

基于脉冲耦合神经网络和图像熵的各向异性扩散模型研究

郭业才 周林锋

Study of anisotropic diffusion model based on pulse coupled neural network and image entropy

Guo Ye-Cai Zhou Lin-Feng

引用信息 Citation: *Acta Physica Sinica*, 64, 194204 (2015) DOI: 10.7498/aps.64.194204

在线阅读 View online: <http://dx.doi.org/10.7498/aps.64.194204>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn/CN/Y2015/V64/I19>

您可能感兴趣的其他文章

Articles you may be interested in

相干场成像全相位目标直接重构法

All-phase target reconstruction method for coherent field imaging

物理学报.2015, 64(12): 124205 <http://dx.doi.org/10.7498/aps.64.124205>

数字显微全息重建图像的景深扩展研究

Study on extending the depth of field in reconstructed image for a micro digital hologram

物理学报.2015, 64(11): 114209 <http://dx.doi.org/10.7498/aps.64.114209>

基于小波与重调和方程的扩散去噪模型的研究

Diffusion denoising model based on the wavelet and biharmonic equation

物理学报.2015, 64(6): 064203 <http://dx.doi.org/10.7498/aps.64.064203>

基于梯度与曲率相结合的图像平滑模型的研究

Image smoothing model based on the combination of the gradient and curvature

物理学报.2015, 64(4): 044201 <http://dx.doi.org/10.7498/aps.64.044201>

基于 Demons 算法改进的图像去噪模型研究

Image denoising model based on the improved Demons algorithm

物理学报.2015, 64(2): 024205 <http://dx.doi.org/10.7498/aps.64.024205>

基于脉冲耦合神经网络和图像熵的各向异性扩散模型研究*

郭业才[†] 周林锋

(南京信息工程大学, 江苏省气象探测与信息处理重点实验室, 南京 210044)

(南京信息工程大学, 江苏省大气环境与装备技术协同创新中心, 南京 210044)

(南京信息工程大学电子与信息工程学院, 南京 210044)

(2015年3月31日收到; 2015年5月11日收到修改稿)

在图像去噪过程中, 大部分基于偏微分方程的各向异性扩散模型均使用梯度信息检测边缘, 当边缘部分被噪声严重污染时, 这些方法不能有效检测出这些边缘, 因而无法保留边缘特征. 为了较完整的保留图像的区域信息, 用脉冲耦合神经网络(PCNN)能使具有相似输入的神经元同时产生脉冲的性质对噪声图像做处理, 得到图像熵序列, 并将图像熵序列作为边缘检测算子引入到扩散方程中, 不仅能克服仅用梯度作为边缘检测算子易受噪声影响的弊端, 而且能较完整地保留图像的区域信息. 然后, 用最小交叉熵准则搜索使去噪前后图像信息量差异最小的阈值, 设计最佳阈值控制扩散强度, 建立基于脉冲耦合神经网络与图像熵改进的各向异性扩散模型(PCNN-IEAD). 分析与仿真结果表明, 该模型与经典模型相比, 保留了更多的图像信息, 能够兼顾去除图像的噪声和保护图像的边缘纹理等细节信息, 较完整的保留了图像的区域信息, 性能指标同样也证实了新模型的优越性. 另外, 该模型的运行时间较经典模型的短, 因此, 该模型是一个理想的模型.

关键词: 图像去噪, 脉冲耦合神经网络, 图像熵, 最小交叉熵

PACS: 42.30.Wb, 02.30.Jr

DOI: 10.7498/aps.64.194204

1 引言

图像去噪的方法有很多种, 而近20年来, 基于偏微分方程(partial differential equation, PDE)的方法在图像去噪中得到了广泛的应用^[1-6]. Perona和Malik首次提出了经典的各向异性扩散PM模型, 该模型由一个关于图像梯度模值的扩散函数控制图像的扩散程度, 使图像在梯度模值小的区域进行大规模地扩散, 在梯度模值大的区域进行小规模扩散^[7]. 1992年, Osher和Rudin等提出基于图像的全变差正则化模型(ROF模型), 从而更好地保持图像的边缘纹理等细节特征, 更突出了PDE在

图像去噪中的重要地位^[8]. 随后, 出现了大量的基于偏微分方程的图像去噪方法的研究^[9-12]. 周先春等对该算法做了很多的研究, 提出了一系列改进的各向异性扩散模型, 有效地提高了模型的边缘检测能力^[13-15]. Zhang等提出了一种ROF模型和四阶模型的组合图像去噪模型, 该模型是通过某一权函数将运用AOS算法求解出的ROF模型和四阶PDE模型进行了加权组合, 相对某单一去噪模型在消除“阶梯效应”现象和保留边缘信息方面有所改善^[16]. 李金才等提出了一种基于图像熵的各向异性扩散滤波方法(IEAD模型), 该方法使用图像熵作为边缘检测算子, 避免了由于均值和方

* 国家自然科学基金(批准号: 11202106, 61201444)、教育部高等学校博士学科点专项科研基金(批准号: 20123228120005)、江苏省“信息与通信工程”优势学科建设项目、江苏省气象探测与信息处理重点实验室开放课题(批准号: KDXS1204, KDXS1403)、江苏省青蓝工程和江苏省高校自然科学研究项目(批准号: 13KJB170016)资助的课题.

