



(12) 发明专利

(10) 授权公告号 CN 102243711 B

(45) 授权公告日 2013. 05. 22

(21) 申请号 201110171899. X

(22) 申请日 2011. 06. 24

(73) 专利权人 南京航空航天大学
地址 210016 江苏省南京市御道街 29 号

(72) 发明人 杨欣 费树岷 唐庭阁 郭爱群
周大可

(74) 专利代理机构 南京经纬专利商标代理有限公司 32200

代理人 许方

(51) Int. Cl.

G06T 5/00(2006. 01)

G06K 9/66(2006. 01)

审查员 郝晓丽

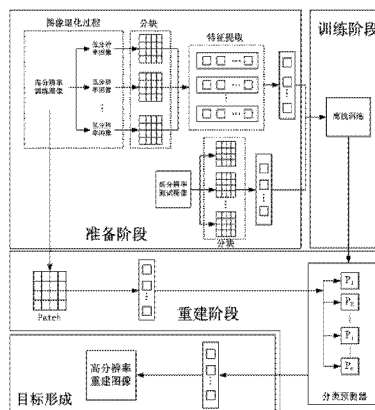
权利要求书2页 说明书6页 附图4页

(54) 发明名称

一种基于邻域嵌套的图像超分辨率重建方法

(57) 摘要

本发明公开了一种基于邻域嵌套的图像超分辨率重建方法,属于数字图像增强技术领域。本发明利用离线方式构建了一个包含多个子预测器的分类预测器,并使用该分类预测器进行在线超分辨率图像重建,节省了传统方法在计算优化权值时所需的大量计算时间,有效提高了超分辨率图像重建的实时性。本发明还通过多特征融合以及与实际情况贴近的退化模型,进一步提高了超分辨率图像的重建质量。对于随机的遥感图像处理、医学视频处理、军事安全监控系统开发等方面,都具有重要的理论和实际意义。



1. 一种基于邻域嵌套的图像超分辨率重建方法,其特征在于,包括以下步骤:

步骤 1、将高分辨率训练图像经退化处理,转变为 L 幅低分辨率训练图像, L 为大于 1 的整数;

步骤 2、分别将得到的 L 幅低分辨率训练图像以及低分辨率测试图像进行邻域嵌套分块,并进行特征提取,得到低分辨率训练图像分块及低分辨率测试图像分块;

步骤 3、将低分辨率训练图像分块和低分辨率测试图像分块进行离线训练,得到自适应优化权值,并送入一个包含 U 个子预测器的分类预测器, U 为步骤 2 中所述邻域嵌套分块的分块数;具体包括以下各子步骤:

步骤 301、用 L2 范数得出与第 i 个低分辨率测试图像分块 \mathbf{y}_t^i 最接近的 V 个低分辨率训练图像分块, $V < U$, 即:

$$L_{ij} = \|\mathbf{y}_t^i - \mathbf{y}_s^j\|^2$$

根据 L_{ij} 的大小,依次选出 V 个与 \mathbf{y}_t^i 最接近的低分辨率训练图像分块,记为: $\mathbf{y}_s^{i,v}$;

步骤 302、对于低分辨率测试图像分块中的第 i 分块 \mathbf{y}_t^i , 令:

$$\min \varepsilon_i : \varepsilon_i = \mathbf{y}_t^i - \sum_{v=1}^V \omega_{i,v} \mathbf{y}_s^{i,v}$$

$\omega_{i,v}$ 为第 i 分块自适应优化权值,解出上式的最小化问题,然后即可求出高分辨率测试

图像分块 \mathbf{z}_t^i , 如下:

$$\mathbf{z}_t^i = \sum_{v=1}^V (\omega_{i,v} \mathbf{z}_s^{i,v})$$

其中, $\mathbf{z}_s^{i,v}$ 为与 $\mathbf{y}_s^{i,v}$ 相对应的第 i 个高分辨率训练图像分块;

步骤 303、将自适应优化权值送入分类预测器中相应的子预测器;

步骤 4、将高分辨率训练图像进行邻域嵌套分块,并将高分辨率训练图像分块送入分类预测器中,根据相应的自适应优化权值进行计算,得到最终的高分辨率测试图像。

2. 如权利要求 1 所述基于邻域嵌套的图像超分辨率重建方法,其特征在于,所述退化处理是指使用模糊化、运动变换、采样、加入噪声这四种处理方法中的一种或多种对图像进行处理。

3. 如权利要求 2 所述基于邻域嵌套的图像超分辨率重建方法,其特征在于,所述退化处理是指根据如下退化模型对图像进行模糊化、运动变换、采样以及加入噪声处理:

$$\mathbf{Y}_s^k = \mathbf{D} \mathbf{B}_k \mathbf{M}_k \mathbf{Z}_s + \mathbf{n}_k,$$

式中, \mathbf{Y}_s^k 为第 k 幅低分辨率训练图像经字典排序后组成的向量, $k=1, 2, \dots, L$; \mathbf{Z}_s 为高分辨率训练图像经字典排序后形成的向量; \mathbf{M}_k 为仿射变换矩阵; \mathbf{B}_k 为模糊矩阵; \mathbf{D} 为下采样矩阵; \mathbf{n}_k 为高斯白噪声向量。

