

文章编号 1004-924X(2009)11-2828-07

# 应用 Hopfield 神经网络和小波域隐 Markov 树模型的图像复原

娄 帅, 丁振良, 袁 峰, 李 晶

(哈尔滨工业大学 电气工程及自动化学院, 黑龙江 哈尔滨 150001)

**摘要:**为了解决传统的 Hopfield 神经网络图像复原算法对噪声抑制和图像细节保护不能很好兼顾的问题,提出了一种基于改进的连续 Hopfield 神经网络和小波域隐 Markov 树(HMT)模型的复原算法。将小波域 HMT 模型作为图像小波系数统计关系的先验知识,并以正则化项的形式引入到神经网络模型中,最终利用 Hopfield 神经网络的能量收敛特性完成图像复原。同时提出了一种高度并行的网络权值矩阵计算方法,通过对模板图像进行算子操作,分批求取网络权值,避免了大型矩阵的乘法运算。实验结果表明,无论是对真实图像还是人工生成图像,算法复原的视觉效果均有明显改善,提高信噪比(ISNR)较传统同类算法增加了 0.3 dB 以上,达到了同时抑制噪声和保护图像细节的目的。

**关键词:**图像复原; Hopfield 神经网络; 小波域隐 Markov 树模型; 权值矩阵

**中图分类号:** TP391.4      **文献标识码:** A

## Image restoration based on Hopfield neural network and wavelet domain HMT model

LOU Shuai, DING Zhen-liang, YUAN Feng, LI Jing

(*School of Electrical Engineering and Automation,  
Harbin Institute of Technology, Harbin 150001, China*)

**Abstract:** The traditional image restoration algorithms based on a Hopfield neural network are unable to compress the noise and protect the details at the same time. In order to solve the problem, a new algorithm based on the modified Hopfield neural network with a continuous state change and the wavelet domain Hidden Markov Tree (HMT) model is presented. The wavelet domain HMT model is utilized as the prior information about the statistical relationship between the two image wavelet coefficients, and is introduced into the neural network model by a regularization term. The final restoration image is obtained by using the energy convergence property of the Hopfield neural network. Furthermore, a highly-parallel weight matrix determination algorithm is proposed, and then the weight values are computed batch by batch through the operation to the pattern images to avoid the multiplication of large scale matrices. Experimental results demonstrate that the visual quality of the restoration result is improved evidently for either real images or artificial images, and the Improved Signal to Noise Ratio (ISNR) is improved more than 0.3 dB compared to that of the traditional algorithms. The objectives of compressing the noise and protecting the details are achieved at the same time.

收稿日期: 2008-10-09; 修订日期: 2008-11-19.

基金项目: 国家自然科学基金资助项目 (No. 50275040)

**Key words:** image restoration; Hopfield neural network; wavelet domain Hidden Markov Tree(HMT) model; weight matrix

## 1 引 言

图像复原是由退化图像重建原始清晰图像的过程,由于其高度的病态性,在数字图像处理中是一类较难解决的问题。由于神经网络所具有的许多优良特性,如高度并行性、良好的容错能力和易于硬件实现等,近年来在众多领域都有着广泛的应用<sup>[1-2]</sup>。同样,针对神经网络的图像复原算法也吸引了大批研究者。基于神经网络的图像复原方法主要分为两类:一是运用大量真实图像与退化图像进行学习训练,再利用训练后的网络进行图像复原<sup>[3]</sup>;二是基于 Hopfield 网络的图像复原,主要利用该类网络在最优化问题求解上的突出优点<sup>[4-5]</sup>。本文将专注于第二类方法。

