



一种结合 IGM 和改进 PCNN 的图像增强方法

张 谦, 周浦城*, 薛模根, 张 杰

偏振光成像探测技术安徽省重点实验室, 合肥 230031



摘要: 针对部分对比度低、噪声大的图像, 提出一种基于大脑内部生成机制(IGM)和改进脉冲耦合神经网络(PCNN)的图像增强方法。首先, 根据 IGM 有关理论将原始图像分解为细节子图与粗糙子图; 然后, 采用改进的 PCNN 增强方法对粗糙子图进行处理, 以提高整体对比度, 采用 PCNN 与模糊集理论结合的增强方法对细节子图进行处理, 增强边缘等细节信息并去除部分噪声; 最后, 将处理后的细节子图与粗糙子图重构, 得到最终的增强图像。实验结果表明, 该方法能够有效增强图像的对比度和纹理细节, 减少部分噪声, 较好地保留原图细节信息。

关键词: 内部生成机制; 脉冲耦合神经网络; 模糊集; 图像增强

中图分类号: TP751

文献标志码: A

Image enhancement using IGM and improved PCNN

Qian Zhang, Pucheng Zhou*, Mogen Xue and Jie Zhang

Anhui Province Key Laboratory of Polarized Imaging Detection Technology, Hefei 230031, China

Abstract: To deal with low-contrast and high-noisy natural images, an image enhancement method based on internal generative mechanism (IGM) and improved pulse coupled neural network (PCNN) is proposed. First, the original image is decomposed into rough sub-graph and detail sub-graph by the theory of IGM. And then, an improved PCNN method is adopted to make the rough sub-graph more clearly. At the same time, the enhancement method which PCNN incorporates with fuzzy sets is introduced for the detail sub-graph so as to sharpen the image edge and remove outliers. Finally, the final image is reconstructed by processed rough sub-graph and detail sub-graph. Experimental results show that the proposed algorithm can effectively enhance the image contrast and image contour, as well as filter out some noise without any loss of image edges.

Keywords: internal generative mechanism; pulse coupled neural network; fuzzy sets; image enhancement

DOI: 10.3969/j.issn.1003-501X.2017.09.005

Citation: *Opto-Elec Eng*, 2017, 44(9): 888-894

1 引言

图像增强是改善图像质量或视觉效果的重要手段。传统的空域增强方法, 如直方图均衡化方法^[1]会导致图像边缘模糊, 频域增强方法^[2]容易破坏图像信息的完整性。近十几年以来, 许多新的图像增强算法不断

涌现, 其中, 基于小波变换和多尺度几何分析^[3-5]的增强方法能够更好地分析图像特征、弱化噪声; 基于 Retinex 理论^[6]的增强方法可以消除光照不均匀带来的影响, 但是对于整体灰度值偏暗、细微结构模糊的图像处理效果一般。

近年来, 脉冲耦合神经网络(pulse coupled neural network, PCNN)作为一种新兴的图像增强方法受到广泛关注。Johnson 等^[7]首次将 PCNN 应用到图像增强上, 取得较好的增强效果, 但许多参数依赖人为设定;

收稿日期: 2017-05-04; 收到修改稿日期: 2017-07-20

*E-mail: zhoupc@hit.edu.cn

Xu 等^[8]使用 PCNN-FM 实现了参数自调节的低质量图像增强；苏娟等^[9]提出一种结合 PCNN 分割和模糊集的图像增强方法，并利用 Retinex 理论对 PCNN 分割区域的反射图像进行自适应模糊增强。虽然 PCNN 增强方法对细节信息和噪声处理效果较好，但是在图像对比度低以及目标轮廓较为模糊时，已有算法在增强目标对比度的同时，也放大了目标轮廓中的噪声，甚至在某些区域无法自主点火导致增强失败。针对上述不足，本文提出一种基于大脑内部生成机制(internal generative mechanism, IGM)和改进 PCNN 的图像增强方法。