[†] 通信作者. E-mail: guo-yecai@163.com

差等统计量的估计带来的误差,提高了边缘检测能力^[17]. 国外学者也做了很多研究,文献^[18]提出了一种NLM滤波器,该滤波器较好地保持了图像纹理和细节特征. Dabov等提出了BM3D去噪方法,该方法去噪后的图像不仅有较高的信噪比,视觉效果也很好^[19]. Deledalle等在文献^[20]上提出了PPB(probabilistic patch-based)滤波器,在合成孔径雷达(synthetic aperture radar, SAR)的滤波上取得了较好的效果. 目前,基于小波的图像阈值去噪也取得了很多研究成果^[21,22].

大部分各向异性扩散的图像去噪方法均使用梯度信息检测边缘,当边缘部分被噪声严重污染时,这些方法未必能检测这些边缘,因而无法保存由边缘包含的特征. 本文基于脉冲耦合神经网络(PCNN)^[23,24]的性质和图像熵的意义,提出了一种基于脉冲耦合神经网络与图像熵改进的各向异性扩散模型(PCNN-IEAD). 该方法将图像熵序列作为另一个边缘检测算子引入到扩散方程中,避免了仅用梯度作为边缘检测算子易受噪声影响的弊端,能够在有效去除图像噪声的同时,较完整的保留图像区域的信息.

2 经典的各向异性扩散模型

2.1 PM模型

PM模型是将图像边缘检测与图像滤波有效的结合在一起,它的表示形式如下:

$$\frac{\partial I(x, y, t)}{\partial t} = \text{div} [g(|\nabla I(x, y, t)|) \nabla I(x, y, t)],$$

$$I(x, y, 0) = I_0(x, y), \quad (1)$$

(1)式中, div , ∇ 分别为散度算子和梯度算子, $I(x, y, 0)$ 为原始图像, $I(x, y, t)$ 为时间 t 时刻的平滑图像, $g(s)$ 是依赖于图像梯度模值的单调递减的扩散函数, PM模型用梯度 $|\nabla I|$ 大小来检测图像的某一区域是均匀的区域还是边缘. Perona, Malik定义了两个有效的扩散函数,表达式如下:

$$g(|\nabla I|) = \frac{1}{1 + \left(\frac{|\nabla I|}{k}\right)^2}, \quad (2)$$

$$g(|\nabla I|) = \exp\left(-\left(\frac{|\nabla I|}{k}\right)^2\right). \quad (3)$$

因为扩散函数 $g(|\nabla I|)$ 单调递减, k 值的大小控制着扩散的强度,当 $k < |\nabla I|$ 时, PM模型能够去

除噪声并增强边缘;当 $k \geq |\nabla I|$ 时,去除噪声并保留边缘.

2.2 ROF模型

ROF模型是另一种经典的去噪模型,其基本思想是含噪声图像的总变分大于无噪声图像的总变分,因此构造一个能量泛函并转化为偏微分方程来求解, ROF模型的能量泛函公式为

$$E(I) = \int |\nabla I| \, d\Omega + \lambda \int |I - I_0|^2 \, d\Omega, \quad (4)$$

式中, I_0 是原始图像, I 为变化中的灰度图像, ∇I 为图像像素的梯度, λ 为拉格朗日算子, 其Euler-Lagrange方程为

$$\lambda(I - I_0) - \text{div}\left(\frac{\nabla I}{|\nabla I|}\right) = 0. \quad (5)$$

用梯度下降流解(5)式, 则可得ROF模型为

$$\frac{\partial I}{\partial t} = \text{div}\left(\frac{\nabla I}{|\nabla I|}\right) - \lambda(I - I_0), \quad (6)$$

式中, div , ∇ 分别为散度算子和梯度算子.

ROF模型实质上就是各向异性扩散, 它能在去噪的同时很好地保持图像的边缘. 但该模型有时会将噪声当成边缘, 从而使恢复的图像产生假边缘.