4. 如权利要求 1-3 任一项所述基于邻域嵌套的图像超分辨率重建方法,其特征在于,所述特征提取是指先分别提取至少两个特征,然后将提取出的特征进行融合。

5. 如权利要求 4 所述基于邻域嵌套的图像超分辨率重建方法,其特征在于,所述特征提取是指先分别提取亮度特征和边缘特征,然后将亮度特征和边缘特征进行融合。

一种基于邻域嵌套的图像超分辨率重建方法

技术领域

[0001] 本发明涉及一种图像超分辨率重建方法,尤其涉及一种基于邻域嵌套的图像超分辨率重建方法,属于数字图像增强技术领域。

背景技术

[0002] 图像空间分辨率是图像质量评价关键性的一项指标,也是图像应用中举足轻重的一个参数,它表示景物信息的详细程度。然而,目前许多成像系统,如红外成像仪和 CCD 照相机等,在采集图像过程中,受其固有传感器阵列排列密度的限制,图像的分辨率不可能很高;同时欠采样效应又会造成图像的频谱交叠,使获取的图像因变形效应而发生降质。如果采用增加传感器阵列采样密度的办法来提高图像分辨率和消除变形效应,可能会付出昂贵的代价或者面临很难克服的技术困难。因此从软件方面着手来提高图像分辨率有着极大的现实意义和应用价值,解决这一问题的一个有效办法就是采用超分辨率 (Super Resolution, SR) 重建技术,即通过一序列低分辨率 (Low Resolution, LR) 变形图像来估计高分辨率 (High Resolution, HR) 的非变形图像。近年来,超分辨率重建技术已成为图像处理领域的一个研究热点,广泛应用于遥感、医学成像和军事等多个领域,并且取得了较为丰硕的成果。

[0003] 在低分辨率图像序列的帧数较少以及分辨率提高倍数较大的情形下,低分辨率图像序列所能提供的互补性样本信息相对有限,不足以使超分辨率重建算法恢复更多的高频信息。这种情况下关于图像本身的先验知识就显得非常重要。除了传统 MRF 统计先验模型和正则空间几何图像模型能够提供图像的先验信息,另一种重要方法就是通过神经网络技术进行学习训练得到。基于学习的超分辨 (example-based SR) 重建研究的主要思想是,通过学习已有的高分辨率图像序列获取先验信息进而提高分辨率。

[0004] 正是由于基于学习的超分辨率重建方法不需要太多的图像先验知识,因而得到进一步发展。文献 (IEEE Transaction on Image Processing, 17(6) :873-886) 提出一个鲁棒的全局人脸空间模型以得到人脸超分辨率图像细节,其缺点是该方法只能应用于某些特定的图像,比如人脸图像等。文献 (IEEE Transaction on Image Processing, 16(6) : 1596-1610) 运用支持向量回归学习的方法研究低分辨率图像与高分辨率图像的 DCT (离散余弦变换) 系数的关系,进而进行超分辨率重建,这个方法具有一定的普遍性,但是也存在一个问题,即需事先假设如高斯分布、DCT 系数等较强的先验知识。文献 (Proceeding of IEEE Conference on Computer Vision and Pattern Recognition, Minnesota, USA, 2007, 1-8) 引入软边缘平滑先验知识,并结合阿尔法抠图技术进行彩色图像的超分辨率。其缺点是:如果先验参数选择不准确,将导致过度平滑甚至导致重建图像模糊。

[0005] 邻域嵌套超分辨率重建方法是基于学习的超分辨率方法中重要的一个分支,近年来取得了丰硕的研究成果。邻域嵌套算法的主要原理为:将训练的低分辨率图像和重建低分辨率图像分别对应分块,并得出重建低分辨率图像分块与多个训练低分辨率图像分块的对应关系,并将对应关系应用于训练的高分辨率图像分块与重建的高分辨率图像分块之中,借此

得出重建的高分辨率图像。文献 (Proceeding of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Washington, DC, USA, 2004, 275-282) 注意到低分辨率和高分辨率图像相对应的分块具有相似的局部几何特征, 对低分辨率和高分辨率图像进行相似性对应分块, 提出了基于邻域嵌套的超分辨率重建算法 (Super-Resolution through Neighbor Embedding, SRNE), 在该方法中, 高分辨率测试图像分块用一组经过优化加权的高分辨率训练图像分块来表示。实验表明该方法在保持图像形状, 减少人工痕迹方面优于 Freeman 算法, 但是, 这种方法没有深入研究图像属性, 比如: 图像边缘, 以及邻域尺寸等, 因此其性能和训练图像的选择密切相关。文献 (Proceeding of IEEE Conference on Computer Vision and Pattern Recognition, Minneapolis, USA, 2007, 201-205) 提出一种基于邻域嵌套的图像联想方法, 这也是由 SRNE 演化而来, 该方法将最大滤波响应作为特征进行提取, 但是由于其中的高频分量条件独立于中, 低频分量, 因此该算法在保持邻域信息方面仍然非常欠缺。

[0006] 综上所述, 现有的基于学习的超分辨率方法主要存在如下问题:

[0007] ①超分辨率重建计算时间消耗过大

[0008] 实时性是超分辨率重建的重要技术指标, 其将影响超分辨率重建技术在安全监控、高清电视等诸多领域的应用, 而现有算法需要经过分块, 训练, 重建, 拼接等步骤, 计算量相当大, 实时性较差, 这势必影响了超分辨率技术的推广应用。而提升超分辨率技术实时性的有价值的成果并不多见, 有待更多的深入研究。