2 基于 IGM 的图像分解

根据 IGM^[10]理论，当大脑受到场景刺激时，会结合固有的先验知识，将场景信息优化为预测的基本信息和残留的不确定信息。Wu 等^[11]在此理论基础上，结合自回归贝叶斯预测模型，将图像分解为粗糙和细节部分。若用 X 表示一幅图像， x_{ij} 为像素 (i, j) 处的灰度值， W_{ij} 为 x_{ij} 的相邻像素的集合，把中心像素 x_{ij} 与其周围像素 x_{mn} 的互信息 $I(x_{ij}; x_{mn})$ 作为自回归系数，自回归模型 x_{ij} 的预测值为

$$x'_{ij} = \sum_{x_{mn} \in W_{ij}} C_{mn} x_{mn} + \varepsilon, \quad (1)$$

式中： ε 为高斯白噪声， C_{mn} 为 x_{ij} 的权重，即

$$C_{mn} = \frac{I(x_{ij}; x_{mn})}{\sum_{x_{mn} \in W_{ij}} I(x_{ij}; x_{mn})}. \quad (2)$$

由 IGM 理论可知，预测值 x'_{ij} 代表图像的基本视觉信息，用粗糙子图 V 表示，其不确定信息代表图像的细节，用细节子图 U 表示，即

$$U = X - V. \quad (3)$$

图像重构过程为

$$X = U + V. \quad (4)$$

图 1 为基于 IGM 理论进行图像分解的实例。图 1(a)

是原始图像，对比度较低，整体较为模糊；图 1(b)是粗糙子图，保留了原始图像中的基本视觉信息，但整体对比度偏低，并且边缘等细节部分缺失明显；图 1(c)是细节子图，包含了原始图像中的边缘、纹理等细节信息，但是细节信息较为模糊，并且含有部分噪声。

3 基于改进 PCNN 的图像增强算法

根据基于 IGM 理论的图像分解结果，为了拉伸粗糙子图的对比度，强化细节子图的纹理细节，改善原始图像的视觉效果，本文采用改进的 PCNN 增强算法，分别对粗糙子图和细节子图进行处理。

3.1 粗糙子图增强

PCNN 用于图像增强的基本思想为，每个像素对应 PCNN 的一个神经元，当像素间灰度差值过小时，更加激励它们同步点火，使之灰度反差更小，从而平滑图像；反之则能增强边缘，突出图像的特征信息。由于粗糙子图 V 包含原图的基本信息，且其整体较为模糊，灰度分布较为集中，传统的 PCNN 增强效果并不明显，较难对每个像素的灰度值有较好的修正。

为了对像素间的点火状态进行调整来拉伸图像整体的对比度，本文采用改进的 PCNN 增强方程：

$$v'_{ij} = v_{ij}^p + \Delta v_{ij}, \quad (5)$$

式中： v'_{ij} 为增强后的粗糙子图 V' 在像素 (i, j) 处的灰度值， v_{ij}^p 为 PCNN 的初始增强结果 V^p 在 (i, j) 处的灰度值， Δv_{ij} 为修正子图 ΔV 在 (i, j) 处的灰度值。

由于粗糙子图的边界模糊，较难判定边界内外，而模糊集方法不仅能较好地描述图像的不确定性，而且对噪声干扰具有较好的稳健性，所以选用模糊集方法求得 ΔV ，以便在 PCNN 的初始增强结果 V^p 基础上，对粗糙子图进行二次调整。在 Zhang 等^[12]的方法中，模糊域的输入为像素灰度值，由于低对比度、高噪声图像的灰度值过于集中，且噪声点较多，不适用于作为模糊增强的输入。根据 PCNN 工作机理，当神经元



图 1 基于内部生成机制的图像分解实例。(a) 原始图像。(b) 粗糙图像。(c) 细节子图。

Fig. 1 Examples of image decomposition by IGM. (a) Original image. (b) Rough sub-graph. (c) Detail sub-graph.