2.3 IEAD模型

IEAD模型是李金才等在2013年提出的一种基于图像熵的各向异性扩散滤波方法, 该方法使用图像熵作为边缘检测算子, 避免了由于均值和方差等统计量的估计带来的误差, 提高了边缘检测能力, 其本质上是对各向异性扩散模型的边缘检测算子作出的改进, IEAD模型如下:

$$\frac{\partial I}{\partial t} = \text{div}(c(q_s) \nabla I),$$

$$I(t = 0) = I_0, \quad (7)$$

式中, div 是散度算子, ∇ 是梯度算子, I_0 是原始图像, I 为变化中的灰度图像, $c(q_s)$ 是扩散系数, q_s 是边缘检测算子, 其中,

$$c(q_s) = \frac{1}{\sqrt{1 + (q_s - q_0)^2}}, \quad (8)$$

$$q_s = -\sum_{t \in \eta_s} p_{s,t} \log p_{s,t}, \quad (9)$$

$$q_0 = \text{mean}(H), \quad (10)$$

$$H = -p_i \log p_i, \quad (11)$$

式中, s 表示当前像素点的位置, η_s 表示位于点 s 的邻居像素点, $p_{s,t}$ 表示像素点 t 的灰度值在整个平滑窗口中个数的比例, q_0 为阈值, H 为图像熵, $i(i = 0, 1, 2, \dots, L - 1)$ 为图像的灰度级, $p(i)$ 为灰度级 i 出现的频率, 即为归一化直方图.

3 改进的扩散模型 (PCNN-IEAD)

IEAD 模型是针对乘性噪声设计的, 对于加性噪声效果一般, 甚至会起到反作用. 虽然将图像熵作为边缘检测算子可以克服在不同灰度值水平的同质区域内相同的噪声起伏却得到梯度值差异较大的缺陷, 能更好地反映图像的灰度值变化, 但是在强噪声的情况下, 该模型仍不能较完整的保留图像区域的信息.




图1 脉冲耦合神经网络模型

Fig. 1. Pulse coupled neural network model.

脉冲耦合神经网络 (PCNN) 被广泛应用于图像平滑、图像分割以及边缘检测等图像处理领域, 并已显示了其优越性. 该 PCNN 模型的离散数学迭代方程如下 (如图 1 所示):

$$F_{ij}(n) = e^{-\alpha_F} F_{ij}(n-1) + V_F \sum_{kl} M_{ijkl} Y_{kl}(n-1) + S_{ij}, \quad (12)$$

$$L_{ij}(n) = e^{-\alpha_L} L_{ij}(n-1) + V_L \sum_{kl} W_{ijkl} Y_{kl}(n-1), \quad (13)$$

$$U_{ij}(n) = F_{ij}(n) (1 + \beta L_{ij}(n)), \quad (14)$$

$$Y_{ij}(n) = \begin{cases} 1, & U_{ij}(n) > E_{ij}(n-1), \\ 0, & \text{其他}, \end{cases} \quad (15)$$

$$E_{ij}(n) = e^{-\alpha_E} E_{ij}(n-1) + V_E Y_{ij}(n). \quad (16)$$

β 为内部活动项的连接系数, 图像像素灰度值 S_{ij} 为神经元强制激发的外部激励, V_F 和 α_F 分别为反馈输入域中放大系数和衰减时间常数, V_L 和 α_L 分别为耦合连接域 L 的放大系数和衰减时间常数, V_E 和 α_E 分别为动态门限 E 的放大系数和衰减时间常

数, 权值矩阵 M_{ijkl} 和 W_{ijkl} 分别为反馈输入域和耦合连接域的连接矩阵.

PCNN 能使具有相似输入的神经元同时产生脉冲, 不仅能克服幅度上微小变化造成的影响, 而且能较完整地保留图像的区域信息. 所以, 对加噪图像做 PCNN 处理, 首先读取噪声图像, 对其像素矩阵并行逐遍扫描运算, 通过连接矩阵、加权系数等关系式计算出, 每个像素的内部活动项为 $U_{ij}(n)$, 当 $U_{ij}(n)$ 大于动态门限 $E_{ij}(n)$ 时, PCNN 产生时序脉冲系列 $Y_{ij}(n)$ (标记矩阵中的值为 1). 每遍扫描结束后, 求得 $Y_{ij}(n)$ 的信息熵, 经过若干次扫描运算后, 对应的输出为熵序列 En , PCNN 对噪声图像作处理, 所有的操作只针对受噪声污染的像素点, 其他的像素点不受影响, 能够较完整地保留图像区域的信息, 故将熵序列 En 作为另一个检测算子与图像梯度 ∇I 共同进行边缘检测, 则扩散系数改进如下:

$$g(\nabla I, En) = \frac{1}{1 + |G_\sigma * \nabla I + En| \cdot k}. \quad (17)$$

建立的 PCNN-IEAD 模型如下:

$$\frac{\partial I}{\partial t} = \text{div}(g(\nabla I, En) \nabla I),$$

$$I(x, y, 0) = I_0, \quad (18)$$

式中, div , ∇ 分别为散度算子和梯度算子, En 为熵序列, $G_\sigma(x, y, t) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right)$ 是高斯核函数, 通常随着 t 的增加而减小, σ 为尺度函数. k 为阈值, 可以进一步控制整个扩散过程中的扩散强度, 通常情况下, 阈值 k 为常数, 交叉熵用于度量两个概率分布之间信息量的差异, 是一个下凸函数, 本文将最小交叉熵准则应用于阈值设计中, 搜索使去噪前后图像信息量差异最小的阈值.

