

# 边缘保持专家场模型的自然图像复原<sup>\*</sup>

张 志<sup>1, 2 \*\*</sup> 王润生<sup>1</sup>

1. 国防科技大学 ATR 实验室, 长沙 410073; 2. 空军装备研究院, 北京 100085

**摘要** 针对传统专家场模型对于图像局部边缘特性欠考虑的缺点, 提出了使用边缘保持滤波器去获取局部边缘结构信息, 建立了具有边缘保持特性的专家场模型. 图像去噪实验结果表明, 复原图像质量在主观评价和客观指标上都获得了优于传统专家场模型的效果, 验证了新模型的合理性和有效性.

**关键词** 专家场 边缘保持 自然图像 Markov 随机场

图像复原的本质是利用来自不同信息源的各种信息, 进行失真过程的逆处理求解, 力求恢复出原始图像. 理想的图像复原算法应该具备如下性能<sup>[1]</sup>: 尽可能地保持图像中的平坦区域平滑; 很好地保护图像边缘; 保持图像的全局对比度; 不引入伪像 (artifacts); 不丢失纹理细节. 图像复原可以利用的信息主要来自: 降质图像、原始图像和围绕它们的各种相关先验信息.

图像复原和低层机器视觉中的立体匹配、图像分割等很多问题一样, 是一个不适定 (ill-posed) 问题, 即问题的解不能同时满足存在、唯一和连续依赖于数据这三个条件. 这类问题可以使用正则化方法去求解, 正则化方法可以归结为一个能量泛函极值问题, 泛函包含两项: 数据保真项和先验项. 数据保真项主要的意义在于使得所求的结果和所需结果图像尽可能相似; 而先验项的意义是利用解的先验知识, 构造附加的解的某种先验信息作为约束条件, 改变求解策略, 限制解的数据, 修改空间和拓扑, 使图像复原的不适定问题变为适定问题, 从而使问题的解变得稳定和确定.

先验项选取的主要依据是先验约束条件, 这些先验约束条件可以来自于成像系统, 也可以来自于图像内容本身, 一般是针对相应问题的解空间提出

一定的约束. 这些约束条件的形成有两类方法, 一个是确定性的先验条件, 其约束条件是确定的参数或者规则, 如确定性正则化形式中的惩罚跳变的罚函数形式; 另一个是统计性的先验条件, 其约束条件是概率性的参数或者规则, 如随机场中的极大后验概率框架中的势函数这类概率型的函数形式.

由于图像数据更多地以某种类型的随机变量来考虑, 因此更多地采用概率分布来描述先验信息. 在图像处理中, 空间上下文信息有着重要的作用. 图像中某个像素点的亮度 (即灰度) 值, 与其邻域内其他像素点的亮度值有着紧密关系, 这类空间结构方面的信息有着重要作用. 长期以来, 人们尝试使用随机场模型对自然图像进行建模, 其中有代表性的就是 Markov 随机场 (Markov random fields; MRF) 模型. MRF 可以有效地对这类空间结构信息进行建模<sup>[2]</sup>, 在图像处理中有着广泛的运用.

通常的 MRF 的模型训练和推断是一个 NP-hard 问题<sup>[3]</sup>, 基于计算能力的限制一般假设 MRF 选取较小的邻域系统和手工指定的势函数形式, 并且使用高效的近似训练和推断的技术去对 MRF 模型进行训练和推断. 这样使得计算量极大的 MRF 模型的训练和推断计算变得可能实现, 但是通常假设的 MRF 结构比较简单, 如邻接空间邻域结构的

2009-03-26 收稿, 2009-05-25 收修改稿

<sup>\*</sup> 国防科技重点实验室基金资助项目 (批准号: 9140C8004010611, 9140C8002010705)

<sup>\*\*</sup> E-mail: zhizh.zhang@gmail.com

©1994-2018 China Academic Journal Electronic Publishing House. All rights reserved. <http://www.cnki.net>

MRF 等, 这类模型的实现速度较快, 但是对于高维的、细节结构丰富的自然图像特别是复杂自然场景图像的建模来说, 模型的效果并不够理想. Yanover<sup>[4]</sup>研究了 MRF 模型的全局最优解问题, 其成果表明, MRF 模型在低层机器视觉任务中表现不够理想的原因并不是因为使用近似训练和推断技术而无法收敛到全局最优解, 而是由于大多数 MRF 模型建立时使用的是低阶的邻域结构, 从而无法对复杂的图像结构进行有效的建模.

为了使得 MRF 模型能够更加充分的描述图像丰富的局部结构, Roth 和 Black<sup>[5-7]</sup>将 MRF 方法和稀疏编码的思想结合起来, 建立了高次的均一性 (homogeneous) 势函数形式的 MRF 模型, 称之为专家场 (fields of experts; FoE) 模型. 专家场模型是建立在一个丰富的可训练获取的滤波器集合上, 在图像数据库上使用对比发散 (contrastive divergence; CD) 方法训练获取的. 专家场模型提供了一个有效的途径去在更广的邻域上和更多的滤波器上建立更加丰富的先验知识模型. 专家场模型中所有的参数包括滤波器本身都可从数据中训练获取, 最终的概率模型可以使用在任意的需要空间图像先验的 Bayes 推断方法中. 其实验结果表明, 基于专家场模型的图像复原方法获得了优于所知的基于 MRF 模型方法的效果.