将神经网络用于图像复原的方法最早由 Zhou 等人提出<sup>[4]</sup>。他们将复原问题与 Hopfield 神经网络通过能量函数联系起来,提出了一种基于简单求和的二值串行网络模型,将图像复原问题转化为适合神经网络计算的最优化问题。在此基础上,Paik 等人提出了改进型的 Hopfield 神经网络模型(MHNN)<sup>[5]</sup>,改进了 Zhou 方法的网络模型庞大,算法效率低下的缺点。为了克服 Paik 方法中状态变量阶跃取值的缺点,王磊等人提出了基于状态连续变化的 Hopfield 网络的方法<sup>[6]</sup>,韩玉兵等人证明了这种算法的收敛性<sup>[7]</sup>。由于 Paik 算法采用了 Laplace 算子作为正则化项,因此会使得复原图像的边缘产生不同程度的模糊,极大降低了视觉质量。为了克服这一缺点,吴亚东等人将变分偏微分方程(PDE)引入到神经网络图像复原模型中,提出了基于调和方程和总变分方程的神经网络图像复原算法,在一定程度上保护了复原图像的边缘和细节<sup>[8]</sup>。

到目前为止,文献中所提出的 Hopfield 神经网络图像复原方法中的正则化项主要基于 Laplace 算子和变分 PDE,这两种模型均与具体的待复原图像无关,无法精确地反映图像的先验信息。我们注意到,小波域隐 Markov 树(HMT)模型能够准确地刻画自然图像的小波变换统计特性<sup>[9]</sup>,因此,本文将小波域 HMT 模型引入到

Hopfield 神经网络模型中,提出了一种新的神经网络图像复原算法,并证明了算法的收敛性。同时,为了解决直接求取网络权值矩阵困难的问题,提出了一种高度并行的权值矩阵计算方法,将空间复杂度转化为时间复杂度,避免了大型矩阵的乘法运算。为了验证算法的性能,在实验中还将本文算法与 Paik 算法和基于变分 PDE 的神经网络复原算法进行比较,实验结果表明,本文算法在视觉效果和客观评价指标上,较以往算法均有明显提高。

## 2 基于状态连续变化的 Hopfield 神经网络图像复原的基本原理

一般情况下,图像的降质模型可以用下式来表示<sup>[10]</sup>

$$y = H\hat{x} + n, \quad (1)$$

其中, $\hat{x}$ 、 $y$ 、 $n$  分别表示原始图像,退化图像和加性噪声, $H$  为成像系统的退化矩阵。图像复原问题可以转化为下述约束最优化问题

$$\begin{cases} \min R = \|Cx\|^2 \\ \text{s. t. } y = Hx \end{cases}, \quad (2)$$

其中, $R$  为正则化项, $\|\cdot\|$  表示  $L_2$  范数, $C$  是为了克服病态性所引入的正则化算子,该问题等价于最小化下面的代价函数

$$E = \frac{1}{2} \|y - Hx\|^2 + \frac{\lambda}{2} \|Cx\|^2, \quad (3)$$

其中, $\lambda > 0$  为正则化参数,用来调整解的保真度与平滑度之间的平衡。将(3)式展开并舍去常数项得(仍用  $E$  表示)

$$E = \frac{1}{2} x^T T x - b^T x, \quad (4)$$

其中, $T = H^T H + \lambda C^T C$ ,  $b = H^T y$ 。

改进的 Hopfield 神经网络结构如图 1 所示。其网络能量函数为

$$E_{hp} = -\frac{1}{2} v^T A v - b^T v, \quad (5)$$

其中, $A$  为网络权值矩阵, $v$  为网络状态矢量,将代价函数(4)与 Hopfield 神经网络能量函数(5)相对应可得: $A = -T$ ,  $v = x$ 。第  $i$  个神经元状态

