

基于细胞神经网络的图像复原新方法

冯 强 于盛林 张 维

(南京航空航天大学自动化学院, 南京 210016)

摘 要 针对图像复原方法普遍运算量大的问题,提出了一种利用细胞神经网络进行图像复原的新方法,并首先提出了易于硬件实现的基于边缘方向判据的正则化复原方法;然后通过细胞神经网络的能量函数设计合适的网络参数来对该正则化函数进行细胞神经网络实现。仿真结果表明,该新方法是有效的,复原效果优于有约束的最小二乘复原法和已有的细胞神经网络图像复原法,而且由于细胞神经网络的并行性和硬件易实现性,使该新方法可以实时进行图像复原。

关键词 细胞神经网络 图像复原

中图法分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2009)03-0430-05

A Novel Image Restoration Algorithm Using Cellular Neural Networks

FENG Qiang, YU Sheng-lin, ZHANG Wei

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

Abstract Aiming at the real time image restoration, a novel image restoration algorithm using cellular neural networks is proposed in this paper. First, based on the classic regularized image restoration algorithm, the edge direction constraint is introduced with easy hardware implementation. Then, suitable template parameters of cellular neural networks are designed based on the CNN energy function. The cellular neural network is applied to implement the regularization function of the traditional model of degraded image. Simulation results show the efficiency of the new algorithm, its restoration results are better than the least square image restoration method with constraints and another image restoration algorithm base on CNN. Because of the easy hardware implementation and parallel realization, the real time image restoration can be realized with the new algorithm.

Keywords cellular neural networks, image restoration

1 引 言

图像复原是图像处理的一个重要领域。由于受大气干扰、相对运动以及聚焦不良等因素影响,使得成像系统实际得到的图像不可避免地加入了噪声和干扰而引起图像的降质。由于在降质严重的情况下,对图像进行进一步应用,如特征提取、自动识别和图像分析都是相当有害的,因此,对降晰图像进行复原,在军事、遥感等许多领域都具有非常重要的实

际意义。

图像复原就是由一幅或者多幅观测图像来恢复原始图像。基本的图像复原方法有 Wiener 滤波、最小二乘法等。在此基础上,还有很多改进方法,即通过引进约束项来达到抑制噪声、保护边缘的目的^[1-2]。上述方法的基本思路都是对数值方程组进行求解,然后通过大矩阵求逆来获得复原结果。为了减小计算的复杂度,可以通过退化矩阵的特点来改善算法的效率^[3],也可以采用 Van Cittert 迭代^[4]来解卷积,以避免矩阵求逆。但是即使采用了快速

基金项目: 航空基金项目(04D52032)

收稿日期: 2007-05-08; 改回日期: 2007-09-20

第一作者简介: 冯 强(1980 ~),男,现为南京航空航天大学自动化学院测试计量技术及仪器专业博士研究生。主要研究方向为神经网络、图像处理。E-mail: nuaafengq@163.com

算法,若要实现实时的图像处理,运算量还是太大,特别是那些改进算法,因为它们在改善复原效果的同时,却大大增加了算法复杂度,如文献[2]方法,复原时间甚至长达45 s,所以,对于实时性要求苛刻的场合,一般的复原方法存在速度瓶颈。

为了实现图像的实时复原,文献[5]提出了一种基于最大后验概率估计的细胞神经网络(CNN)图像复原算法。该算法将图像的统计信息应用到CNN模板的设计中,提出了解决退化图像最大熵复原问题的模板形式,进而得到了一种退化图像的CNN复原方法。该算法虽可有效地对噪声污染的图像进行复原处理,但是由于没有成熟的模板参数设计方法,只能根据模型的物理意义大致确定合适的模板参数,因此对于退化模型已知的图像复原问题,该算法效果不理想^[6]。针对上述两个问题,本文提出了一种基于细胞神经网络的图像复原新方法,并首先提出了一种易于硬件实现的边缘方向平滑约束的正则化图像复原方法。该方法通过4个边缘方向判据来判别相应方向上是否存在边缘信息,首先生成不同的正则化参数,以尽可能地保护图像的边缘信息;然后把该正则化方法作为一个优化问题映射到CNN上,再利用CNN的能量函数确定CNN的模板参数,以便通过CNN对目标函数进行搜索,使网络能量达到全局最小值来得到问题的最优解。由于CNN的硬件易实现性和具有强大的并行处理能力,使得该方法可以实时进行图像复原运算。