本文分析了传统的专家场模型中所存在的问题, 提出了一种具有边缘保持特性的专家场模型, 将提出的新模型用于自然图像复原中, 通过与传统专家场模型的实验对比验证了其合理性和有效性.

## 1 图像标记的 MRF 模型

图像标记任务通常归结为给定观测图像, 估计出对应的标记图像. 假设  $S$  为给定图像中所有图像位置的集合.  $Y = \{y_i, i \in S\}$  表示观测图像,  $y_i$  为图像位置  $i$  处的观测, 可能为像素值, 也可能为特征向量.  $X = \{x_i, i \in S\}$  表示未知的标记图像. 位置  $i$  处的标记  $x_i$  在一组离散数值  $\{1, 2, \dots, M\}$  中取值, 其中  $M$  表示标记类别的数目. 图像标记的概率方法通常归结为极大后验 (maximum a posteriori, MAP) 估计, 即

$$X = \arg \max_X p(X | Y) \quad (1)$$

利用 Bayes 定律, 后验概率可以写为

$$p(X | Y) \propto p(Y | X)p(X) \quad (2)$$

其中  $p(Y | X)$  为生成观测图像的概率,  $p(X)$  为图像先验, 若其服从 Gibbs 分布,  $X$  称为一个 MRF<sup>[3]</sup>, 得到的模型称为生成的 MRF 模型. 它将后验概率的建模转化为对先验模型  $p(X)$  和观测模型  $p(Y | X)$  的建模.

观测模型  $p(Y | X)$  也称为似然分布. 要对整幅观测图像进行联合建模是十分困难的, 且计算量也是十分复杂的. 因此为了计算和建模的可行性, MRF 模型通常考虑对单位置或局部的观测图像建模. 通过条件独立假设实现, 即

$$p(Y | X) = \prod_{i \in S} p(y_i | x_i) \quad (3)$$

将联合的观测模型  $p(Y | X)$  简化表示为一些局部的模型后, 一些已有的概率分布模型可以实际地运用到 MRF 模型中, 最常用的分布模型如 Gauss 分布和混合 Gauss 分布.

先验模型  $p(X)$  包含关于标记图像  $X$  的先验知识. 在一些典型的图像标记任务中, 一种合理的先验假设是标记图像  $X$  完全由局部上下文信息所表征. 这种局部上下文信息限制通常通过 MRF 来建模.

## 2 自然图像的先验概率模型

图像是一种高维的数据, 建立表述图像的先验概率模型是一个困难问题. 例如仅仅对于  $32 \times 32$  的黑白二值图像来说, 其可能图像集合的数量可达到  $10^{308}$  的数量级. 针对现实的机器视觉任务, 现实中我们处理的图像更多的是自然场景的图像, 所以一般的研究都针对于如何对自然图像进行建模. 自然图像指的是在一般的实际生活中可以看到的场景图像, 如风景、动物、人类活动、建筑物等等<sup>[3]</sup>. 在本文中也限定考虑的图像范围为自然图像.

图像先验的统计最早源于图像的频谱特性的统计之中. 起初的文献一般都认为图像服从 Gauss 随机场, 假设图像先验分布存在 Gauss 性, 其先验的势函数使用的是简单的邻域微分算子的和的形式,

这样的模型使得模型惩罚跳变边缘, 将噪声和边缘同样滤除, 导致边缘的模糊而使得图像过于平滑, 处理效果不够理想. 而研究中发现<sup>[8]</sup>, 典型自然图像的带通响应是非 Gauss 的, 其边缘概率密度函数存在高峰度 (kurtosis) 重拖尾的函数形式, 如图 1 所示. 这一类的性质告诉我们使用 Gauss 先验的函数并不适合一般的自然图像的统计特性, 也就引起了学者对于图像统计性先验的研究.




图 1 自然图像水平方向导数滤波器输出的对数直方图

针对具体的机器视觉应用背景研究者使用了不同的概率函数形式, 比较有代表性的有 Gauss 尺度混合函数 (Gaussian scale mixtures: GSM)<sup>[9]</sup>, Student-t 分布<sup>[10]</sup>,  $l^1$  范数下的 Charbonnier 函数形式<sup>[11]</sup> 等去模拟自然图像的统计分布, 获得了比较好的结果.

### 3 专家场的数学模型

低层机器视觉任务中出于模型的通用性和计算可实现性的考虑, 所使用的 MRF 模型主要存在以下三个特点:

- (1) 仅仅考虑简单的邻域结构, 如成对结构和 4 邻域结构;
- (2) 势函数形式一般是人工定义和手工调整的, 并不能很好地反映具体数据的具体属性;
- (3) MRF 一般来说不是空间自适应的, 即其是空间位置均一的, 不能随着空间位置的某些特征属性的改变而变化.