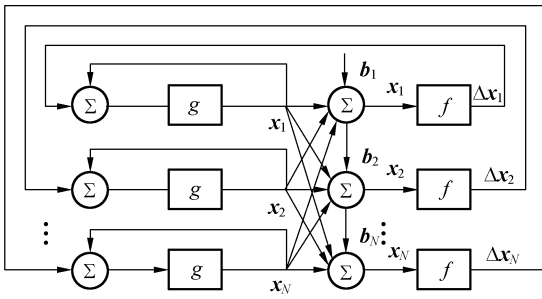


图 1 改进的 Hopfield 神经网络模型  
Fig. 1 Modified Hopfield neural network

更新规则为

$$v_i(t+1) = g(v_i(t) + \Delta v_i), i = 1, \dots, N, \quad (6)$$

$$g(v) = \begin{cases} 0, & v < 0 \\ v, & 0 \leq v \leq 255 \\ 255, & v > 255 \end{cases}, \quad (7)$$

$$\Delta v_i = f(u_i), \quad (8)$$

其中

$$u_i = b_i - \sum_j t_{ij} v_j(t) = \mathbf{e}_i^T (\mathbf{b} - \mathbf{T} \mathbf{v}(t)), \quad (9)$$

$\mathbf{e}_i$  表示第  $i$  个元素为 1, 其余元素为 0 的单位向量。对于连续 Hopfield 网络, 式 (8) 中的函数  $f$  可以取下列两个函数之一<sup>[7]</sup>

$$f(u_i) = r u_i, r > 0, \quad (10)$$

$$f(u_i) = \frac{2}{1 + e^{-r u_i}} - 1, r > 0, \quad (11)$$

其中,  $r$  为调节参数。

### 3 基于 HMT 的 Hopfield 神经网络图像复原

小波域 HMT 模型最早由 Crouse 等人提出<sup>[9]</sup>, 由于该模型可以比较精确地刻画真实图像




图 2 二维小波域 HMT 模型

Fig. 2 Two dimensional wavelet-domain HMT model

小波系数间的统计特性, 因此, 近年来被广泛应用于图像复原等众多领域<sup>[11-12]</sup>。二维图像小波域 HMT 模型具有如图 2 所示的结构。

其中实心点表示小波系数, 空心点表示隐藏的状态。图像的小波系数有两个基本统计特性: 非高斯分布特性和尺度间隐藏状态的 Markov 依赖性。单个结点的小波系数概率分布可以用独立混合高斯分布来描述, 即如果已知第  $i$  个结点的状态概率, 则该结点小波系数为  $w_i$  的概率密度与其它结点无关, 并且有

$$f_{w_i}(w_i) = \sum_{m=1}^M p_{S_i}(m) f_{w_i|S_i}(w_i | S_i = m), \quad (12)$$

其中,  $p_{S_i}(m) = p(S_i = m | \theta)$  表示在 HMT 模型参数  $\theta$  已知的情况下第  $i$  个小波系数处于状态  $m$  的概率;  $f_{w_i|S_i}(w_i | S_i = m) = g(w_i; \mu_{i,m}, \sigma_{i,m}^2)$  表示第  $i$  个小波系数处于状态  $m$  时取值为  $w_i$  的概率服从均值、方差分别为  $\mu_{i,m}$  和  $\sigma_{i,m}^2$  的高斯分布;  $M$  为隐藏状态可取值的数量, 通常取  $M=2$ 。HMT 模型中结点状态的 Markov 依赖性可以表述为: 任一结点的隐藏状态仅依赖于其父结点  $\rho(i)$  的隐藏状态。这种依赖关系可由条件概率  $\epsilon_{i,\rho(i)}^m = p_{S_i|S_{\rho(i)}}(S_i = m | S_{\rho(i)} = n)$  来表达。小波域 HMT 模型的参数向量由上述相关参数和根结点的状态概率  $p_{S_1}(m)$  构成, 记为  $\theta$ , 可通过 EM 算法训练得到<sup>[9]</sup>。

下面, 我们将 HMT 模型作为图像的先验知识引入到图像复原算法框架中。将 (1) 式两边进行正交小波变换得

$$\mathbf{W} \mathbf{y} = (\mathbf{W} \mathbf{H} \mathbf{W}^T) \mathbf{W} \mathbf{x} + \mathbf{W} \mathbf{n}, \quad (13)$$