[0009] ②训练集和测试集图像选择过于简单, 没有考虑图像实际退化情况

[0010] 训练集图像过于简单, 如 SRNE、NeedFS 等算法, 其训练集中的低分辨率图像, 是通过高分辨率图像简单的采样所得, 且一幅高分辨率训练图像只对应一幅低分辨率训练图像, 且对实际中图像退化的模糊过程和仿射变换过程没有任何的考虑, 这势必对重建的效果产生消极的影响。

发明内容

[0011] 本发明所要解决的技术问题在于克服现有基于学习的图像超分辨率重建技术所存在的重建计算时间过大, 实时性差的缺陷, 提供一种基于邻域嵌套的图像超分辨率重建方法。

[0012] 本发明采用以下技术方案解决上述技术问题:

[0013] 一种基于邻域嵌套的图像超分辨率重建方法, 包括以下步骤:

[0014] 步骤 1、将高分辨率训练图像经退化处理, 转变为 L 幅低分辨率图像, L 为大于 1 的整数;

[0015] 步骤 2、分别将得到的 L 幅低分辨率图像以及低分辨率测试图像进行邻域嵌套分块, 并进行特征提取, 得到低分辨率训练图像分块及低分辨率测试图像分块;

[0016] 步骤 3、将低分辨训练图像分块和低分辨率测试图像分块进行离线训练, 得到自适应权值系数, 并送入一个包含 U 个子预测器的分类预测器, U 为分块数;

[0017] 步骤 4、将高分辨率训练图像进行邻域嵌套分块, 并将高分辨率训练图像分块送入分类预测器中, 根据相应的自适应权值系数进行计算, 得到最终的高分辨率测试图像。

[0018] 所述步骤 3 具体包括以下各子步骤:

[0019] 步骤 301、用 L2 范数得出与第 i 个测试图像分块 \mathbf{y}_t^i 最接近的 V ($V < U$) 个训练图像分块, 即 :

$$[0020] \quad L_{ij} = \|\mathbf{y}_t^i - \mathbf{y}_s^j\|^2$$

[0021] 根据 L_{ij} 的大小, 依次选出 V 个与 \mathbf{y}_t^i 最接近的训练集图像分块, 记为 $\mathbf{y}_s^{i,v}$; 步骤 302、对于测试集中的第 i 分块 \mathbf{y}_t^i , 令 :

$$[0022] \quad \min \varepsilon_i : \varepsilon_i = \mathbf{y}_t^i - \sum_{v=1}^V \omega_{i,v} \mathbf{y}_s^{i,v}$$

[0023] $\omega_{i,u}$ 为第 i 分块自适应优化权值, 解出上式的最小化问题, 然后即可求出高分辨率测试图像分块 \mathbf{z}_t^i , 如下 : $\mathbf{z}_t^i = \sum_{v=1}^V (\omega_{i,v} \mathbf{z}_s^{i,v})$

[0024] 其中, $\mathbf{z}_s^{i,v}$ 为与 $\mathbf{y}_s^{i,v}$ 相对应的第 i 个高分辨率训练图像分块 ;

[0025] 步骤 303、将所有可能的权值组合送入分类预测器中相应的子预测器。

[0026] 进一步地, 所述退化处理是指使用模糊化、运动变换、采样、加入噪声这四种处理方法中的一种或多种对图像进行处理。

[0027] 进一步地, 所述特征提取是指先分别提取至少两个特征, 然后将提取出的特征进行融合。

[0028] 本发明利用离线方式构建了一个包含多个子预测器的分类预测器, 并使用该分类预测器进行在线超分辨率图像重建, 节省了传统方法在计算优化权值时所需的大量计算时间, 有效提高了超分辨率图像重建的实时性。本发明还通过多特征融合以及与实际情况贴近的退化模型, 进一步提高了超分辨率图像的重建质量。对于随机的遥感图像处理、医学视频处理、军事安全监控系统开发等方面, 都具有重要的理论和实际意义。

附图说明

[0029] 图 1 为本发明具体实施方式中多特征融合的特征提取方法原理示意图 ;

[0030] 图 2 为本发明具体实施方式中分类预测器离线训练流程图 ;

[0031] 图 3 为本发明的图像超分辨率重建方法流程图 ;

[0032] 图 4 为实验所使用的训练和测试图像 ;

[0033] 图 5 为实时性对比实验结果。

具体实施方式

[0034] 下面结合附图对本发明的技术方案进行详细说明 :

[0035] 本发明的图像超分辨率重建方法, 包括以下步骤 :

[0036] 步骤 1、将高分辨率训练图像经退化处理, 转变为 L 幅低分辨率图像, L 为大于 1 的整数 ;

[0037] 通常基于邻域嵌套的 SR 重建算法, 都是选择一幅 HR 图像和对应的一幅 LR 图像作为训练图像, 并且训练集中的 LR 图像是通过 HR 图像经过简单采样得到的, 这并没有考虑到图像退化模型, 并且简单的采样并不能准确描述现实中 HR 图像的退化 (或者降质) 过程, 因此将影响图像重建效果。