经典的 MRF 模型中出于计算可实现性考虑, 使用较小的邻域系统和手工指定的一次导数滤波器的势函数形式<sup>[12]</sup>, 这样的低维 MRF 模型并不能很好地描述结构丰富、关联性很强的图像结构, 在实际中的计算效果并不令人满意, 但是如果使用更大的邻域结构或者可变的势函数形式又给 MRF 模型的训练和推断带来计算的困难, 甚至是现有的计算能力还无法解决的.

Zhu 等<sup>[13]</sup> 率先考虑了图像 MRF 建模中的邻域系统和势函数的选取问题, 提出了 FRAME 模型. 他们将传统的以导数滤波器为基础的平滑性先验进行了推广并使用概率性建模的观点, 使用滤波器的输出作为势函数的表示形式, 通过一些预定义的高次滤波器集合去学习参数, 通过它们的组合来学习表示势函数, 将 MRF 模型推向高维数的形态.

Welling 等<sup>[10]</sup> 随后提出使用专家乘积模型 (product of experts: PoE) 去解决高维图像数据的先验概率建模问题. PoE 的思想是将高维的概率分布用一些低维的专家的乘积来表示, 而这些专家作用于低维的子空间, 从而相对容易去建模. 通常专家定义为一维线性子空间 (例如在稀疏编码模型中的基向量). 通过观察发现作用于自然图像的线性滤波器响应存在类似于 student-t 分布的高峰度重拖尾的边缘分布函数形式, Welling 据此提出使用 student-t 分布的专家 (PoT) 对标记图像进行建模, 其模型如下:

$$p_{\text{PoE}}(\mathbf{X}) = \frac{1}{Z(\Theta)} \prod_{i=1}^N \phi_i(\mathbf{J}_i^T \mathbf{X}; a_i), \Theta = \{ \theta_1, \dots, \theta_N \} \quad (4)$$

其中:  $\theta_i = \{ a_i, \mathbf{J}_i \}$ ,  $Z(\Theta)$  是归一化函数, 也称为划分函数 (partition function), 而专家 (experts)  $\phi_i$  则存在如下 student-t 分布的函数形式:

$$\phi(\mathbf{J}_i^T \mathbf{X}; a_i) = \left[ 1 + \frac{1}{2} (\mathbf{J}_i^T \mathbf{X})^2 \right]^{-a_i} \quad (5)$$

$\mathbf{J}$  为滤波器组,  $a_i$  一般假设是正的, 但是专家本身并没有假设是已经归一化的. 根据 Hammersley-Clifford 定理, 可以等价于 Gibbs 分布形式:

$$p_{PoE}(\mathbf{X}) = \frac{1}{Z(\Theta)} \exp(-E_{PoE}(\mathbf{X}, \Theta)) \quad (6)$$

所以可以由(4)式和(6)式得:

$$\exp(-E_{PoE}(\mathbf{X}, \Theta)) = \prod_{i=1}^N \phi_i(\mathbf{J}_i^T \mathbf{X}; a_i) \quad (7)$$

可得势函数的表示形式为:

$$E_{PoE}(\mathbf{X}, \Theta) = -\log\left(\prod_{i=1}^N \phi_i(\mathbf{J}_i^T \mathbf{X}; a_i)\right) = -\sum_{i=1}^N \log \phi_i(\mathbf{J}_i^T \mathbf{X}; a_i) \quad (8)$$

该模型的特点是所有的参数包括滤波器及其权重都可以从训练数据中学习获取。

但是由于 PoE 模型本身推广性的限制, 从基于块(patch-based)的图像直接推广到全图的建模是不可行的. 最近, Roth 和 Black<sup>[5-7]</sup> 结合了 MRF 和稀疏图像编码的思想, 提出一种高次的 MRF 图像先验模型, 称之为专家场模型。

定义图像中的像素点为图  $G=(V, E)$  中的节点  $V$ ,  $E$  代表边界. 定义一个  $m \times m$  的方形区域的邻域结构, 每一个中心为  $k=1, \dots, K$  的邻域定义为一个图中最大的基团. 根据 Hammersley-Clifford 定理, 可以将图模型的概率密度写为一个 Gibbs 分布如下:

$$p(\mathbf{X}) = \frac{1}{Z} \exp\left(-\sum_k V_k(\mathbf{X}_{(k)})\right) \quad (9)$$

其中:  $\mathbf{X}$  为图像矩阵,  $V_k(\mathbf{X}_{(k)})$  为基团  $\mathbf{X}_{(k)}$  的势函数. 另外假设 MRF 是均一性的, 即对于所有的基团来说势函数是一样的  $V_k(\mathbf{X}_{(k)})=V(\mathbf{X}_{(k)})$ , 这样使得 MRF 模型有平移不变的特性。