2 基于边缘方向平滑约束的图像复原

2.1 正则化图像复原方法介绍

图像的降晰退化模型可以用矩阵-向量形式描述为

$$\mathbf{g} = \mathbf{H}\mathbf{f} + \mathbf{n} \quad (1)$$

其中, \mathbf{g} 、 \mathbf{f} 、 \mathbf{n} 分别为观测图像、原始图像和噪声的堆积矩阵。 \mathbf{H} 是降晰函数作为卷积核生成的循环矩阵。图像复原的核心思想是通过给定的观测图像 \mathbf{g} 和对退化模型 \mathbf{H} 及噪声 \mathbf{n} 的先验了解来寻找对原始图像 \mathbf{f} 的最优估计 $\hat{\mathbf{f}}$,使事先确定的最优准则 J 为最小。但是由于噪声的存在,使得图像复原问题具有病态性,为了克服这种病态,通常采用正则化图像复原方法,即通过对复原图像引入一定的约束,使问题的解正则化,以便降低噪声的干扰。

引入平滑约束后的 J 为

$$J = \|\mathbf{g} - \mathbf{H}\hat{\mathbf{f}}\|^2 + \lambda \|\mathbf{C}\hat{\mathbf{f}}\|^2 \quad (2)$$

其中, $\hat{\mathbf{f}}$ 表示复原图像, \mathbf{C} 为正则化算子,通常为一个各向同性的高通滤波器, λ 为正则化参数。

2.2 基于边缘方向判据的平滑约束

式(2)通过引入一个各向同性的高通滤波器生成的矩阵 \mathbf{C} 来实现平滑约束,它总是同时放大边缘和噪声,或者在抑制噪声的同时,边缘也被过度平滑掉了。为了更好地保护图像的边缘信息,本文引进了边缘方向判据,即先通过判别待复原像素附近 0° 、 45° 、 90° 和 135° 这4个方向上是否存在明确的边缘,然后运用不同的高通滤波器,让边缘方向的图像信息得到更好保护,以便获得更好的复原效果。

可通过定义边缘方向判据 P_1 、 P_2 、 P_3 和 P_4 来判定上述4个方向上面是否存在边缘,它们的计算表达式如下:

$$\begin{aligned} P_1 &= \begin{cases} 1 & |f(i, j-1) - f(i, j+1)| \geq \Delta \\ 0 & |f(i, j-1) - f(i, j+1)| < \Delta \end{cases} \\ P_2 &= \begin{cases} 1 & |f(i-1, j+1) - f(i+1, j-1)| \geq \Delta \\ 0 & |f(i-1, j+1) - f(i+1, j-1)| < \Delta \end{cases} \\ P_3 &= \begin{cases} 1 & |f(i-1, j) - f(i+1, j)| \geq \Delta \\ 0 & |f(i-1, j) - f(i+1, j)| < \Delta \end{cases} \\ P_4 &= \begin{cases} 1 & |f(i-1, j) - f(i+1, j)| \geq \Delta \\ 0 & |f(i-1, j) - f(i+1, j)| < \Delta \end{cases} \end{aligned} \quad (3)$$