[0038] 本发明将训练集扩大,令 Z_s 为 HR 训练图像, \mathbf{Y}_s^k 为 Z_s 经过模糊化、运动变换、采样以及加入噪声因素,退化成的第 k 幅 ($k = 1, 2, \dots, L$) LR 图像。即有:

$$[0039] \quad \mathbf{Y}_s^k = \mathbf{D}\mathbf{B}_k\mathbf{M}_k\mathbf{Z}_s + \mathbf{n}_k, 1 \leq k \leq L \quad (1)$$

[0040] 上式模型中, \mathbf{Y}_s^k 为第 k 幅 $m \times n$ 的 LR 观测图像 \mathbf{y}_s^k 经字典排序后组成的 $N \times 1$ ($N = mn$) 的向量,如果 r_1 和 r_2 分别为水平和垂直方向的下采样因子,那么, Z_s 为 $r_1 m \times r_2 n$ 的 HR 训练图像 \mathbf{z}_s 经字典排序后形成的 $r_1 r_2 N \times 1$ 的向量, \mathbf{M}_k 为 $r_1 r_2 N \times r_1 r_2 N$ 的仿射变换矩阵, \mathbf{B}_k 为 $r_1 r_2 N \times r_1 r_2 N$ 的模糊矩阵, \mathbf{D} 为 $N \times r_1 r_2 N$ 下采样矩阵, \mathbf{n}_k 为 $N \times 1$ 的高斯白噪声向量。

[0041] 步骤 2、分别将得到的 L 幅低分辨率图像以及低分辨率测试图像进行邻域嵌套分块,并进行特征提取,得到低分辨率训练图像分块及低分辨率测试图像分块;

[0042] 将 \mathbf{Y}_s^k 分割成 U 个大小为 $s \times s$ 的小块,组成块集合 $\{\mathbf{y}_s^{k,i}\}$ ($k = 1, 2, \dots, L$), $\mathbf{y}_s^{k,i}$ 表示第 k 幅 LR 训练图像的第 i 小块,相邻的块之间有 1 或 2 个像素点重合,同样,将 Z_s 分割成相对应的 U 个大小为 $r_1 s \times r_2 s$ 的小块,同样相邻的块之间根据水平方向和垂直方向分别有 r_1, r_2 或者 $2r_1, 2r_2$ 个像素点重合,组成块集合 $\{\mathbf{z}_s^i\}$, $\{\mathbf{y}_s^{k,i}\}$ 和 $\{\mathbf{z}_s^i\}$ 对于参数 i 是一一对应的关系;同样,将第 k 幅 LR 测试图像 \mathbf{Y}_t^k ($k = 1, 2, \dots, L'$) 也通过同样的方法进行分块,组成块集合 $\{\mathbf{y}_t^{k,i}\}$ 。

[0043] 本发明在进行特征提取时,采用了多信息融合的特征提取方法,即提取梯度信息与灰度信息并进行特征融合,有效降低图像噪声、锐化图像边缘。其原理如附图 1 所示,具体按照以下方法:

[0044] 首先,提取图像分块的亮度特征,将原始图像分块转化为标准亮度分块,标准亮度的计算公式如下,

$$[0045] \quad u_{ij} = x_{ij} - \frac{1}{s^2} \sum_{p=1}^s \sum_{q=1}^s x_{pq}, \quad (2)$$

[0046] 然后提取图像分块的边缘信息,边缘信息为 4 维的边缘特征向量,其作用为使得原图像中有边缘的地方锐化,而平滑的地方则抑制噪声。边缘特征向量由标准亮度根据下式计算得出,

$$[0047] \quad b_{i,j} = \|\mathbf{b}_{i,j}\|^2 = (b_{i,j}^1)^2 + (b_{i,j}^2)^2 + (b_{i,j}^3)^2 + (b_{i,j}^4)^2 \quad (3)$$

[0048] 其中:

[0049]

$$\mathbf{b}_{i,j} = \begin{pmatrix} (u_{i,j-1} - u_{i,j}) + (u_{i,j} - u_{i,j+1}) \\ (u_{i-1,j} - u_{i,j}) + (u_{i,j} - u_{i+1,j}) \\ \frac{\sqrt{2}}{2} (u_{i-1,j-1} - u_{i,j}) + \frac{\sqrt{2}}{2} (u_{i,j} - u_{i+1,j+1}) \\ \frac{\sqrt{2}}{2} (u_{i-1,j+1} - u_{i,j}) + \frac{\sqrt{2}}{2} (u_{i,j} - u_{i+1,j-1}) \end{pmatrix} = \begin{pmatrix} u_{i,j-1} - u_{i,j+1} \\ u_{i-1,j} - u_{i+1,j} \\ \frac{\sqrt{2}}{2} (u_{i-1,j-1} - u_{i+1,j+1}) \\ \frac{\sqrt{2}}{2} (u_{i-1,j+1} - u_{i+1,j-1}) \end{pmatrix} = \begin{pmatrix} b_{i,j}^1 \\ b_{i,j}^2 \\ b_{i,j}^3 \\ b_{i,j}^4 \end{pmatrix} \quad (4)$$

[0050] 最后,按照下式将亮度特征和边缘特征进行融合,从而得到低分辨率训练图像分块及低分辨率测试图像分块的总体特征,

[0051] $x_{i,j} = [u_{i,j}, b_{i,j}]$, (5)

[0052] 步骤 3、将低分辨率训练图像分块和低分辨率测试图像分块进行离线训练,得到自适应权值系数,并送入一个包含 U 个子预测器的分类预测器, U 为分块数;