为了可以从训练图像中学习获取而不是手工定义势函数  $V$ , 其使用专家乘积的模型去表示 MRF 的势函数  $V(\mathbf{X}_{(k)})=E_{PoE}(\mathbf{X}_{(k)}, \Theta)$ , 因此, 整幅图像在专家场模型下的概率密度可以写为:

$$p_{FoE}(\mathbf{X}) = \frac{1}{Z(\Theta)} \exp(-E_{FoE}(\mathbf{X}, \Theta)) \quad (10)$$

其中,

$$E_{FoE}(\mathbf{X}, \Theta) = -\sum_k \sum_{i=1}^N \log \phi_i(\mathbf{J}_i^T \mathbf{X}_{(k)}; a_i) \quad (11)$$

或者等价的形式:

$$p_{FoE}(\mathbf{X}) = \frac{1}{Z(\Theta)} \prod_k \prod_{i=1}^N \phi_i(\mathbf{J}_i^T \mathbf{X}_{(k)}; a_i) \quad (12)$$

专家  $\phi_i$  假设存在如(5)式相同的 student-t 分布的函数形式。

该模型与 PoE 模型相比的重要不同在于建立了全局的图像概率模型, 使得其可以将所有的  $K$  个邻域的势函数相乘起来, 以便于图像的全局建模。

为了能表述更加丰富的图像结构先验, 专家场模型考虑了更大的邻域结构, 使用了 student-t 分布的先验假设, 可随之也带来了模型的训练和推断过程中所必须要解决的计算量巨大的问题. 他们以滤波器及其相应的系数的组合去表示势函数, 将高维基团空间的学习问题转化为滤波器及其系数的学习问题. 但是虽然使用多种简化算法和模型的约减, 其计算量还是相当的大。

#### 4 边缘保持专家场模型

专家场模型在图像复原中取得了良好的效果, 优于使用其他基于 MRF 模型的方法<sup>[7, 14]</sup>, 但是通过分析可以发现, 专家场模型为了将图像进行全局建模而假设的空间位置均一性的势函数形式, 并没有充分考虑图像具体位置的局部特性, 因此, 对于整幅图像都使用统一的势函数形式并不能自适应的描述图像在局部位置的统计特性, 也必然会限制其有效的应用。

我们针对传统专家场模型在图像建模假设时存在的这点局限, 将每一个基团的势函数形式与图像局部的边界描述算子结合起来, 设计一组对图像边缘敏感的滤波器, 提出一种具有边缘保持特性的自然图像专家场模型, 使得专家场模型在 MAP 求解时更加倾向于保持图像的边缘, 以期获得优于传统专家场模型的效果。

为了使用一种合适的边缘保持算法去改进传统专家场模型的框架, 首先必须考虑两个问题:

(1) 专家场模型中的图像建模所使用的势函数形式是滤波器响应的加权和, 所以边缘保持算法也

需要表示为滤波器形式, 以便使用自然图像建模的概率统一框架;

(2) 专家场的图像建模是建立在自然图像的滤波器响应存在高峰度、长拖尾的概率密度函数形式, 所以为了保证改进的专家场模型的有效性, 必须设计同样符合滤波器响应为高峰度、长拖尾的概率密度函数的边缘保持滤波器的滤波器。

对于(12)式中的滤波器组  $J$ , 根据专家场中使用的图像稀疏性表示的性质, 我们针对文献 [7] 中的专家场模型训练所获得的八个  $3 \times 3$  滤波器组, 设计添加了四个简单的  $3 \times 3$  滤波器去表征垂直、水平、两条斜对角线四个方向的线结构. 对于像素  $x_{k,j} \in X$ , 定义滤波器  $f_{k,j,n}$  其中  $n \in \{0, 1, 2, 3\}$ , 滤波器如下所示:

$$\begin{aligned} f_{k,j,0} &= x_{k,j+1} - 2x_{k,j} + x_{k,j-1} \\ f_{k,j,1} &= x_{k+1,j} - 2x_{k,j} + x_{k-1,j} \\ f_{k,j,2} &= \frac{1}{2}x_{k-1,j-1} - x_{k,j} + \frac{1}{2}x_{k+1,j+1} \\ f_{k,j,3} &= \frac{1}{2}x_{k-1,j+1} - x_{k,j} + \frac{1}{2}x_{k+1,j-1} \end{aligned} \quad (13)$$

由上式可得,  $f_{k,j,n}$  可以表示为四个  $3 \times 3$  滤波器  $F_n$  的形式, 即:

$$\begin{aligned} F_0 &= \begin{bmatrix} 0 & 1 & 0 \\ 0 & -2 & 0 \\ 0 & 1 & 0 \end{bmatrix}, F_1 = \begin{bmatrix} 0 & 0 & 0 \\ 1 & -2 & 1 \\ 0 & 0 & 0 \end{bmatrix}, \\ F_2 &= \frac{1}{2} \begin{bmatrix} 1 & 0 & 0 \\ 0 & -2 & 0 \\ 0 & 0 & 1 \end{bmatrix}, F_3 = \frac{1}{2} \begin{bmatrix} 0 & 0 & 1 \\ 0 & -2 & 0 \\ 1 & 0 & 0 \end{bmatrix} \end{aligned} \quad (14)$$