式中, Δ 为一个常数。

与边缘方向判据 P_1 、 P_2 、 P_3 和 P_4 相对应的各个方向上的高通滤波器 \mathbf{c}_1 、 \mathbf{c}_2 、 \mathbf{c}_3 和 \mathbf{c}_4 如下所示:

$$\begin{aligned} \mathbf{c}_1 &= \frac{1}{4} \begin{bmatrix} 0 & 0 & 0 \\ -1 & 2 & -1 \\ 0 & 0 & 0 \end{bmatrix} & \mathbf{c}_2 &= \frac{1}{4} \begin{bmatrix} 0 & -1 & 0 \\ 0 & 2 & 0 \\ 0 & -1 & 0 \end{bmatrix} \\ \mathbf{c}_3 &= \frac{1}{4} \begin{bmatrix} -1 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & -1 \end{bmatrix} & \mathbf{c}_4 &= \frac{1}{4} \begin{bmatrix} 0 & 0 & -1 \\ 0 & 2 & 0 \\ -1 & 0 & 0 \end{bmatrix} \end{aligned} \quad (4)$$

如果以各向同性的高通滤波器 \mathbf{c}_0 为基准,然后加入边缘方向上的方向算子,则可得如下复合后的正则化算子:

$$\hat{\mathbf{c}} = \frac{1}{1 + \sum_i P_i} \left(\mathbf{c}_0 + \sum_i P_i \mathbf{c}_i \right) \quad (5)$$

其中,

$$\mathbf{c}_0 = \frac{1}{16} \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad (6)$$

然后即可得到基于边缘方向判据的平滑约束的正则化方程的具体表达式,即

$$J = \|g - H\hat{f}\|^2 + \lambda \|\hat{C}\hat{f}\|^2 \quad (7)$$

其中, \hat{C} 是以式(5)中的 \hat{c} 作为卷积核生成的循环矩阵。

3 细胞神经网络图像复原方法

3.1 细胞神经网络介绍

细胞神经网络^[7-8]是一种具有实时信号处理能力的大规模的非线性模拟电路,由于它既具有时间域上的连续处理能力,又具有类似细胞自动机的局部连接的简单的网络拓扑,所以它具有易于硬件实现^[9-10]和并行处理的能力。

一个标准的 $M \times N$ 大小的 CNN 阵列中, $C(i, j)$ 表示第 i 行第 j 列的细胞。细胞 $C(i, j)$ 的中心半径为 r 的近邻影响区域 $S_{i,j}(r)$ 定义为

$$S_{i,j}(r) = \{C(k, l) \mid \max(|k-i|, |l-j|) \leq r\} \quad (8)$$

在 CNN 中,每个细胞都有一个状态 $v_{x(i,j)}$ 、一个恒定的外界输入 $v_{u(i,j)}$ 和一个输出 $v_{y(i,j)}$ 。每个细胞的动态过程由如下的一阶微分方程表示:

$$C \frac{dv_{x(i,j)}(t)}{dt} = -\frac{1}{R}v_{x(i,j)}(t) + \sum_{(k,l) \in S_{i,j}(r)} A(i,j;k,l)v_{y(k,l)}(t) + \sum_{(k,l) \in S_{i,j}(r)} B(i,j;k,l)v_{u(k,l)} + I_{i,j} \quad (9)$$

其中, $A(i,j;k,l)$ 表示细胞 $C(k,l)$ 的输出 $v_{y(k,l)}$ 与细胞 $C(i,j)$ 之间的连接权, $B(i,j;k,l)$ 表示细胞 $C(k,l)$ 的输入 $v_{u(k,l)}$ 与细胞 $C(i,j)$ 之间的连接权。 C, R 表示等效电路中的电容和电阻, $I_{i,j}$ 表示偏置电流。

每个细胞的输出函数是一个分段线性函数,即

$$v_{y(i,j)}(t) = \frac{1}{2}(|v_{x(i,j)}(t) + 1| - |v_{x(i,j)}(t) - 1|) \quad (10)$$

CNN 的能量函数如下:

$$E_{\text{CNN}}(t) = -\frac{1}{2} \sum_{(i,j)} \sum_{(k,l) \in S_{i,j}(r)} A(i,j;k,l)v_{y(i,j)}(t)v_{y(k,l)}(t) - \sum_{(i,j)} I_{i,j}v_{y(i,j)}(t) + \frac{1}{2R} \sum_{(i,j)} v_{x(i,j)}^2(t) - \sum_{(i,j)} \sum_{(k,l) \in S_{i,j}(r)} B(i,j;k,l)v_{y(i,j)}v_{u(k,l)} \quad (11)$$