[0053] 如图 2 所示,本发明的分类预测器 P 中包含 U 个子预测器 P_j ,我们知道,在 U 块分块中要选取 V 个最接近的分块,共有 C_U^V 种可能的组合方式,预测分类器的思想为:将所有的可能的自适应权值的组合先离线计算出来,放入 U 个子预测器中,可以看出,子预测器是一个 V 维空间,令之为 $P[U_1][U_2]L[U_V]$,其中 $1 \leq U_i \leq U, 1 \leq i \leq V$ 。当 LR 测试图像分块通过拉式距离得到 V 个最近的 LR 训练图像分块,分别送入相对应的子预测器中,取出各自的自适应优化权值,然后直接通过下式计算出 HR 重建图像。如附图 2 所示,整个过程如下;

[0054] 首先用 L2 范数得出与第 i 个测试图像分块 \mathbf{y}_t^i 最接近的 V ($V < U$) 个训练图像分块,即:

[0055]
$$L_{ij} = \|\mathbf{y}_t^i - \mathbf{y}_s^j\|^2$$
 (6)

[0056] 根据 L_{ij} 的大小,依次选出 V 个与 \mathbf{y}_t^i 最接近的训练集图像分块,记为: $\mathbf{y}_s^{i,v}$;

[0057] 对于测试集中的第 i 分块 \mathbf{y}_t^i ,令:

[0058]
$$\min \varepsilon_i : \varepsilon_i = \mathbf{y}_t^i - \sum_{v=1}^V \omega_{i,v} \mathbf{y}_s^{i,v}$$
 (7)

[0059] $\omega_{i,u}$ 为第 i 分块自适应优化权值,解出上式的最小化问题,然后即可求出高分辨率测试图像分块 \mathbf{z}_t^i ,训练的数据采用 LR 训练图像分块集,即上式可变为:

[0060]
$$\min \xi^i : \xi^i = \mathbf{y}_s^i - \sum_{v=1}^V \omega_{i,v} \mathbf{y}_s^{i,v}$$
 (8)

[0061] 于是 (8) 式中 $\mathbf{y}_s^{i,v}$ 就转变为离 \mathbf{y}_s^i 最近的 V 个训练集图像分块,

[0062] (8) 式的最小化问题可转化为约束最小二乘问题,解决方法如下:

[0063] 令:

[0064]
$$\mathbf{G}_i = (\mathbf{y}_s^i \mathbf{1}^T - \mathbf{H})^T (\mathbf{y}_s^i \mathbf{1}^T - \mathbf{H})$$
 (9)

[0065] 这里, $\mathbf{1}$ 为元素都为 1 的列向量, \mathbf{H} 为矩阵,其列向量由与 \mathbf{y}_t^i 最近的 V 个分块 $\mathbf{y}_s^{i,v}$ ($v = 1, 2, \dots, V$) 构成,则:

[0066]
$$\omega_i = \frac{\mathbf{G}_i^{-1} \mathbf{1}}{\mathbf{1}^T \mathbf{G}_i^{-1} \mathbf{1}}$$
 (10)

[0067] (10) 式中, ω_i 为 V 维的列向量,其元素由自适应优化权值 $\omega_{i,v}$ ($v = 1, 2, \dots, V$) 组成。用上述方法算出所有可能的 C_U^V 种优化权值组合,然后分别输入到预测器中,以作为在线图像重建时使用。

[0068] 步骤 4、将高分辨率训练图像进行邻域嵌套分块,并将高分辨率训练图像分块送入分类预测器中,根据相应的自适应权值系数进行计算,得到最终的高分辨率测试图像。

[0069] 本发明的图像超分辨率重建方法的流程如图 3 所示。

[0070] 为了验证本发明的有益效果,进行了以下实验:以图 4 中的图像作为训练和测试图像,分别采用本发明方法,以及现有的 SRNE 算法、NeedFS 算法进行图像重建。采用分块均方差 ε_p 来验证各方法的优劣,分块均方差 ε_p 定义如下:

[0071]

$$\varepsilon_p = \frac{1}{U} \sum_{i=1}^U \|\tilde{\mathbf{z}}_i^i - \mathbf{z}_i^i\| = \frac{1}{U} \sum_{i=1}^U \sum_{j=1}^{s \times s} (\tilde{\mathbf{z}}_i^i(j) - \mathbf{z}_i^i(j))^2 \quad (11)$$

[0072] (11) 式中, $\tilde{\mathbf{z}}_i^i$ 为 HR 图像的第 i 块分块真值, \mathbf{z}_i^i 为 HR 测试图像的第 i 个分块的重建值, $\tilde{\mathbf{z}}_i^i(j)$ 和 $\mathbf{z}_i^i(j)$ 分别为其相应的第 j 个像素点, U 为分块的个数。

[0073] 依次选择图 4 中第 a, b, c, d, e, f 幅图像为训练图像, 其余则为测试图像, 例如: 当选 a 为训练图像时, 其余的 5 幅图像为测试图像, 这样, 共进行六组实验。实验首先令 $L = L' = 3$, 仿射变换参数以及模糊过程的选择如表 1 所示, 其中, 表 1 中三种模糊过程的点扩展函数定义如 (12) 式所示:

[0074]