其滤波器输出对于垂直、水平、两条斜对角线四个方向的线结构边界比较敏感, 可以表征图像局部在四个典型方向上的边缘信息. 通过计算可以获得这四个滤波器对于典型的自然图像响应的对数直方图如图 2 所示. 与图 1 进行比较可知, 设计的这四个滤波同样也符合高峰度、长拖尾的概率密度函数形式, 所以(14)式设计的滤波器符合前文提出的两个约束, 可以改进传统专家场的边缘保持特性。




图 2 自然图像对于边缘保持滤波器输出的对数直方图

(a) 垂直方向; (b) 水平方向; (c)  $45^\circ$  对角线方向; (d)  $135^\circ$  对角线方向

我们将图像在边缘保持的专家场模型下的概率密度写为:

$$p_{\text{FoE-Edge}}(\mathbf{X}) = \frac{1}{Z(\Theta)} \prod_k \prod_{i=1}^{N+L} \phi_i((\mathbf{J}_E(i))^T * \mathbf{X}_{(k)}; a_i) \quad (15)$$

滤波器组  $\mathbf{J}_E(i)$  为传统专家场模型训练所获得的滤波器组  $\mathbf{J}$  和边缘保持的滤波器组  $\mathbf{F}$  的组合, 即

$$\mathbf{J}_E(i) = \begin{cases} \mathbf{J}_i & i = 1, \dots, N \\ \mathbf{F}_{i-N} & i = N + 1, \dots, N + L \end{cases} \quad (16)$$

专家  $\phi_i$  假设同样存在与 (5) 式相同的 student-t 分布的函数形式如下:

$$\phi_i((\mathbf{J}_E(i))^T * \mathbf{X}_{(k)}; a_i) = \left[ 1 + \frac{1}{2} ((\mathbf{J}_E(i))^T * \mathbf{X}_{(k)})^2 \right]^{-a_i} \quad (17)$$

至此我们获得了一种具有边缘保持特性的专家场模型框架。

## 5 边缘保持专家场模型的自然图像复原算法

本节利用上文提出的具有边缘保持特性的专家场模型框架, 运用在自然图像复原中, 以验证模型的有效性。

在图像去噪中, 对于一个被噪声污染的观测图像  $\mathbf{Y}$  来说, 我们的目的是寻找到真实的图像  $\mathbf{X}$ , 使得后验概率达到最大化, 即:

$$\mathbf{X} = \operatorname{argmax}_p(\mathbf{X} | \mathbf{Y}) \quad (18)$$

利用 Bayes 定律, 极大后验估计可以等价地写为

$$\mathbf{X} = \operatorname{argmax}_p(\mathbf{X} | \mathbf{Y}) = \operatorname{argmax}_p(\mathbf{Y} | \mathbf{X}) p(\mathbf{X}) \quad (19)$$

本文假设污染噪声采用零均值方差为  $\sigma^2$  加性 Gauss 噪声, 于是可以将似然函数写为:

$$p(\mathbf{Y} | \mathbf{X}) \propto \prod_k \exp\left[-\frac{1}{2\sigma^2} (y_k - x_k)^2\right] \quad (20)$$

其中  $k$  遍历图像中的所有像素。图模型最大后验概率的最大化过程一般来说比较困难, 但是在专家场中由于使用的是可导的专家函数形式, 所以可以避免使用计算复杂的推断算法, 而采用后验概率对数的梯度上升法。对数似然的梯度可以写为:

$$\Delta_x \log p(\mathbf{Y} | \mathbf{X}) = \frac{1}{\sigma^2} (\mathbf{Y} - \mathbf{X}) \quad (21)$$

概率对数先验  $\log p(\mathbf{X})$  的梯度可以类似推导为<sup>[13]</sup>:

$$\Delta_x \log p(\mathbf{X}) = \sum_{i=1}^{N+L} \mathbf{J}_E(i)^{-} * \psi(\mathbf{J}_E(i) * \mathbf{X}) \quad (22)$$

其中  $\mathbf{J}_E(i) * \mathbf{X}$  表示图像  $\mathbf{X}$  和滤波器  $\mathbf{J}_E(i)$  的卷积,  $\psi(\mathbf{Y})$  为专家的对数偏导, 即  $\psi(\mathbf{Y}) = \frac{\partial \log \phi_i(\mathbf{Y}; a_i)}{\partial \mathbf{Y}}$ ,  $\mathbf{J}_E(i)^{-}$  代表的是  $\mathbf{J}_E(i)$  以中心像素为中心的镜像滤波器,  $\phi_i$  与前文一致假设为服从 student-t 分布的函数形式。

引入迭代次数  $t$ , 步长  $\eta$  和一个优化的权重  $\lambda$ , 我们可以将算法写为:

$$\mathbf{X}^{(t+1)} = \mathbf{X}^{(t)} + \eta \left[ \sum_{i=1}^{N+L} \mathbf{J}_E(i)^{-} * \psi(\mathbf{J}_E(i) * \mathbf{X}^{(t)}) + \frac{\lambda}{\sigma^2} (\mathbf{Y} - \mathbf{X}^{(t)}) \right] \quad (23)$$