已知有两个概率分布 $P = \{p_1, p_2, \dots, p_N\}$ 和 $Q = \{q_1, q_2, \dots, q_N\}$, 若用交叉熵度量它们之间的信息量差异, 则其对称形式为

$$D(P : Q) = \sum_{i=1}^N p_i \times \ln \frac{p_i}{q_i} + \sum_{i=1}^N q_i \times \ln \frac{q_i}{p_i}. \quad (19)$$

为了计算扩散去噪阈值 k , 用 P 和 Q 分别表示噪声图像和去噪后图像, 然后计算目标之间的交叉熵、背景之间的交叉熵, 把它们之和定义为噪声图像和去噪后图像之间的交叉熵:

$$D(P, Q : k)$$

$$= \sum_{f=0}^k \left[f \times h(f) \times \ln \frac{f}{\mu_1(k)} + \mu_1(k) \times h(f) \times \ln \frac{\mu_1(k)}{f} \right] + \sum_{f=k+1}^z \left[f \times h(f) \times \ln \frac{f}{\mu_2(k)} + \mu_2(k) \times h(f) \times \ln \frac{\mu_2(k)}{f} \right], \quad (20)$$

$$\mu_1(k) = \frac{1}{\sum_{f=0}^k h(f)} \sum_{f=0}^k f \times h(f), \quad (21)$$

$$\mu_2(k) = \frac{1}{\sum_{f=k+1}^z h(f)} \sum_{f=k+1}^z f \times h(f). \quad (22)$$

(20) 式中, f 是图像灰度值; $h(f)$ 是图像的灰度统计直方图, z 是灰度上界, k 是假定的阈值, $\mu_1(k)$ 和 $\mu_2(k)$ 是类内均值, 分别代表在该阈值下, 目标和背景的平均灰度. 在计算中, 用 z 对 (20) 式进行归一化处理, (20) 式是基于某一阈值 k 的噪声图像和去噪后图像之间的信息量差异度量结果, 在图像灰度范围内搜索 k 值, 而能使 (20) 式值最小的 k 即为最佳去噪阈值.

基于脉冲耦合神经网络和图像熵改进的各向异性扩散滤波的步骤如下:

步骤一 采用 PCNN 模型对加噪图像作处理计算边缘检测算子 En .

步骤二 进行阈值寻优并进行处理, 计算最佳去噪阈值 k ;

a) 初始化阈值 $k(n+1) = e^{-t}k(n)$, $k = \text{round}(k)$, $\text{round}(\cdot)$ 为取整运算, t 为阈值衰减时间, 设为 0.1, n 为迭代次数;

b) 按 (21) 式和 (22) 式分别计算目标的平均灰度和背景的平均灰度;

c) 计算目标交叉熵

$$D_1 = \sum_{f=0}^k \left[f \times h(f) \times \ln \frac{f}{\mu_1(k)} + \mu_1(k) \times h(f) \times \ln \frac{\mu_1(k)}{f} \right]$$

和背景交叉熵

$$D_2 = \sum_{f=k+1}^z \left[f \times h(f) \times \ln \frac{f}{\mu_2(k)} + \mu_2(k) \times h(f) \times \ln \frac{\mu_2(k)}{f} \right];$$

d) 将步骤 c) 中的 D_1 和 D_2 代入 (20) 式中得到整幅图的交叉熵, 即 $D(P, Q : k) = D_1 + D_2$;

e) 计算最小交叉熵 $D_{\min} = \min(D(P, Q : k))$, $\min(\cdot)$ 为取最小值运算, 此时将 D_{\min} 对应的迭代次数代入到步骤 a) 中, 得到最佳阈值 k .

步骤三 按照上面两个步骤计算出的边缘检测算子 En 和最佳去噪阈值 k , 由 PCNN-IEAD 模型 (18) 进行处理, 得到去噪后的图像.

用加性算子分裂算法 (AOS 算法)^[25] 解 PCNN-IEAD 模型 (18), 其简化过程如下.

当用一维矩阵向量表示法表示时, 其迭代方案如下:

$$I^{n+1} = [I - 2\Delta t A(I^n)]^{-1} I^n, \quad (23)$$

其中, Δt 是时间步长, $A(I^n) = [a_{ij}(I^n)]$, 且

$$a_{ij}(I^n) = \begin{cases} \frac{\gamma_i^n + \gamma_j^n}{2h^2}, & j \in N_i, \\ -\sum_{k \in N_i} \frac{\gamma_i^n + \gamma_k^n}{2h^2}, & j = i, \\ 0, & \text{其他}, \end{cases} \quad (24)$$

式中, $\gamma_i = g_i(\nabla I, En)$, N_i 是自然数集, h 是离散化步长. 以此类推, 当用 n 维矩阵向量表示法表示时, 其迭代方案如下:

$$I^{n+1} = \left[I - 2\Delta t \sum_{l=1}^n A_l(I^n) \right]^{-1} I^n, \quad (25)$$

式中, 矩阵 $A_l = (a_{ijl})_{ij}$ 对应 l 方向的坐标轴.