	第一组	第二组	第三组	第四组	第五组	第六组
第 i 幅 运动参数	1 2 3	1 2 3	1 2 3	1 2 3	1 2 3	1 2 3
θ	0 2.1 3.3	-1 -0.4 2.0	-3 1.2 2.8	-8.1 2.3 -7.3	0 4.7 7.6	9.0 -0.2 -0.9
S_x /subpixel	0 0.34 0.71	0.62 0.61 0.36	0.44 0.65 0.78	0.34 0.67 0.31	0.2 0.50 0.72	0.61 0.30 0.17
S_y /subpixel	0 0.20 0.53	0.14 0.44 0.19	0 0.21 0.77	0 0.28 0.37	0 0.19 0.77	0.23 0.54 0.86
Blur model	Gaussian blur	Linear blur	Out-of-focus blur	Gaussian blur	Out-of-focus blur	Gaussian blur

[0075] 表 1

[0076]

$$\varpi = \begin{cases} \text{离焦模糊 (Out-of-focus blurs): } b_1(\sigma) = 1/\pi r^2 (\sqrt{x^2 + y^2} \leq r) \\ \text{高斯模糊 (Gaussian blur): } b_2(\sigma) = \exp(-(x^2 + y^2)/(2\sigma^2)) \\ \text{线性模糊 (Linear blur): } b_3(a, b) = b - a\sqrt{x^2 + y^2} \end{cases} \quad (12)$$

[0077] 实验结果如图 5 所示, 图中的实验结果为每组实验数据的平均值, 其中 1 为 SRNE 算法, 2 为 NeedFS 算法, 3 为本发明方法 ($L = 2, L' = 2$), SRNE 和 NeedFS 都是较为经典的算法, 因此和本发明方法进行效果比较就具有代表性和典型性。由图 5 可知, 本发明的分块均方差 ε_p 相对较小, 由此可得本发明方法重建的图像较为平滑, 噪声较小。

[0078] 接着又比较了本发明方法, SRNE 算法以及 NeedFS 算法的实时性, 同样进行了 6 组实验, 实验结果如图 5 所示。图 5 的纵轴代表每秒可重建的帧数, 其中 1 为 SRNE 算法, 2 为 NeedFS 算法, 3 为本发明方法 ($L = 2, L' = 2$), 由图中可以看出, NeedFS 虽然效果要好于 SRNE, 但是由于需对特征进行加工和处理, 实时性反而要略低于 NeedFS; 而本发明方法的实时性大大优于其它两种算法, 基本可以对视频进行处理, 当然, 本发明方法的离线运算会耗费一定的时间, 但这并不影响算法在线计算的实时性。