因为假设  $\phi_i$  为 student-t 分布的函数形式, 即:

$$\phi_i(\mathbf{J}_E(i) * \mathbf{X}; a_i) = \left[ 1 + \frac{1}{2} (\mathbf{J}_E(i) * \mathbf{X})^2 \right]^{-a_i} \quad (24)$$

所以  $\psi(\mathbf{J}_E(i) * \mathbf{X}^{(t)})$  有如下形式:

$$\begin{aligned} \psi(\mathbf{J}_E(i) * \mathbf{X}^{(t)}) &= \frac{\partial \log \phi_i(\mathbf{J}_E(i) * \mathbf{X}^{(t)}; a_i)}{\partial (\mathbf{J}_E(i) * \mathbf{X}^{(t)})} = \\ &= \frac{\partial \log \left[ \left( 1 + \frac{1}{2} (\mathbf{J}_E(i) * \mathbf{X}^{(t)})^2 \right)^{-a_i} \right]}{\partial (\mathbf{J}_E(i) * \mathbf{X}^{(t)})} = \\ &= -a_i \cdot \frac{\mathbf{J}_E(i) * \mathbf{X}^{(t)}}{1 + \frac{1}{2} (\mathbf{J}_E(i) * \mathbf{X}^{(t)})^2} \end{aligned} \quad (25)$$

从(23)式可以看出,对于图像去噪任务来说,可以使用边缘保持专家场模型,通过梯度上升法进行极大后验估计从而获得去噪图像的实验结果。

## 6 仿真实验及结果

本节根据前文所提出的算法框架,做了大量的仿真实验,并与 Roth 的传统专家场图像复原算法进行了比较. 本文的实验平台为 Windows XP 操作系统, Matlab 7. 6. 0. 324 (R2008a) 软件, Dual Core Intel Pentium D CPU 2.8GHz 微机, 1GB 内存.

实验选取的图像为 Berkeley 标准图像库<sup>[19]</sup>中的 Castle 图(321×481)和去噪实验中常用的五幅不同尺寸的标准图像(512×512 的 Lena, Barbara, Boats 和 256×256 的 House, Peppers)共计六幅图像; 降质的图像所添加的噪声为零均值标准差  $\sigma$  分别为 1, 2, 5, 10, 15, 20, 25, 50, 75 和 100 的十种不同强度的加性 Gauss 噪声; 基本专家场模型使用的是八个 3×3 滤波器组和 student-t 分布的专家函数形式, 迭代步长设置为 0.1, 迭代次数设置为 3000 次.

根据第五节提出的复原算法框架,我们对上述实验数据进行图像复原处理. 为了对两种方法进行

准确的定量比较,使用了峰值信噪比(peak signal to noise ratio; PSNR)和结构相似度(structural similarity; SSIM)<sup>[17, 18]</sup>两个参数. SSIM 参数是 Wang 等最近提出的图像质量评价度量<sup>[19]</sup>,用以度量两幅图像间的结构性失真. 对于具体两个图像矩阵  $X, Y$  而言,具体数学表示为:

$$Q(X, Y) = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} \cdot \frac{2\mu_X \mu_Y}{\mu_X^2 + \mu_Y^2} \cdot \frac{2\sigma_X \sigma_Y}{\sigma_X^2 + \sigma_Y^2} \quad (26)$$

其中  $\mu$  和  $\sigma$  分别代表图像灰度值的均值和标准差,  $\sigma_{XY}$  代表协方差. 当图像  $X, Y$  完全一致时  $Q=1$ .

图像去噪实验结果的定量比较如表 1 所示, 分别给出了在上述十种不同噪声水平下, 噪声图像的 PSNR 和 SSIM 值. 六幅不同类型和尺寸的测试图像在传统专家场和边缘保持专家场两种模型下去噪结果的 PSNR 和 SSIM 值. 图 3 所示的是传统专家场模型和边缘保持专家场模型在不同噪声水平下对于六幅测试图像的 PSNR 和 SSIM 的平均提高值.

从图 3 和表 1 可以看出, 本文所提出的边缘保持专家场模型在统计性和结构误差的定量指标上优于传统专家场模型.

