓天]