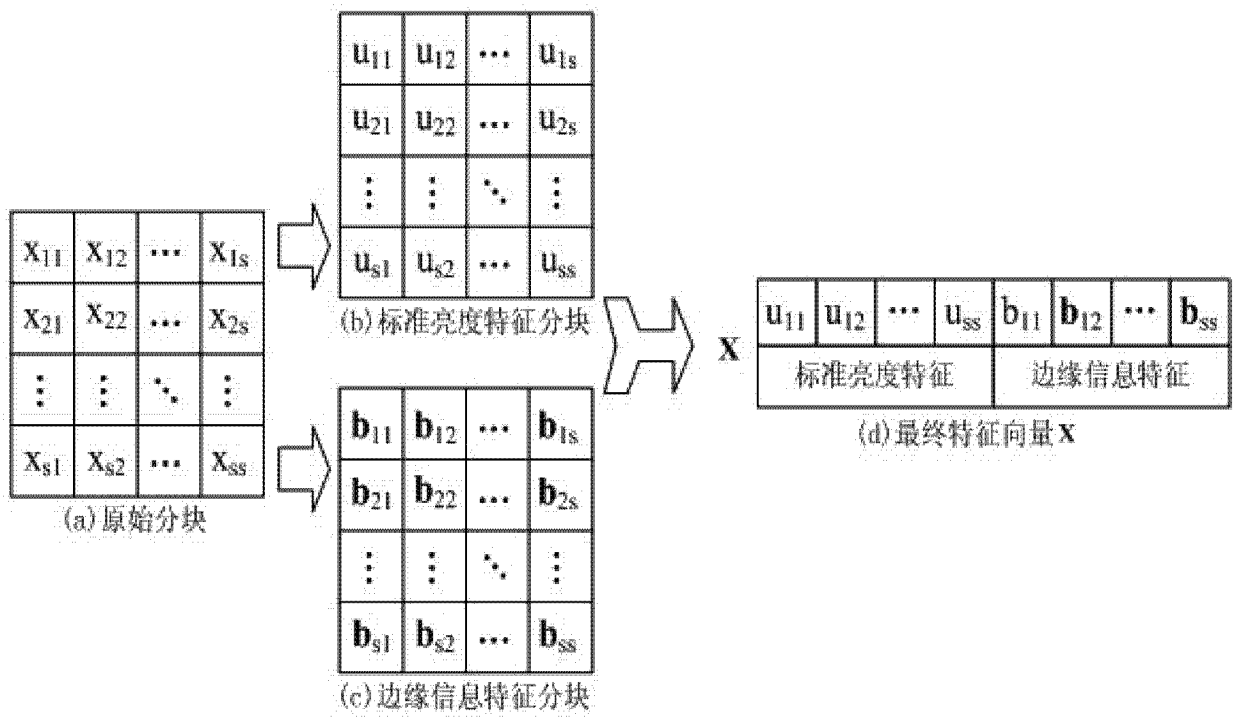


图 1

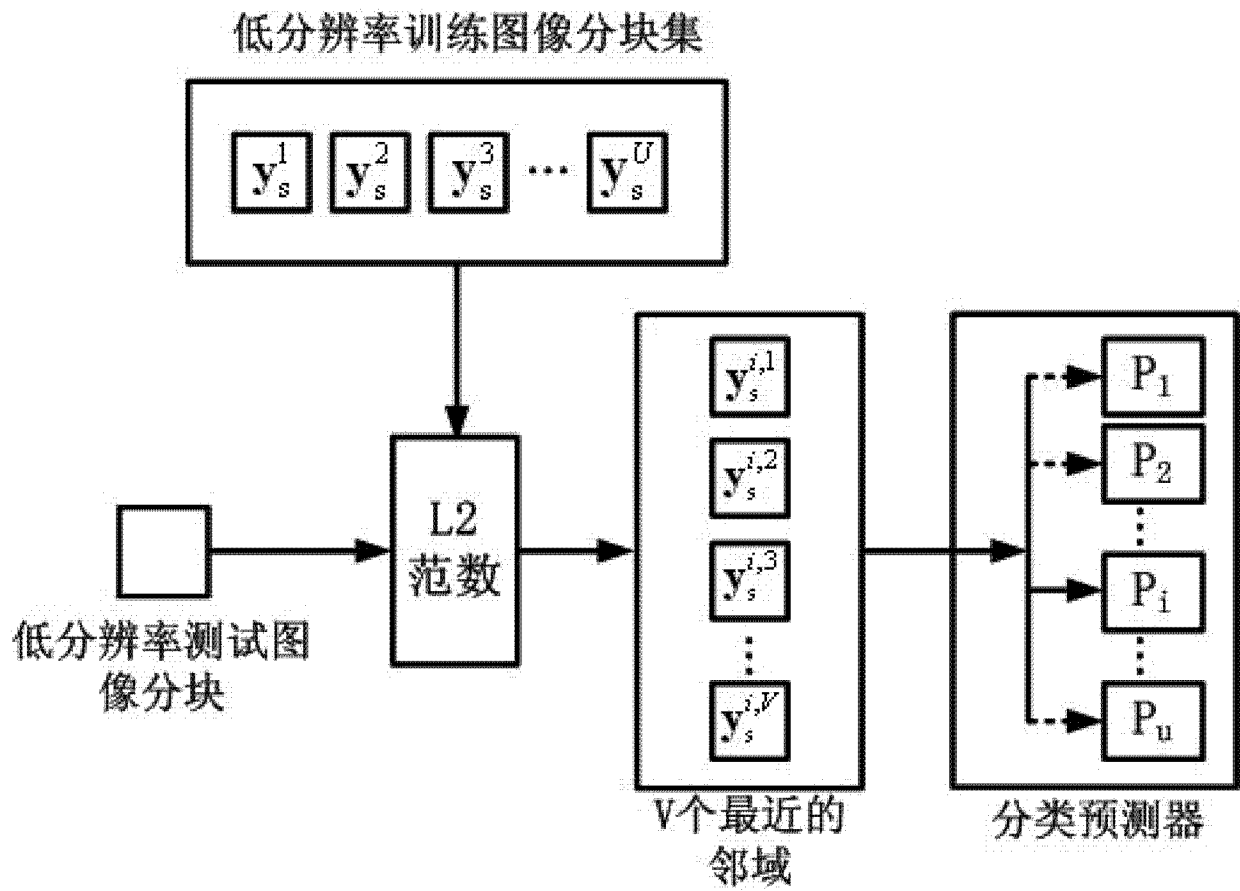


图 2