A_{ij} 被激发点火时,将产生脉冲输出 $Y_{ij}=1$, 否则输出 $Y_{ij}=0$, 该 Y_{ij} 又作为邻域神经元的链接输入而影响其他神经元的点火状态。链接信号 l_{ij} L 是链接矩阵 L 中位于 (i, j) 处的元素值, 它不仅影响自身和邻域神经元的点火状态, 而且每个神经元接收到的链接信号 l_{ij} 都各不相同, 特别是噪声点处的链接信号 l_{ij} 相对较小, 因此选择链接信号 l_{ij} 代替像素灰度值作为模糊增强的输入。

利用模糊隶属度函数将各链接信号 l_{ij} 从空间域变换到模糊域, 得到模糊特征 $\{\mu\}$:

$$\mu_{ij} = F(l_{ij}) = \begin{cases} \frac{l_{ij}}{2l_1}, & l_{ij} \leq l_1 \\ 1 - \frac{l_2 - l_{ij}}{2(l_2 - l_1)}, & l_1 < l_{ij} \leq l_2 \\ \frac{l_{\max} - l_{ij}}{l_{\max} - l_2}, & l_{ij} > l_2 \end{cases} \quad (6)$$

式中: l_1 和 l_2 分别为链接阈值, l_{\max} 为链接矩阵 L 中的最大元素值。若链接矩阵 L 中的元素均值为 l_M , l_1 取为 $l_M/10$, 链接信号小于 l_1 的神经元认为是被抑制点火, l_2 取为 l_M , 表示自然点火和捕获火的分界值。

在PCNN用于图像增强的过程中, 每个像素的点火状态可区分为三种: 抑制点火、自然点火及捕获点火。由于 l_{ij} 直接反映了其邻域神经元对 A_{ij} 的影响, 为此结合链接阈值 l_1 和 l_2 , 精确划分三种点火状态: 当 $l_{ij} < l_1$ 时, 认为该神经元 A_{ij} 为被抑制点火的噪声点, 通过模糊增强算子的递归调用, 可以进一步压缩噪声点的灰度动态范围, 使其与其他有用信息的灰度差增大, 以此达到降低噪声的目的; 当 $l_1 < l_{ij} < l_2$ 时, 认为 A_{ij} 被自然点火; 当 $l_{ij} > l_2$ 时, 认为 A_{ij} 被捕获点火。

利用模糊增强算子的递归调用来修正模糊隶属度, 调整神经元间的链接信号, 进而拉伸像素间的灰度差, 改善粗糙子图的对比度, 获得的新模糊特征 $\{\mu'\}$ 为

$$T_1(\mu_{ij}) = \begin{cases} \frac{\mu_{ij}^2}{2\mu_{c1}}, & 0 \leq \mu_{ij} \leq \mu_{c1} \\ \mu_{c2} - \frac{(\mu_{c2} - \mu_{ij})^2}{2(\mu_{c2} - \mu_{c1})}, & \mu_{c1} < \mu_{ij} \leq \mu_{c2} \\ 1 - \frac{(1 - \mu_{ij})^2}{2(1 - \mu_{c2})}, & \mu_{c2} < \mu_{ij} \leq 1 \end{cases} \quad (7)$$

$$\mu'_{ij} = T_r(\mu_{ij}) = T_1[T_{r-1}(\mu_{ij})], \quad (8)$$

式中: μ_{c1} 和 μ_{c2} 分别为隶属度阈值, 取 $\mu_{c1}=F(l_1)=0.5$, $\mu_{c2}=F(l_2)=1$, $T_0(\mu_{ij})=\mu_{ij}$, $T_r(\cdot)$ 为 $T_1(\cdot)$ 的 r 次迭代运算。实验发现, 迭代次数 r 越大, 图像清晰度和边缘等细

节信息随之提高, 但 r 过大时, 增强效果不再明显改善。为了自适应确定最佳迭代次数 r , 采用 Li 等^[13]提出的一种综合衡量图像清晰度和纹理细节信息的无参考图像质量评价方法 GREE, 首先统计迭代前后两幅增强粗糙子图的 GREE 值并做差分运算, 若差值小于阈值 ε_r (ε_r 取 0.01), 则迭代终止。