1) 当 $i = 1, \dots, N$ 时, 计算 $(I - 2\Delta t A_{x,i}^n)$ 三个对角线上的元素: $(\alpha_k^{(i)}, k = 1, \dots, N)$, $(\beta_k^{(i)}, k = 1, \dots, N-1)$, $(\gamma_k^{(i)}, k = 2, \dots, N)$ 并采用追赶法求解 $(I - 2\Delta t A_{x,i}^n)I_{1i}^{n+1} = I_{1i}^n$, 得到 I_{1i}^{n+1} .

2) 当 $j = 1, \dots, M$ 时, 同样计算 $(I - 2\Delta t A_{y,j}^n)$ 的三个对角线上的元素, 并采用追赶法求解 $(I - 2\Delta t A_{y,j}^n)I_{2j}^{n+1} = I_{2j}^n$, 得到 I_{2j}^{n+1} .

3) 最后计算 $I^{n+1} = \frac{1}{2}(I_{1i}^{n+1} + I_{2j}^{n+1})$, 这样便完成了一次迭代, 如此按照如上过程计算, 便可得到较理想的图像.

4 实验结果与分析

为了比较不同模型的去噪效果, 以均方差 (MSE)、峰值信噪比 (PSNR) 和清晰度 (Definition)

作为质量评价指标, 它们的定义为

$$MSE = \frac{\sum_{i=1}^W \sum_{j=1}^H [\hat{I}(i, j) - \hat{I}_0(i, j)]^2}{W \times H}, \quad (26)$$

$$PSNR = 10 \log_{10} \left(\frac{255^2}{MSE} \right), \quad (27)$$

$$\begin{aligned} \text{Definition} = & \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H [(\hat{I}(i, j) \\ & - \hat{I}(i-1, j))^2 \\ & + (\hat{I}(i, j) - \hat{I}(i, j-1))^2]^{1/2}. \quad (28) \end{aligned}$$

图像的分辨率为 $W \times H$, 用于加噪图像时, \hat{I} 为加噪图像, 用于各模型处理后图像时, \hat{I} 为各模型处理后图像, \hat{I}_0 均为原图像, 即 \hat{I} 和 \hat{I}_0 是用于比较的两幅图像, $\hat{I}(i, j) - \hat{I}(i-1, j)$ 与 $\hat{I}(i, j) - \hat{I}(i, j-1)$ 分别为 \hat{I} 沿 x 和 y 方向的差分, 均方差 (MSE) 越小越好, 峰值信噪比 (PSNR) 越大越好, 清晰度 (Definition) 反映图像的细节反差和纹理特征, 其值越大越好.

分别对自然图像 Barbara (600×600) 和真实的图 Buddha (600×600) 加方差为 20 的加性高斯随机噪声进行实验, 如图 2 所示. 并与代表性

的正则化 PM 模型、ROF 模型和 IEAD 模型进行比较. 首先对图像 Barbara, 分别使用 PM 模型、ROF 模型、IEAD 模型和 PCNN-IEAD 模型进行平滑. 其中, 时间步长 (Δt) 都为 5, 迭代次数都为 7, PM 模型的扩散系数取 (2) 式, 阈值取 10; ROF 模型的 λ 取 0.02; IEAD 模型中窗口大小为 5×5 ; PCNN-IEAD 模型中, $\alpha_L = 1.0$, $\alpha_E = 1.0$, $\alpha_F = 0.1$, $V_F = 0.5$, $V_L = 0.2$, $V_E = 20$, $\beta = 0.1$, $\mathbf{W} = [0.5 \ 1 \ 0.5; 1 \ 0 \ 1; 0.5 \ 1 \ 0.5]$, $\mathbf{M} = \mathbf{W}$, $F = Y$, $L = Y$, $U = Y$, $E = Y$. 平滑结果如图 3 所示, 评价指标如表 1 所示, 图 4 是 Barbara 图像局部放大效果. 为了更好的显示滤波前后图像边缘纹理等细节信息情况, 采用 Canny 算子 [26] 对各种模型滤波结果进行边缘检测, 结果如图 5 所示.

现对真实图像 Buddha 进行 4 种模型的滤波实验, 进一步观察各模型对图像的处理效果. 参数设置与 Barbara 图像的参数设置相同, 滤波结果如图 6 所示, 评价指标如表 1 所示, 为了更好的显示各模型的滤波效果, 对图像的脸部进行局部放大, 如图 7 所示, 图 8 是采用 Canny 算子对各种模型滤波结果进行边缘检测的结果图.

表 1 各图像使用不同去噪模型的 MSE, PSNR 和 Definition 比较
Table 1. MSE, PSNR and Definition of each image for different model.