其中,  $\mathbf{W}$  为二维小波变换矩阵, 这里我们只考虑正交小波变换, 因此  $\mathbf{W}^T \mathbf{W} = \mathbf{I}$ ,  $\mathbf{I}$  为单位矩阵。利用图像的 HMT 模型来指定图像在小波域的先验概率密度  $P(\mathbf{W} \mathbf{x} | \theta)$ , 我们寻找的是这样一个解: 它满足条件  $\mathbf{y} = \mathbf{H} \mathbf{x}$ , 并且使  $P(\mathbf{W} \mathbf{x} | \theta)$  取极大值。将约束最优化问题 (2) 重写成如下形式

$$\begin{cases} \min R_{\text{HMT}} = -\log[P(\mathbf{W} \mathbf{x} | \theta)] \\ \text{s. t. } \mathbf{y} = \mathbf{H} \mathbf{x} \end{cases}, \quad (14)$$

由式 (12) 及各结点小波系数的分布独立性有

$$R_{\text{HMT}} = \sum_{i=1}^N -\log\left(\sum_{m=1}^2 p_{S_i}(m) f_{w_i|S_i}(w_i | S_i = m)\right), \quad (15)$$

其中  $N$  为结点总数。由于式 (15) 形式比较复杂,

参考文献[11],我们可将其简化为

$$R_{\text{HMT}} = (\mathbf{W}\mathbf{x})^T \mathbf{P}(\mathbf{W}\mathbf{x}) = \mathbf{x}^T \mathbf{W}^T \mathbf{P} \mathbf{W} \mathbf{x}, \quad (16)$$

其中,  $\mathbf{P} = \text{diag}(1/(p_{S_i}(1)\sigma_{i,1}^2 + p_{S_i}(2)\sigma_{i,2}^2))$ ,  $p_{S_i}(m)$ 可由 Upward-Downward 算法得到<sup>[9]</sup>。参照式(2),(4)和(16),可得到新的网络权值矩阵

$$\mathbf{T}_{\text{HMT}} = \mathbf{H}^T \mathbf{H} + \lambda \mathbf{W}^T \mathbf{P} \mathbf{W}, \quad (17)$$

$$\mathbf{A}_{\text{HMT}} = -\mathbf{T}_{\text{HMT}}. \quad (18)$$

由于矩阵  $\mathbf{P}$  是对角矩阵且其对角线元素均  $>0$ , 因此,  $\mathbf{T}_{\text{HMT}}$  为对称正定矩阵, 并且其对角线元素  $t_{ii} >0$ , 因此本文提出的 Hopfield 神经网络复原算法收敛, 具体证明参见文献[7]。

## 4 权值矩阵计算方法

在式(17)、(18)中,为了计算矩阵  $\mathbf{A}_{\text{HMT}}$ ,需要分别计算  $\mathbf{H}^T \mathbf{H}$  及  $\mathbf{W}^T \mathbf{P} \mathbf{W}$ 。直接计算是非常困难的,主要原因有两点:一是参与计算的矩阵规模一般都比较庞大,直接进行乘法运算将占用大量内存。二是因为二维小波变换矩阵  $\mathbf{W}$  难以写出具体的形式,但是将它作为小波算子来实现却容易得多。基于以上两点原因,本文提出了一种权值矩阵  $\mathbf{A}_{\text{HMT}}$  的计算方法,利用退化矩阵  $\mathbf{H}$  及小波变换矩阵  $\mathbf{W}$  自身的特点,避开了直接计算矩阵乘法,将空间复杂度转化为时间复杂度,易于在计算机上实现。