表 1 图像去噪实验结果的定量比较

$\sigma$	PSNR (db)							SSIM						
	(上: 传统专家场模型; 下: 边缘保持专家场模型)							(上: 传统专家场模型; 下: 边缘保持专家场模型)						
	Noisy	Castle	Lena	Barbara	Boats	House	Peppers	Noisy	Castle	Lena	Barbara	Boats	House	Peppers
1	47.8272	48.6730	48.0920	48.0293	<b>47.8794</b>	48.4759	48.0835	0.99141	0.99383	<b>0.99224</b>	0.99458	<b>0.99417</b>	0.99273	0.99385
		<b>48.7817</b>	<b>48.1122</b>	<b>48.0532</b>	47.8688	<b>48.5943</b>	<b>48.1139</b>		<b>0.99409</b>	<b>0.99224</b>	<b>0.99459</b>	0.99412	<b>0.99298</b>	<b>0.99386</b>
2	42.0733	43.7701	43.1098	42.9233	<b>42.4496</b>	43.7686	43.0334	0.96898	0.98395	<b>0.97695</b>	0.98424	<b>0.98030</b>	0.98067	0.98168
		<b>43.9042</b>	<b>43.1551</b>	<b>42.9939</b>	42.4096	<b>43.9363</b>	<b>43.1514</b>		<b>0.98481</b>	0.97658	<b>0.98430</b>	0.97948	<b>0.98141</b>	<b>0.98180</b>
5	34.2086	37.6130	37.7024	36.6448	36.1767	<b>38.0307</b>	37.3452	0.84625	<b>0.95135</b>	0.93582	0.95430	<b>0.92528</b>	<b>0.93929</b>	0.94794
		<b>37.6843</b>	<b>38.0510</b>	<b>36.8938</b>	<b>36.2696</b>	37.9028	<b>37.7878</b>		0.94965	<b>0.93764</b>	<b>0.95605</b>	0.91896	0.92667	<b>0.95149</b>
10	28.1879	33.3115	34.2429	32.0401	32.5942	34.3575	33.4905	0.62940	<b>0.90656</b>	0.89454	0.91249	<b>0.86733</b>	<b>0.88371</b>	0.91162
		<b>33.4951</b>	<b>34.7518</b>	<b>32.3516</b>	<b>32.8891</b>	<b>34.8057</b>	<b>34.2124</b>		0.90256	<b>0.89711</b>	<b>0.91309</b>	0.86004	0.87971	<b>0.92106</b>
15	24.6841	29.3980	30.0631	28.3109	28.8732	30.0448	29.1927	0.48016	0.78853	0.77599	0.80546	0.75728	0.76113	0.79203
		<b>31.2117</b>	<b>32.8103</b>	<b>29.7133</b>	<b>30.8576</b>	<b>33.0067</b>	<b>31.9535</b>		<b>0.87108</b>	<b>0.86977</b>	<b>0.87102</b>	<b>0.81753</b>	<b>0.85591</b>	<b>0.89622</b>
20	22.2461	25.8011	26.0701	25.1344	25.5593	26.0621	25.7253	0.38290	0.57650	0.55682	0.63957	0.59454	0.54929	0.60965
		<b>29.4735</b>	<b>31.1848</b>	<b>27.7993</b>	<b>29.2756</b>	<b>31.3251</b>	<b>30.2853</b>		<b>0.83693</b>	<b>0.83845</b>	<b>0.82908</b>	<b>0.77626</b>	<b>0.82881</b>	<b>0.86584</b>
25	20.3725	23.2612	23.4363	22.8735	23.1872	23.4638	23.2369	0.31728	0.43709	0.41256	0.51914	0.47524	0.41316	0.48590
		<b>27.8651</b>	<b>29.6125</b>	<b>26.2687</b>	<b>27.8468</b>	<b>29.7285</b>	<b>28.4917</b>		<b>0.79096</b>	<b>0.79749</b>	<b>0.78513</b>	<b>0.73450</b>	<b>0.79279</b>	<b>0.82264</b>
50	14.8872	16.0070	15.8078	15.8444	15.7479	15.7535	15.8577	0.16312	0.18529	0.14476	0.23558	0.19096	0.15796	0.20668
		<b>17.6279</b>	<b>17.5951</b>	<b>17.3857</b>	<b>17.4569</b>	<b>17.5059</b>	<b>17.5672</b>		<b>0.22490</b>	<b>0.19370</b>	<b>0.28251</b>	<b>0.24141</b>	<b>0.20201</b>	<b>0.26133</b>
75	12.0522	12.5675	12.3244	12.4506	12.2501	12.2559	12.3576	0.10371	0.11123	0.07756	0.13660	0.10628	0.08788	0.11809
		<b>13.2587</b>	<b>13.0539</b>	<b>13.1422</b>	<b>12.9596</b>	<b>12.9700</b>	<b>13.0673</b>		<b>0.12155</b>	<b>0.08864</b>	<b>0.15019</b>	<b>0.11934</b>	<b>0.09932</b>	<b>0.13294</b>
100	10.3534	10.6270	10.4058	10.5096	10.3848	10.4086	10.4657	0.07303	0.07650	0.05044	0.09048	0.06967	0.05950	0.08109
		<b>10.9936</b>	<b>10.7669</b>	<b>10.8628</b>	<b>10.7418</b>	<b>10.7673</b>	<b>10.8263</b>		<b>0.08089</b>	<b>0.05467</b>	<b>0.09587</b>	<b>0.07486</b>	<b>0.06422</b>	<b>0.08733</b>