该能量函数随时间的变化为

$$\frac{dE(t)}{dt} = -C \left(-\frac{1}{R}v_{x(i,j)}(t) + \sum_{(k,l) \in S_{i,j}(r)} A(i,j;k,l)v_{y(k,l)}(t) + \sum_{(k,l) \in S_{i,j}(r)} B(i,j;k,l)v_{u(k,l)}(t) + I_{i,j} \right)^2 \leq 0 \quad (12)$$

由上式可知,随着时间的增加, CNN 总是向着网络能量减小的方向运动,网络最终会达到稳定的平衡点,也就是网络能量的最小值点。

3.2 细胞神经网络图像复原方法

CNN 用于图像复原时,其阵列规模和待复原的图像规模相同。复原时,先将观测得到的图像 g 作为 CNN 的初始值映射到 CNN 的空间排列细胞阵列上;然后利用 CNN 对网络能量进行搜索,使 CNN 最终到达稳定的平衡点。此稳定平衡点就是 CNN 能量函数的最小值,也是正则化方程的极小值点。此时 CNN 的输出就是满足式(7)约束条件的最优解,也就是图像复原的结果。关键问题是如何将式(7)的系数映射到 CNN 的能量函数(式(11))中,以便得到符合条件需要的一组模板。

将 g, f, H 和 \hat{c} 分别代入式(7),即可得到以下具体的表达式:

$$J = \sum_{(i,j)} \left(g(i,j) - \sum_{(k,l) \in S_{i,j}(r)} h(i-k, j-l)f(k,l) \right)^2 + \lambda \sum_{(i,j)} \left(\sum_{(k,l) \in S_{i,j}(r)} \hat{c}(i-k, j-l)f(k,l) \right)^2 = \sum_{(i,j)} \left(g(i,j) - \sum_{(k,l) \in S_{i,j}(r)} h(i-k, j-l)f(k,l) \right)^2 + \lambda \sum_{(i,j)} \left(\sum_{(k,l) \in S_{i,j}(r)} \hat{c}(i-k, j-l)f(k,l) \right)^2 = \sum_{(i,j)} (g(i,j))^2 + \sum_{(i,j)} \left(\sum_{(k,l) \in S_{i,j}(r)} h(i-k, j-l)f(k,l) \right)^2 - 2 \sum_{(i,j)} \left(g(i,j) \sum_{(k,l) \in S_{i,j}(r)} h(i-k, j-l)f(k,l) \right) + \lambda \sum_{(i,j)} \left(\sum_{(k,l) \in S_{i,j}(r)} \hat{c}(i-k, j-l)f(k,l) \right)^2 \quad (13)$$

如果令

$$\hat{J} = -2 \sum_{(i,j)} \left(g(i,j) \sum_{(k,l) \in S_{i,j}(r)} h(i-k, j-l)f(k,l) \right) + \sum_{(i,j)} \left(\sum_{(k,l) \in S_{i,j}(r)} h(i-k, j-l)f(k,l) \right)^2 + \lambda \sum_{(i,j)} \left(\sum_{(k,l) \in S_{i,j}(r)} \hat{c}(i-k, j-l)f(k,l) \right)^2 \quad (14)$$

则

$$J = \sum_{(i,j)} (g(i,j))^2 + \hat{J} \quad (15)$$

由于观测图像 g 是已知的,所以 $\sum_{(i,j)} (g(i,j))^2$ 也已知。因此 \hat{J} 的最小值也对应着 J 的最小值。

若将 \hat{J} 展开,则可改写成以下类似式(11)形式的公式:

$$\begin{aligned} \hat{J} = & -2 \sum_{(i,j)} \left(f(i,j) \sum_{(k,l) \in S_{i,j}(r)} h(i-k,j-l)g(k,l) \right) + \\ & \sum_{(i,j)} \left((f(i,j))^2 \sum_{(m,n) \in S_{i,j}(r)} \left((h(m-i,n-j))^2 + \right. \right. \\ & \left. \left. \lambda (c(m-i,n-j))^2 \right) \right) + \\ & \sum_{(i,j)} \left(f(i,j) \sum_{\substack{(k,l) \in S_{i,j}(r) \\ (k,l) \neq (i,j)}} \left(2f(k,l) \sum_{\substack{(m,n) \in S_{i,j}(r) \\ (m,n) \in S_{k,l}(r)}} (h(m, \right. \right. \\ & \left. \left. n)h(k+m-i,l+n-j) + \lambda \hat{c}(m,n) \hat{c}(k+m- \right. \right. \\ & \left. \left. i,l+n-j) \right) \right) \right) \quad (16) \end{aligned}$$

由 $E_{CNN}(t) = \hat{J}, v_{u(i,j)} = g(i,j), v_{y(i,j)} = f(i,j)$ 可知,通过比较式(11)与式(16),所得到的合适的 CNN 3 个模板参数为

$$\begin{cases} A(i,j;k,l) = \begin{cases} -4 \sum_{\substack{(m,n) \in S_{i,j}(r) \\ (m,n) \in S_{k,l}(r)}} (h(m-i,n-j)h(m-k,n-l) + \\ \lambda \hat{c}(m-i,n-j) \hat{c}(m-k,n-l)) \\ (k,l) \neq (i,j) \\ \frac{1}{R} - 2 \sum_{(m,n) \in S_{i,j}(r)} (h(m-i,n-j))^2 - \\ 2\lambda \sum_{(m,n) \in S_{i,j}(r)} (\hat{c}(m-i,n-j))^2 \\ (k,l) = (i,j) \end{cases} \\ B(i,j;k,l) = 2h(i-k,j-l) \\ I_{i,j} = 0 \end{cases} \quad (17)$$

4 仿真结果

为了验证本文算法的有效性,还将本文方法的图像复原效果和文献[5]方法、有约束的最小二乘法进行了比较。实验环境为 AMD1800 + 型号的 CPU,512M 内存,Matlab 7.0。测试图像采用大小为 256×256 的标准测试图像 Cameraman、Lena 和 Bridge,以不同的退化模型来验证本文方法的有效性。图 1 为 Cameraman 图像的几种方法的复原结果。有约束的最小二乘法参数取 $\lambda = 0.00125$ 。CNN 采用步长 0.1 的前向欧拉公式进行模拟,并且令式(3)中 $\Delta = 3$,式(9)中 $C = 1, R = 1$,式(15)中 $\lambda = 0.00125$ 。从图 1 复原结果可见,文献[5]的方法由于原理性的缺陷,其处理退化模型已知的退化图像的效果不佳,3 种方法中,本文方法的处理效果最佳。

为了定量检验图像复原的效果,本文采用以下峰值信噪比 (PSNR) 作为评价图像复原效果的指标:

$$PSNR = 10 \log \frac{255^2}{\frac{1}{MN} \sum_{(i,j)} (x_{i,j} - \hat{x}_{i,j})^2} \quad (18)$$

其中, x 为标准图像, \hat{x} 为复原后的图像, M 和 N 分别为图像的行和列的数目。

表 1 列出了对于不同的测试图像,在不同的退化模型下,本文方法和文献[5]方法、最小二乘法得到的复原结果的 PSNR 值的比较。其中高斯函数模糊采用的是大小 5×5 、方差为 1 的高斯函数,并加入 2% 的均匀高斯白噪声;运动模糊就是在曝光时间内, x 方向和 y 方向各移动 5 pixels,并加入 2% 的均匀高斯白噪声。从表 1 可以看出,本文方法的复原效果要优于其他两种方法。



图 1 原始图像、退化图像和复原图像

Fig. 1 Original image, degraded image and restored image

表 1 实验结果比较

Tab. 1 List of experiment result

测试图像	不同复原方法复原图像的 PSNR 值 (dB)					
	Gaussian 模糊			运动模糊		
	文献[5]方法	最小二乘法	本文方法	文献[5]方法	最小二乘法	本文方法
Cameraman	23.37	25.35	26.17	22.76	23.84	25.15
Lena	24.28	25.90	27.79	24.22	24.16	26.95
Bridge	21.25	23.19	23.44	20.70	22.65	22.79