首先我们注意到,将矩阵  $\mathbf{A}_{\text{HMT}}$  与单位向量  $\mathbf{e}_i$  相乘,将得到向量  $(a_{1i}, a_{2i}, \dots, a_{Ni})^T$ , 即  $\mathbf{A}_{\text{HMT}}$  的第  $i$  列列向量。可以将  $\mathbf{e}_i$  看成是一幅图像的辞书式堆积向量,即

$$\mathbf{e}_i = \text{rvec}(\mathbf{X}_i), \quad (19)$$

其中,  $\text{rvec}$  为行向量化函数,  $\mathbf{X}_i$  为一幅图像,其大小与复原图像相同,并且按照行优先顺序计数的第  $i$  个元素为 1,其余元素为 0。我们可以称  $\mathbf{X}_i$  为模板图像,因此,  $\mathbf{A}_{\text{HMT}}$  与单位向量的乘积可以通过对相应的模板图像进行算子操作来实现,这样,  $\mathbf{A}_{\text{HMT}}$  第一项中的  $\mathbf{H} \cdot$  及  $\mathbf{H}^T \cdot$  可以利用 FFT 来计算<sup>[13]</sup>,第二项中的  $\mathbf{W} \cdot$  及  $\mathbf{W}^T \cdot$  可以通过线性滤波器组来实现<sup>[14]</sup>。权值矩阵计算方法的具体步骤如下:

- (1) 设  $i=1$ , 初始化  $\mathbf{X}_i$ ;
- (2) 利用 FFT 计算  $\mathbf{V}_1 = \mathbf{H}^T \mathbf{H} \cdot \text{rvec}(\mathbf{X}_i)$ ;
- (3) 通过对  $\mathbf{X}_i$  进行小波变换、点乘矩阵  $\mathbf{P}$  的对角线元素、小波逆变换及标量乘法求得  $\mathbf{V}_2 =$

$$\lambda \mathbf{W}^T \mathbf{P} \mathbf{W} \cdot \text{rvec}(\mathbf{X}_i);$$

(4) 计算并保存  $\mathbf{A}_{\text{HMT}}$  的第  $i$  列  $\mathbf{V} = -(\mathbf{V}_1 + \mathbf{V}_2)$ ;

(5) 如果  $i=N$ , 则结束, 否则,  $i=i+1$ , 更新  $\mathbf{X}_i$ , 转 2);

在上述算法的运算过程中,  $\mathbf{A}_{\text{HMT}}$  各列的求取是互不相关的, 因此可以在不同的处理器上并行进行, 大大提高计算效率。

## 5 实验与结果

在实验中,我们分别采用真实图像与人工生成的图像对本文算法进行测试。为了比较算法性能,本文算法的结果将与 Paik 算法<sup>[5]</sup>和基于变分 PDE 调和模型的算法<sup>[8]</sup>进行对比。实验中使用的真实图像为标准 Lena 图像,我们从中截取了  $64 \text{ pixel} \times 64 \text{ pixel}$  大小的一部分。原始图像经过  $5 \text{ pixel} \times 5 \text{ pixel}$  均匀模糊和 Gaussian 白噪声 ( $\sigma=10$ ) 干扰后生成降质图像。为了较为客观地评价算法性能,我们采用提高信噪比 (ISNR) 作为客观评价指标,其定义为

$$\text{ISNR} = 10 \log_{10} \frac{\|\mathbf{x} - \mathbf{y}\|^2}{\|\mathbf{x} - \hat{\mathbf{x}}\|^2}, \quad (20)$$

其中,  $\hat{\mathbf{x}}$ ,  $\mathbf{y}$  和  $\mathbf{x}$  分别表示原始图像, 降质图像和复原图像。对于正则化参数  $\lambda$  的选择, 由于目前还没有一种统一而有效的方法, 因此我们这里采用实验的方法确定, 即对于不同  $\lambda$  进行多次实验, 选择效果最好的值作为最终的正则化参数。实验结果显示, 虽然不同的  $\lambda$  值对同一算法的复原效果有一定影响, 但只要保证算法收敛, 其对不同算法之间性能的比较影响不大。另外, 所有算法均采用全并行更新策略, 迭代次数为 50 次, 本文算法选用的小波为 db4 小波。

为了验证权值矩阵求取算法的并行性, 实验中我们将待求矩阵分为多个部分, 并分别在多个 CPU 上同时计算, 将计算时间与单 CPU 串行运算比较, 比较结果如表 1 所示。