		加噪图像	PM 模型	ROF 模型	IEAD 模型	PCNN-IEAD 模型
Barbara	MSE	396.8103	74.7408	29.0986	112.9350	3.0556e-05
	PSNR	22.1450	29.3952	33.4921	27.6025	93.2799
	Definition	2.3802	87.6246	106.2456	76.7356	132.2020
Buddha	MSE	352.4852	62.8808	28.6591	94.6936	8.3333e-06
	PSNR	22.6594	30.1456	33.5582	28.3676	98.9226
	Definition	2.3129	84.1590	102.2251	74.8052	132.3889




图 2 用于数值实验的加噪图像 (a) Barbara 图像; (b) Buddha 图像

Fig. 2. Noisy image used in numerical experiment: (a) Barbara image; (b) Buddha image.



图3 Barbara 图像各模型平滑后图像 (a) PM 模型; (b) ROF 模型; (c) IEAD 模型; (d) PCNN-IEAD 模型
Fig. 3. Smoothed image of Barbara for each model: (a) PM model; (b) ROF model; (c) IEAD model; (d) PCNN-IEAD model.




图4 Barbra 图像各模型平滑后局部放大 (a) PM 模型; (b) ROF 模型; (c) IEAD 模型; (d) PCNN-IEAD 模型
Fig. 4. Local amplification of smoothed image Barbara for each model: (a) PM model; (b) ROF model; (c) IEAD model; (d) PCNN-IEAD model.




图5 Barbara 图像各模型平滑后边缘提取图像 (a) PM 模型; (b) ROF 模型; (c) IEAD 模型; (d) PCNN-IEAD 模型
Fig. 5. Edge extraction of smoothed Image Barbara for each model: (a) PM model; (b) ROF model; (c) IEAD model; (d) PCNN-IEAD model.




图6 Buddha 图像各模型平滑后图像 (a) PM 模型; (b) ROF 模型; (c) IEAD 模型; (d) PCNN-IEAD 模型
Fig. 6. Smoothed image of Buddha for each model: (a) PM model; (b) ROF model; (c) IEAD model; (d) PCNN-IEAD model.




图7 Buddha 图像各模型平滑后局部放大 (a) PM 模型; (b) ROF 模型; (c) IEAD 模型; (d) PCNN-IEAD 模型
Fig. 7. Local amplification of smoothed image Buddha for each model: (a) PM model; (b) ROF model; (c) IEAD model; (d) PCNN-IEAD model.




图8 Buddha 图像各模型平滑后边缘提取图像 (a) PM 模型; (b) ROF 模型; (c) IEAD 模型; (d) PCNN-IEAD 模型
Fig. 8. Edge extraction of smoothed image Buddha for each model: (a) PM model; (b) ROF model; (c) IEAD model; (d) PCNN-IEAD model.

从图 3(a), (b) 的整体可视效果和图 4(a), (b) 的局部放大可视效果来看, PM 模型和 ROF 模型都具有一定的平滑效果, 但是图像较模糊, 从图 5(a), (b) 可以更清楚地看到角点、尖峰、窄边缘和纹理等细节信息被平滑掉了, 这是因为 PM 模型和 ROF 模型都是用梯度作为边缘检测算子来进行边缘检测的, 容易受到噪声的影响, 所以使得图像细节被磨光. 如图 3(c)、图 6(c) 和图 4(c)、图 7(c) 所示, IEAD 模型是针对乘性噪声设计的, 对于加性噪声效果一般, 甚至会起到反作用, 虽然 IEAD 模型将图像熵作为边缘检测算子可以克服在不同灰度值水平的同质区域内相同的噪声起伏却得到梯度值差异较大的缺点, 能更好地反映图像的灰度值变化, 但是在强噪声的情况下, 仍不能较完整的保留图像区域的信息, 如图 5(c), 图 8(c) 所示, Barbara 的头巾、裤子和桌布上和 Buddha 图像中石碑、树木等丢失了很多细节信息. PCNN-IEAD 模型充分利用了 PCNN 和图像熵的性质, 较完整的保留了图像区域的细节信息, 能够克服边缘检测算子易受噪声影响的弊端, 稳定地控制扩散强度, 由图 4(d), 图 7(d) 和图 5(d), 图 8(d) 可知 PCNN-IEAD 模型处理后的图像可视效果最好, 边缘纹理也保持的非常好. 从表 1 的评价指标可以看出, PCNN-IEAD 模型 MSE 最小, PSNR 和 Definition 最高, 与滤波结果的可视性相一致.

此外, 为进一步检测 PCNN-IEAD 模型的性能, 用不同方差的噪声进行实验, 观察各模型处理后的图像清晰度的变化. 由图 9 可知, 随着噪声方差的增大, PCNN-IEAD 模型处理后的图像清晰度也一直增大, 并且在所有模型中 PCNN-IEAD 模型的清晰度最高, 说明 PCNN-IEAD 模型处理后图像的细节反差和纹理特征保持的最好, 较完整的保留了图像区域的信息, 主要原因有: PCNN 能使得具有相似输入的神经元同时产生脉冲, 不仅能克服幅度上微小变化造成的影响, 而且能较完整地保留图像的区域信息; 使用图像熵作为边缘检测算子, 克服了仅用梯度作为边缘检测算子的弊端, 提高了边缘检测能力; 采用最小交叉熵设计最佳阈值, 控制扩散强度, 能够有效地去除图像的噪声和保护图像的边缘纹理等细节信息.