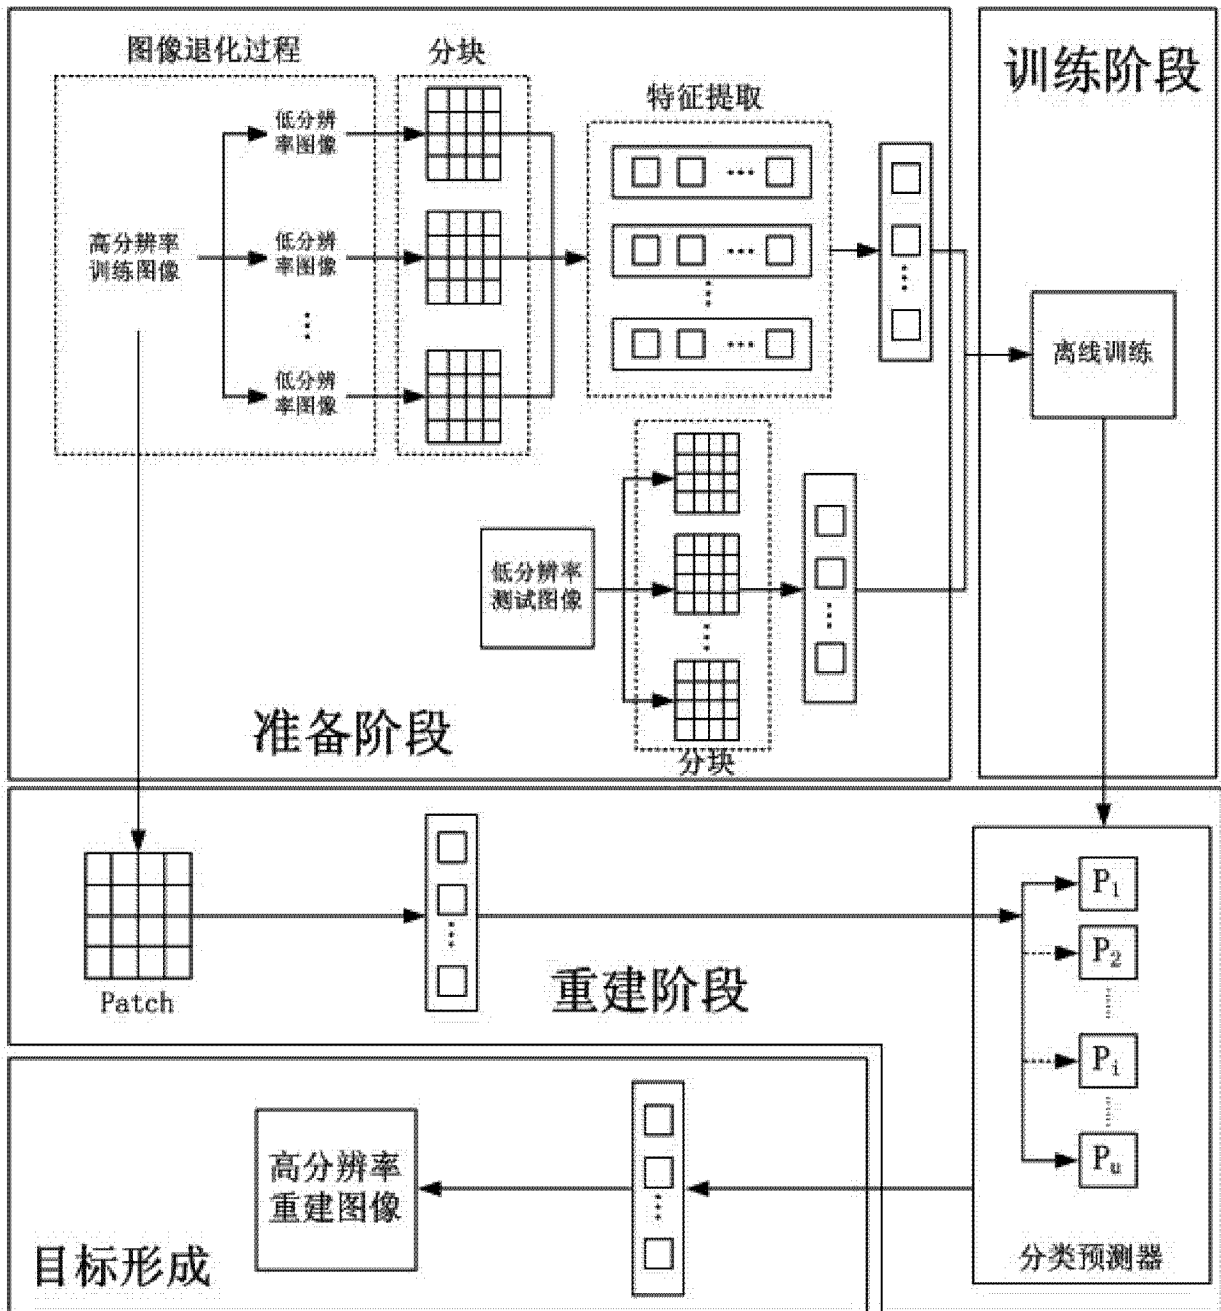


图 3

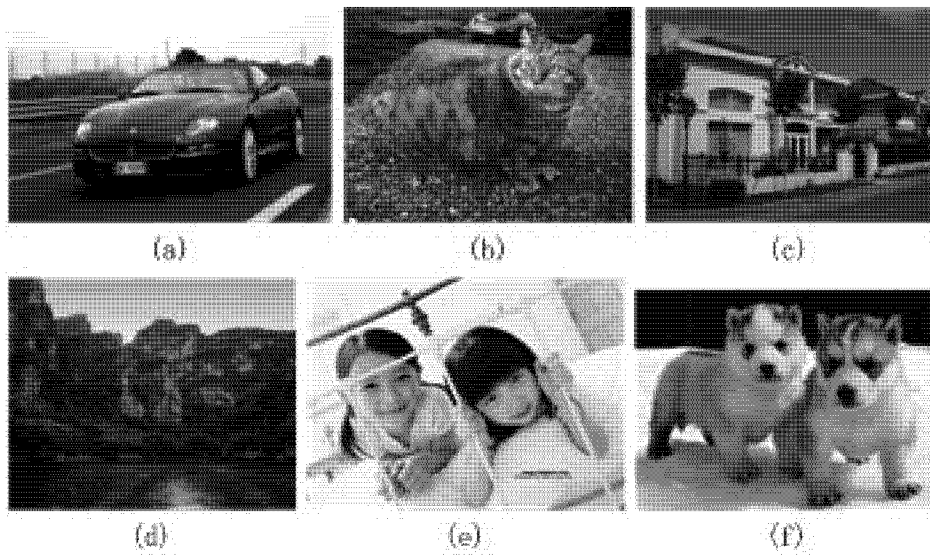


图 4




图 5