表 1 并行与串行权值算法性能对比

Tab.1 Performance comparison of parallel and serial algorithms

CPU 数目(台)	运行时间(s)	加速比	并行效率
1	173.48		
2	89.51	1.94	97%
4	46.47	3.73	93.3%

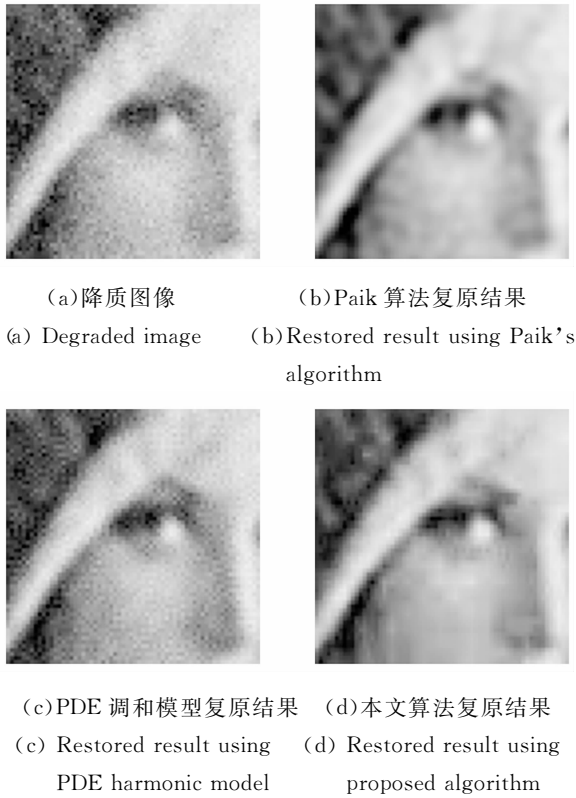


图 3 标准图像测试

Fig. 3 Standard image test

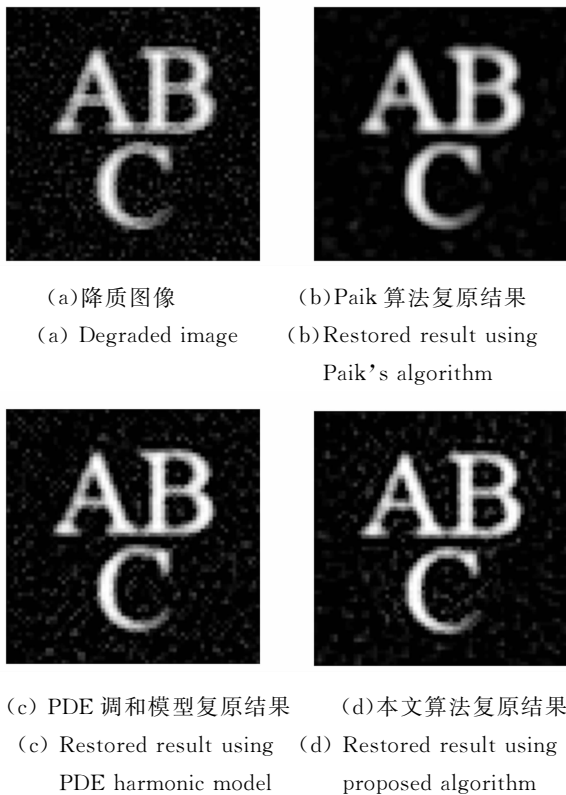


图 4 人工图像测试

Fig. 4 Artificial image test

表 2 两种测试 ISNR 结果比较 (单位: dB)

Tab. 2 Comparison of ISNR results in two tests (Unit: dB)