模糊特征 $\{\mu'\}$ 进行逆变换, 将链接矩阵 L 从模糊域内变换回空间域, 逆变换函数为

$$l'_{ij} = \begin{cases} 2l_1\mu'_{ij}, & l_{ij} \leq l_1 \\ l_2 - 2(l_2 - l_1)(1 - \mu'_{ij}), & l_1 < l_{ij} \leq l_2 \\ l_{\max} - (l_{\max} - l_2)\mu'_{ij}, & l_{ij} > l_2 \end{cases} \quad (9)$$

通过式(9)得到链接矩阵 L 中每个点的链接信号值 l'_{ij} 后, 再按照式(10)计算修正子图 ΔV :

$$\Delta v_{ij} = \frac{l'_{ij}}{l_{ij}} v_{ij} + v_0, \quad (10)$$

式中: v_{ij} V 为原始粗糙子图 V 在像素 (i, j) 处的灰度值, v_0 为调整参数。

将修正子图 ΔV 中各像素点灰度值 Δv_{ij} 代入式(5), 便可得到增强后的粗糙子图 V' 。图 2(a)为原始粗糙子图, 图 2(b)为增强后的粗糙子图。原始粗糙子图的整体较为模糊, 对比度较低, 树干和树枝处的细节与背景差别很小; 增强后的粗糙子图整体对比度更高, 各处细节都有了较好的增强, 总体视觉效果更好。

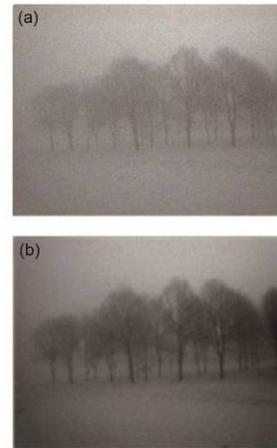


图 2 粗糙子图增强效果. (a) 原始粗糙子图. (b) 增强后的粗糙子图.

Fig. 2 Enhancement results of rough sub-graph. (a) Original rough sub-graph. (b) Enhanced rough sub-graph.

3.2 细节子图增强

细节子图 U 包含大量待增强的模糊的细节信息, 调制参数 β_{ij} B 是调制矩阵 B 中位于 (i, j) 处的元素值,

影响邻域内部周围神经元对中心神经元的点火周期，进而影响像素灰度值的大小。可以通过调整模糊细节处的 β 值来改善像素间的灰度差，以此来改善原始细节子图 U 的细节信息。

为了使每个像素点有适合自己邻域内部特征的 β_{ij} 值，需要改进 β_{ij} 值的计算方法。改进的基本思想为，低 β_{ij} 值可以拉大图像边缘的像素差值，从而强化边缘等细节信息，而高 β_{ij} 值可以缩小图像内部的像素差值，从而平滑图像。改进 β_{ij} 值的计算方法如下：

- 1) 输入：一幅原始图像 I ；
- 2) 在每个以像素 (i, j) 为中心的 3×3 邻域内，分别计算 P_1 和 Q_1 ；

$$P_1 = [I(i, j) - I(i-1, j)]^2 + [I(i, j) - I(i, j-1)]^2 + [I(i, j) - I(i, j+1)]^2 + [I(i, j) - I(i+1, j)]^2,$$

$$Q_1 = [I(i, j) - I(i-1, j-1)]^2 + [I(i, j) - I(i-1, j)]^2 + [I(i, j) - I(i-1, j+1)]^2 + [I(i, j) - I(i, j-1)]^2 + [I(i, j) - I(i, j+1)]^2 + [I(i, j) - I(i+1, j-1)]^2 + [I(i, j) - I(i+1, j)]^2 + [I(i, j) - I(i+1, j+1)]^2;$$

- 3) 令 $M_1 = Q_1/P_1$ ，若 $M_1 < I_T$ ， $\beta_{ij} = P_1$ ，转步骤 6)；若 $M_1 > I_T$ ，说明与邻域内其他像素灰度值差距过小，转步骤 4)；

- 4) 各扩展一行一列，引入变量 P_i 和 $Q_i (i=2, 3, \dots, 8)$ ，分别是在 P_1 和 Q_1 的基础上增加扩展像素的灰度值，超出图像边界的其灰度值设为 0，转步骤 5)；