5 结 论

为了能够实时地进行图像复原,本文提出了一种基于神经网络的图像复原新方法。该方法首先提出了易于硬件实现的边缘方向约束方法,即先利用边缘方向判据产生合适的正则化参数,从而达到更好的保护边缘和细节信息的目的;然后将图像复原的正则化方法映射到 CNN 上,同时将 CNN 的能量函数和正则化方程对应,得到 CNN 的网络参数;最后利用 CNN 的平衡稳定状态能量最小的特点来得到正则化方程的最小值,从而得到原始图像的最优解。

从仿真结果可以看出,本文方法在不同的点扩散函数下,都能够进行图像复原,而且图像复原的效果好于文献[5]的神经网络图像复原方法和有约束的最小二乘法。另外,由于本文的边缘方法约束简单,且容易硬件实现,同时 CNN 也具有硬件容易实现和并行处理的特点,所以相对于文献[2]巨大的运算量,本文方法可以满足实时性的要求。在实时性要求严格的场合,具有很大的实用性。

参考文献 (References)

- 1 Liu Peng, Zhang Yan, Mao Zhi-gang. An adaptive smoothness constraint image restoration algorithm based on fuzzy functions [J]. Journal of Image and Graphics, 2005, **10**(9): 1178-1183. [刘鹏, 张岩, 毛志刚. 一种基于模糊函数的自适应平滑约束图像复原算法 [J]. 中国图象图形学报, 2005, **10**(9): 1178-1183.]
- 2 Cao Xue-gang, Yi Mo, Wang Xue-lin, *et al.* Image restoration with

- edge-preserving regularization in wavelet domain [J]. Journal of Image and Graphics, 2006, **11**(2): 224-229. [曹学光, 易沫, 汪雪林等. 小波域边缘保持正则化图像复原 [J]. 中国图象图形学报, 2006, **11**(2): 224-229.]
- 3 Xu G F, Bose T, Kober W, *et al.* A fast adaptive algorithm for image restoration [J]. IEEE Transactions on Circuit and System-I: Fundamental Theory and Application, 1999, **46**(1): 216-220.
- 4 Wang Yan-pin. Signal Restoration and Rebuilding [M]. Nanjing: Southeast University Press, 1992:124-125. [王延平. 信号复原与重建 [M]. 南京:东南大学出版社, 1992:124-125.]
- 5 Zhao Jian-ye, Yu Dao-heng. A new approach for image restoration based on cellular neural network [J]. Journal of Electronics, 1998, **21**(2): 168-174. [赵建业, 余道衡. 用细胞神经网络实现图像恢复的一种新方法 [J]. 电子科学学刊, 1998, **21**(2): 168-174.]
- 6 Bai Sen, Zhang Bang-li, Cao Cang-xiu. Review of neural network for image restoration [J]. Journal of Image and Graphics, 2002, **7**(11):1105-1112. [柏森, 张邦礼, 曹长修. 神经网络图像复原方法的研究进展 [J]. 中国图象图形学报, 2002, **7**(11): 1105-1112.]
- 7 Chua L O, Yang L. Cellular neural networks: theory [J]. IEEE Transactions on Circuit and System, 1988, **35**(10): 1257-1272.
- 8 Chua L O, Yang L. Cellular neural networks: applications [J]. IEEE Transactions on Circuit and System, 1988, **35**(10): 1273-1290.
- 9 Nagy Zoltan, Voroshazi Zsolt, Szolgay Peter. Emulated digital CNN-UM solutions of PDEs [J]. International Journal of Circuit Theory and Applications, 2006, **34**:445-470.
- 10 Rodrigex-Vazquez A, Dominguez-Castro R, Espejo S. Challenges in mixed-signal IC design of CNN chips in submicron CMOS [A]. In: Proceedings of the fifth IEEE International Workshop on Cellular Neural Networks and their Applications [C], London, UK, 1998:13.