图 3 传统专家场模型和边缘保持专家场模型在不同噪声水平下实验效果的比较

(a) PSNR 平均提升效果; (b) SSIM 平均提升效果

为了考察本文所提出的边缘保持专家场模型的实验结果在人眼主观评价下的效果, 我们给出了 Castle 图的实验结果及其相应的细节放大图如图 4 所示. 其中, 图 4(a)为原始真实的实验图像, 图 4(b)为使用零均值标准差为 15 的加性 Gauss 噪声污染后的图像, 图 4(c)为使用传统专家场模型所获

得的去噪结果图像, 图 4(d)为使用本文提出的边缘保持专家场模型所获得的去噪结果图像. 从图 4 可以看出, 本文提出的边缘保持专家场模型所获得的去噪结果图像在主观质量上, 特别是在边缘处的效果优于传统专家场模型所获得的去噪结果图像. 图 5 给出的是实验结果图像利用 Canny 算子提取边缘




图 4 图像去噪实验结果及其细节图的比较

(a) 原始图像; (b) 噪声图像; (c) 传统专家场模型; (d) 边缘保持专家场模型



的比较, 从图中可以看出, 边缘保持专家场模型所获得的去噪结果图像在边缘的保持效果上优于传统专家场模型所获得的去噪结果图像。




图 5 实验结果图像利用 Canny 算子提取边缘图的比较

(a) 原始图像; (b) 噪声图像; (c) 传统专家场模型; (d) 边缘保持专家场模型

## 7 结束语

本文研究了具有边缘保持特性的自然图像专家场模型。首先分析了传统的专家场模型对于图像局部边缘特性欠考虑的缺点, 提出了使用边缘保持滤波器去获取图像局部的边缘结构信息, 形成了一种边缘保持的自然图像专家场模型框架。为验证该模型的有效性, 将其运用在图像去噪的实验中。仿真实验结果表明, 本文提出的边缘保持专家场模型是有效的, 复原图像在主观评价质量和客观指标上都获得了优于传统专家场模型的效果。

## 参 考 文 献

- 1 Liu C, Szeliski R, Kang SB et al. Automatic estimation and removal of noise from a single image. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008, 30(2): 299—314
- 2 Li SZ. *Markov Random Field Modeling in Image Analysis*. 2nd ed. New York: Springer-Verlag, 2001
- 3 Boykov Y, Veksler O, Zabih R. Fast approximate energy minimization via graph cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(11): 1222—1239
- 4 Yanover C, Meltzer T, Weiss Y. Linear programming relaxations and belief propagation—an empirical study. *Journal of Machine Learning Research*, 2006, 7: 1887—1907
- 5 Roth S. High-order Markov random fields for low-level vision. Ph.D. Dissertation, Providence, Rhode Island: Brown University, 2007

从图 4, 5 可以看出, 本文所提出的边缘保持专家场模型在主观视觉评价上优于传统专家场模型方法。

- 6 Roth S, Black MJ. Fields of experts: A framework for learning image priors. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR2005)*, San Diego, CA, USA, 2005. IEEE Computer Society, 860—867
- 7 Roth S, Black MJ. Fields of experts. *International Journal of Computer Vision*, 2009, 82(2): 205—229
- 8 Olshausen BA, Field DJ. Emergence of simple-cell receptive field properties by learning a sparse code for natural images. *Nature*, 1996, 381: 607—609
- 9 Wainwright MJ, Simoncelli EP. Scale mixtures of Gaussians and the statistics of natural images. *Advances in Neural Information Processing Systems (NIPS2000)*, Vancouver, BC, Canada, 2000. MIT Press, 855—861
- 10 Welling M, Hinton G, Osindero S. Learning sparse topographic representations with products of student-t distributions. *Advances in Neural Information Processing Systems (NIPS2003)*, Vancouver BC, Canada, 2003. MIT Press, 1359—1366
- 11 Donoho DL, Elad M, Temlyakov V. Stable recovery of sparse overcomplete representations in the presence of noise. *IEEE Transactions on Information Theory*, 2006, 52(1): 6—18
- 12 Geman S, Geman D. Stochastic relaxation, Gibbs distributions and the bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1984, 6(6): 721—741
- 13 Zhu SC, Wu Y, Mumford D. Filters, random fields and maximum entropy (FRAME): Towards a unified theory for texture modeling. *International Journal of Computer Vision*, 1998,

- 27(2): 107—126
- 14 Xu D, Wang R. An improved FoE model for image deblurring. *International Journal of Computer Vision*, 2009, 81(2): 167—171
  - 15 Zhu SC, Mumford D. Prior learning and Gibbs reaction-diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(11): 1236—1250
  - 16 Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. *IEEE International Conference on Computer Vision (ICCV01)*, Vancouver, BC, Canada, 2001. IEEE Computer Society, 416—423
  - 17 Wang Z, Bovik AC, Sheikh HR, et al. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 2004, 13(4): 600—612
  - 18 Wang Z, Wu G, Sheikh HR, et al. Quality-aware images. *IEEE Transactions on Image Processing*, 2006, 15(6): 1680—1689
  - 19 王润生. 信息融合. 北京: 科学出版社, 2007