另外, 从图 10 可以看到, PCNN-IEAD 模型的运行时间虽然较经典的 PM 模型和 ROF 模型的运行时间慢, 但是较 IEAD 模型的运行时间快, 一方

面是由于该模型充分利用 PCNN 算法计算图像熵序列, 所有的操作只针对受噪声污染的像素点, 其他的像素点不作处理, 大大减少了运行时间, 另一方面是由于本文所提模型是采用 AOS 算法进行数值化分解, 并用追赶法进行求解, 进一步减少了运行时间.

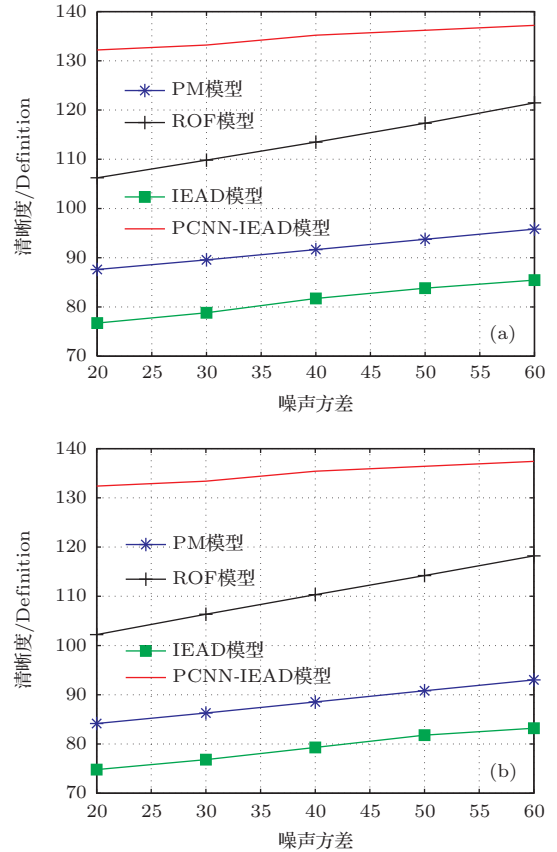


图 9 各模型不同方差下的清晰度 (a) Barbara 图像清晰度; (b) Buddha 图像清晰度
Fig. 9. Definition of each model under different variance: (a) definition of Barbara image; (b) definition of Buddha image.

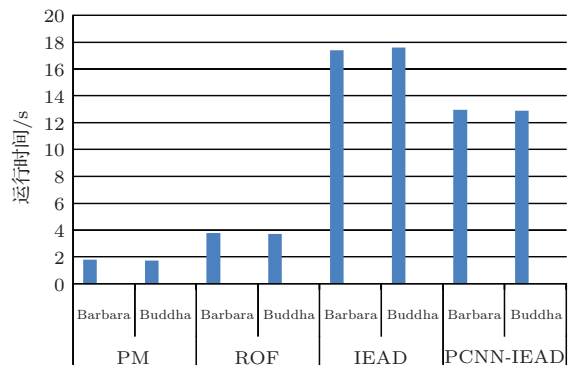


图 10 各模型平滑图像的运行时间
Fig. 10. Operation time of image smoothing for each model.

5 结 论

基于偏微分方程的图像去噪扩散强度通常使用梯度信息检测边缘,但当边缘部分被噪声严重污染时,这些方法不能有效检测出这些边缘,因而无法保留边缘包含的特征.本文模型首先用PCNN对图像做处理,得到图像熵序列,并将图像熵序列引入到扩散模型中,然后采用最小交叉熵准则设计最佳阈值,进一步控制扩散强度.提出的模型不但能有效的抑制噪声,而且能够稳定地保护图像的边缘纹理等细节信息,能够较完整的保留图像的区域信息,去噪后的图像信噪比相对于PM模型提高了65 dB左右,相对于ROF模型提高了60 dB左右,相对于IEAD模型提高了70 dB左右,清晰度也大幅度提升.实验结果表明,PCNN-IEAD模型去噪性能的优越性.