	Paik 算法	PDE 调和模型	本文算法
标准图像	1.715 9	0.708 9	2.217 1
人工图像	1.173 7	1.941 7	2.257 8

由表 1 可见,由于本文提出的网络权值矩阵计算方法中各列的计算是相互独立的,因此,将它们的计算任务分配给多个 CPU 同时进行将得到很高的并行效率。

实验的复原结果如图 3 和图 4 所示。由图 3 中对标准图像的复原结果可以看出,Paik 算法使得复原图像整体趋于平滑,这样虽然较好地抑制了噪声,但也使得图像边缘变得模糊。而基于变分 PDE 方法的结果边缘比较清晰,但是在图像的平滑区域,受噪声的影响产生了很多的干扰,严重地影响了视觉质量。而本文算法在视觉效果上保持了前两种算法的优点,即使得图像边缘比较锐利,而对平滑区域的噪声也有很好的抑制,对比人工生成字母图像的复原结果可以得到相同的结论。复原结果的 ISNR 值如表 1 所示,从客观评价指标来看,本文算法的 ISNR 要高于前两种算法,其中,ISNR 最少提高 0.3 dB,最高提高 1.5 dB。这里我们注意到,标准图像测试中 Paik 方法的 ISNR 比变分 PDE 方法高,而在人工图像测试中则相反。究其原因,是由于标准图像测试中的原始图像的边缘较少,图像从整体上说比较平滑,而人工图像测试中的原始图像则具有较多的锋锐边缘。Paik 方法与变分 PDE 方法的正则化项是与图像无关的,因此复原结果受原始图像自身特点的影响较大。而本文算法将图像小波系数的统计特性引入到复原算法中,对于不同种类的图像均可获得较好的结果。

## 6 结 论

本文利用小波域 HMT 模型精确刻画图像小波域统计特性的能力,将其与改进的连续 Hopfield 神经网络模型相结合,提出了一种有效的图像复原算法。并且针对神经网络权值矩阵计算困难的问题,提出了一种高度并行的权值矩阵计算方法。实验结果表明,由于本算法采用了小波域 HMT 模型作为图像的先验知识,因此,与传