- 5) 计算 $M_i = Q_i/P_i$ 并存入集合 S ；若 $M_i < I_T$ ，令 $\beta_{ij} = k_2/[k_1 \cdot \min(S)]$ ，转步骤 6)；若 $M_i > I_T$ ，则当邻域尺寸 9×9 时，令 $\beta_{ij} = k_2/[k_1 \cdot \max(S)]$ 并转步骤 6)，否则转步骤 4)；

- 6) 输出：每个像素的调制参数值 β_{ij} 。

由于原始细节子图中还含有部分被污染的噪声点，所以在增强其细节信息的同时应去除这些噪声点。判断噪声点的依据为，在以像素 (i, j) 为中心的 9×9 邻域内，若其值 β_{ij} 不满足 3σ 原则，则判断该点的链接信号 I_{ij} 是否小于 I ；若同时满足上述两个条件，则判

断为噪声点^[14]。根据 PCNN 运行机制，当某个神经元点火时，会捕获其周围神经元点火，而且只要噪声的强度与周围像素点相近，即将被捕获点火的神经元的噪声输入提升至先点火的神经元的链接输入，可消除图像的灰度差。为去除细节子图中的部分噪声点，在调制参数的计算过程中加入邻域灰度方差：

$$\beta'_{ij} = \beta_{ij} \cdot E_{ij} \cdot \exp(\alpha \times \sigma_{ij}), \quad (11)$$

式中： E_{ij} 为以像素 (i, j) 为中心的局部邻域均值， σ_{ij} 为局部邻域标准差， $\alpha < 0$ 为调节参数，用以平衡局部邻域均值和标准差在系数选择方面的重要性。

局部邻域标准差 σ 越小，说明像素邻域内灰度值分布范围越小，受噪声影响小。较小的链接输入可使邻域内的神经元点火，反之亦然。因此，处理时须使链接输入权值 a 取值稍大。因此，可根据 β'_{ij} 的值自适应地调整细节处的灰度值，从而增强纹理细节信息并去除部分噪声。增强后的细节子图 U' 为

$$u'_{ij} = u_{ij} (1 + \theta_{ij} \beta'_{ij}) + u_0, \quad (12)$$

式中： $u'_{ij} \in U'$ 为增强后的细节子图 U' 在像素 (i, j) 处的灰度值， $u_{ij} \in U$ 为原始细节子图 U 在 (i, j) 处的灰度值， u_0 为调节因子， $\theta_{ij} \in [-1, 1]$ 为像素 (i, j) 处的梯度方向一致性因子。由于原始细节子图 U 经调制参数 β' 修正后会产生梯度方向与原图不一致的现象，因此加入梯度方向一致性约束：

$$\theta_{ij} = \cos \left[\arctan \left(\frac{\nabla_x u_{ij}}{\nabla_y u_{ij}} \right) - \arctan \left(\frac{\nabla_x (\beta'_{ij} u_{ij})}{\nabla_y (\beta'_{ij} u_{ij})} \right) \right], \quad (13)$$

式中 x 和 y 分别为水平和垂直方向的一阶梯度算子。

图 3(a) 为原始细节子图，图 3(b) 为增强后的细节子图。原始细节子图中的轮廓细节信息较为模糊，特别是树干部分，并且树枝和天空部分有白色的噪声带。通过上述方法的增强处理，原始细节子图树干等细节部分的灰度值得到调整，边缘更加清晰，同时还滤除了树枝和天空区域的部分噪声，实现增强细节子图的目的。

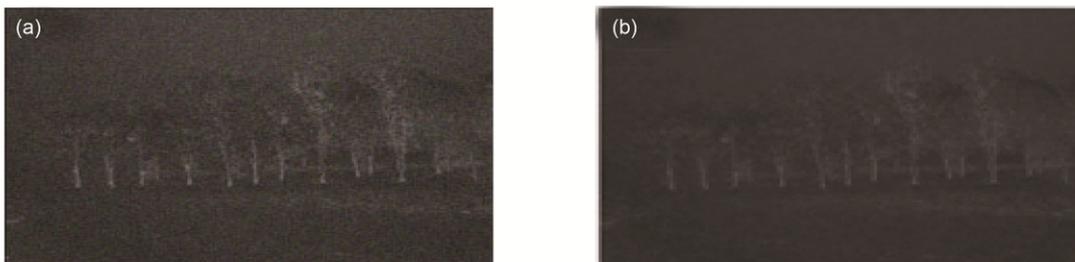


图 3 细节子图增强效果。(a) 原始细节子图。(b) 增强后的细节子图。

Fig. 3 Enhancement results of detail sub-graph. (a) Original detail sub-graph. (b) Enhanced detail sub-graph.