参考文献

- [1] Zhang W, Li J J, Yang Y P 2014 *Signal Process* **103** 6
- [2] Chumchob N 2013 *IEEE Trans. Image Process* **22** 4551
- [3] Wu T T, Yang Y F, Pang Z F 2012 *Appl. Numer. Math.* **62** 79
- [4] Wu J, Tang C 2011 *IEEE Trans. Image Process* **20** 2428
- [5] Brito-Loeza C, Chen K 2010 *IEEE Trans. Image Process* **19** 1518
- [6] Wang Z, Huang X, Li Y X, Song X N 2013 *Chin. Phys. B* **22** 010504
- [7] Perona P, Malik J 1990 *IEEE Trans. Pattern Anal. Mach. Intell.* **12** 629
- [8] Rudin L I, Osher S, Fatemi E 1992 *Physica D* **60** 259
- [9] Cheng L Y, Tang C, Yan S 2011 *Optics Communications* **284** 5549
- [10] Liu P, Fang H, Li G Q, Liu Z W 2012 *IEEE Geosci. Remote Sens.* **9** 358
- [11] Niang O, Thioune A, Gueire M C 2012 *IEEE Trans. Image Process* **21** 3991
- [12] Bumsab H, Dongbo M, Kwanghoon So 2013 *IEEE Trans. Image Process* **22** 1096
- [13] Zhou X C, Wang M L, Zhou L F, Wu Q 2015 *Acta Phys. Sin.* **64** 024205 (in Chinese) [周先春, 汪美玲, 周林峰, 吴琴 2015 物理学报 **64** 024205]
- [14] Zhou X C, Shi L F, Han X L, Mo J Q 2014 *Chin. Phys. B* **23** 090204
- [15] Zhou X C, Shi L F, Mo J Q 2014 *Chin. Phys. B* **23** 040202
- [16] Zhang Y H, Ding Y, Wang L H 2011 *Procedia Engineering* **15** 2778
- [17] Li J C, Ma Z H, Peng Y X, Huang B 2013 *Acta Phys. Sin.* **62** 099501 (in Chinese) [李金才, 马自辉, 彭宇行, 黄斌 2013 物理学报 **62** 099501]
- [18] Zhang K K, Gao X B, Li X L 2012 *IEEE Trans. Image Process* **21** 4544
- [19] Dabov K, Foi A, Katkovnik V, Egiazarian K 2007 *IEEE Trans. Image Process* **16** 2080
- [20] Deledalle C A, Denis L, Tupin F 2009 *IEEE Trans. Image Process* **18** 2661
- [21] Nikpour M, Hassanpour H 2010 *IET Image Process* **4** 452
- [22] Kamilov, Bostan E, Unser M 2012 *IEEE Signal Process Lett.* **19** 187
- [23] Johnson J L, Padgett M L 1999 *IEEE Trans. Neural Netw.* **10** 480
- [24] Ranganath H S, Kuntimad G 1999 *IEEE Trans. Neural Netw.* **10** 615
- [25] Weickert J, Bary H R, Max A V 1998 *IEEE Trans. Image Process* **7** 398
- [26] Canny J 1986 *IEEE Trans. Pattern Anal. Mach. Intell.* **PAMI-8** 679

Study of anisotropic diffusion model based on pulse coupled neural network and image entropy*

Guo Ye-Cai[†] Zhou Lin-Feng

(Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science and Technology, Nanjing 210044, China)

(Jiangsu Collaborative Innovation Center of Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China)

(College of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

(Received 31 March 2015; revised manuscript received 11 May 2015)

Abstract

In image processing, most of the anisotropic diffusion models based on partial differential equation use gradient information to detect image edge. If the image edge is seriously polluted by noise, these methods would not be able to detect image edge, so the edge features cannot be retained. Pulse coupled neural network (PCNN) has the property that similar input neurons can generate pulse at the same time; this property is used to process the noisy image, and we can get an image entropy sequence. The image entropy sequence which will be used as an edge detecting operator is introduced into the diffusion equation, and this will not only reduce the defects produced when the gradient is used as an edge detecting operator so it is easily affected by the noise, but the area image information can also retain more completely. Then, we will use the rule of minimum cross entropy to search for a minimum threshold, which would satisfy the condition that the information difference between noisy image and denoised image is the minimum. The optimal threshold designed will control diffusion intensity reasonably, and the anisotropic diffusion model based on pulse coupled neural network and image entropy (PCNN-IEAD) can be established. Analysis and simulation results show that the proposed model preserves more image information than the classical ones. It removes the image noise and at the same time protects the edge texture details of the image; the proposed model retains the area image information more completely, the performance indexes can also confirm the superiority of the new model. In addition, the operating time of the proposed model is shorter than that of the classical models, therefore, the proposed model may be the ideal one.

Keywords: image denoising, pulse coupled neural network, image entropy, minimum cross entropy

PACS: 42.30.Wb, 02.30.Jr

DOI: [10.7498/aps.64.194204](https://doi.org/10.7498/aps.64.194204)

* Project supported by the National Natural Science Foundation of China (Grant Nos. 11202106, 61201444), the Specialized Research Fund for the Doctoral Program of Higher Education of China (Grant No. 20123228120005), the Jiangsu Information and Communication Engineering Preponderant Discipline Platform, China, the Jiangsu Key Laboratory of Meteorological Observation and Information Processing (Grant Nos. KDXS1204, KDXS1403), the Jiangsu Qing Lan Project, and the Natural Sciences Foundation from the Universities of Jiangsu Province of China (Grant No. 13KJB170016).

[†] Corresponding author. E-mail: guo-yecai@163.com