统的基于图像无关正则化项的神经网络复原算法相比,其复原结果不依赖于原始图像自身的特性,具有更好的视觉效果,提高信噪比在本文的实验

中有 0.3 dB 以上的增加,并且由于采用了新的权值矩阵计算方法,大大减小了计算对内存的需求量,使得算法可以在较差的硬件条件下运行。

## 参考文献:

- [1] 刘宏建,罗毅,刘允才.可变精度的神经网络摄像机标定法[J].光学精密工程,2004,12(4):443-448.  
LIU H J, LUO Y, LIU Y C. Variable precision camera calibration using neural network [J]. *Opt. Precision Eng.*, 2004, 12(4): 443-448. (in Chinese)
- [2] 邓超,张涛,姚清华.应用小波神经网络处理 CCD 图像噪声[J].光学精密工程,2008,16(2):345-351.  
DENG CH, ZHANG T, YAO Q H. Application of wavelet neural network in removing CCD noise of digital images [J]. *Opt. Precision Eng.*, 2008, 16(2):345-351. (in Chinese)
- [3] EICHMANN G, STOJANCIC M. Superresolving signal and image restoration using a linear associative memory [J]. *Appl. Opt.*, 1987, 26: 1911-1918.
- [4] ZHOU Y T, CHELLAPPA R, JENKINS B K. Image restoration using a neural network [J]. *IEEE Trans. Acoust. Speech Signal Processing*, 1988, 36(7):1141-1151.
- [5] PAIK J K, KATSAGGELOS A K. Image restoration using a modified Hopfield network [J]. *IEEE Trans. on Image Processing*, 1992, 1(1):49-63.
- [6] 王磊,戚飞虎,莫玉龙.精确复原退化图象的连续 Hopfield 网络研究 [J]. 上海交通大学学报,1997, 31(12):43-46.  
WANG L, QI F H, MO Y L. Analysis of accurately restoring degraded images based on continuous Hopfield neural network [J]. *Journal of Shang Hai Jiao Tong University*, 1997, 31(12): 43-46. (in Chinese)
- [7] 韩玉兵,吴乐南.基于状态连续变化的 Hopfield 神经网络的图像复原 [J]. 信号处理,2004, 20(5): 431-435.  
HAN Y B, WU L N. Image restoration using a modified Hopfield neural network of continuous state change [J]. *Signal Processing*, 2004, 20(5): 431-435. (in Chinese)
- [8] WU Y D, ZHU Q X, SUN S X, *et al.*. Image restoration using variational PDE-based neural network [J]. *Neurocomputing*, 2006, 69 (16-18): 2364-2368.
- [9] CROUSE M S, NOWAK R D, BARANIUK R G. Wavelet-based statistical signal processing using hidden Markov models [J]. *IEEE Trans. on Signal Processing*, 1998, 46(4):886-902.
- [10] 江洁,邓琼,张广军.基于小波变换的正则化盲图像复原算法[J].光学精密工程,2007, 15(4):582-586.  
JIANG J, DENG Q, ZHANG G J. Regularization algorithm for blind image restoration based on wavelet transform [J]. *Opt. Precision Eng.*, 2007, 15(4):582-586. (in Chinese)
- [11] 赵书斌,彭思龙.基于小波域 HMT 模型的图像超分辨率重构[J].计算机辅助设计与图形学学报, 2003, 15(11):1347-1352.  
ZHAO SH B, PENG S L. Wavelet-domain HMT-based image superresolution [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2003, 15(11):1347-1352. (in Chinese)
- [12] 汪雪林,赵书斌,彭思龙.基于小波域隐马尔可夫树模型的图像复原[J].计算机学报,2005, 28(6): 1006-1012.  
WANG X L, ZHAO S B, PENG S L. Image restoration based on wavelet-domain hidden Markov tree model [J]. *Chinese Journal of Computers*, 2005, 28(6):1006-1012. (in Chinese)
- [13] 邹谋炎.反卷积和信号复原[M].北京:国防工业出版社,2001.  
ZOU M Y. *Deconvolution and Signal Recovery* [M]. Beijing: National Defence Industry Press, 2001. (in Chinese)
- [14] MALLAT S G. A theory for multiresolution signal decomposition: the wavelet representation [J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1989, 11(7):674-693.

## 作者简介:



娄 帅(1982—),男,辽宁葫芦岛人,博士研究生,主要从事图像复原及超分辨率重建等方面的研究。E-mail: hit-loushuai@163.com



李 晶(1982—),女,吉林白山人,博士研究生,主要研究方向为空间目标的外姿态测量。E-mail: hitlijing@163.com



袁 锋(1963—),男,黑龙江哈尔滨人,教授,博士生导师,主要从事光电检测技术及精密几何参数测量技术等方面的研究。E-mail: yuanf@hit.edu.cn

## 导师简介:



丁振良(1942—),男,黑龙江哈尔滨人,教授,博士生导师,主要从事自动化测试与精密计量、光电图像与位置检测技术、精密测量精度理论等方面的研究。E-mail: dingch@hit.edu.cn

## ●下期预告

## 中子反射谱仪的闸门与会聚导管组合设计

李新喜,王 燕,黄朝强,陈 波

(中国工程物理研究院 核物理与化学研究所,四川 绵阳 621900)

为提高水平散射几何中子反射谱仪的前端束流特性,针对前端闸门与会聚中子导管的组合设计进行了优化计算。根据闸门通道截面、会聚导管进出口截面及相应内表面超镜因子不同分成多组,采用数值方法对多个组合设计进行优化计算,结合水平散射几何中子反射谱仪的特点比较分析并选取比较理想的组合。计算结果表明:会聚导管的最佳组合最好采用水平面会聚,垂直面不会聚,闸门内表面超镜因子为 2,会聚导管水平面超镜因子为 3,垂直面超镜因子为 2。通过多组比较分析,获得了水平散射几何中子反射谱仪的前端闸门与会聚导管的相关物理参数的优化组合,为谱仪的概念设计奠定了理论基础。