3.3 图像重构

将增强得到的粗糙子图 V' 与细节子图 U' 组合相加, 便可得到重构后的增强图像:

$$I' = \lambda V' + (1 - \lambda) U', \quad (14)$$

式中 $\lambda \in [0, 1]$ 为加权系数。

3.4 算法描述

综上所述, 提出的图像增强算法处理过程如下:

- 1) 利用 IGM 理论将原始图像 I 分解为原始粗糙子图 V 和原始细节子图 U ;
- 2) 经过式(6)~(10)求得原始粗糙子图 V 的修正子图 ΔV , 再经过式(5)获得增强后的粗糙子图 V' ;
- 3) 通过3.2节中的算法和式(11)求得改进的像素调制参数 β'_{ij} , 再经过式(12)求得增强后的细节子图 U' , 从而实现原始细节子图 U 的细节信息增强;
- 4) 将增强后的粗糙子图 V' 和细节子图 U' 通过式(14)进行重构, 得到最终的图像增强结果 I' 。

4 实验结果与分析

为了验证基于 IGM 和改进 PCNN 的图像增强方法的可行性和有效性, 在 Matlab 2013 软件环境中, 首先选取 3 幅图像质量较好的图像作为基准图, 并通过 Photoshop 软件对这 3 幅图像进行降质并加噪处理, 然后分别采用传统的 PCNN 增强方法^[7]、文献[8]、文献[9]以及基于 IGM 和改进 PCNN 的图像增强方法进行增强处理, 最后定性定量分析比较各种方法的增强效果。

如图 4~图 6 所示, 传统 PCNN 增强方法不能明显

增强图像的对比度和细节信息, 图像整体较为模糊, 对噪声的处理效果不佳; 文献[8]的方法尽管在对比度上有所提高, 但同时也出现过增强的现象, 丢失部分图像的细节信息, 并出现部分失真; 文献[9]的方法虽然在一定程度上增强了图像的细节, 但是不能较好地增强图像的对比度, 图像整体较为模糊; 基于 IGM 和改进 PCNN 的图像增强方法增强后图像的整体对比度有较大提高, 同时图像的纹理更加清晰, 细节信息更加丰富。通过与几种典型的 PCNN 增强方法比较, 本文提出的改进 PCNN 增强方法在提高图像整体清晰度和保持纹理细节信息等方面具有一定的优势, 并能有效滤除部分噪声, 其增强效果最为理想。

为定量分析不同方法的增强效果, 采用图像的 DV/BV ^[15]、SSIM^[16]、信息熵、信噪比 SNR、边缘保持度 EPI^[17] 进行比较。其中, DV/BV 为图像的细节方差和背景方差的比值, 其值越大说明图像整体对比度越高; SSIM 用于衡量图像间的结构相似度, 其值越高则失真度越小, 增强效果越好; 信息熵反映图像整体信息量的大小, 信息熵越大则图像细节信息越丰富; SNR 衡量图像的去噪程度和清晰度, 其值越大, 去噪程度和清晰度越好; 边缘保持度 EPI 表征图像的边缘完整性, 其值越大, 图像边缘越完整。对四种方法的增强图像进行定量评价, 结果如表 1 所示。可以看出, 与传统 PCNN 增强、文献[8]及文献[9]的改进 PCNN 增强方法相比较, 本文所提的基于 IGM 和改进 PCNN 的图像增强方法的五项参数都有较好的提高, 结合增强图像的视觉效果, 说明本文方法的增强效果更佳。

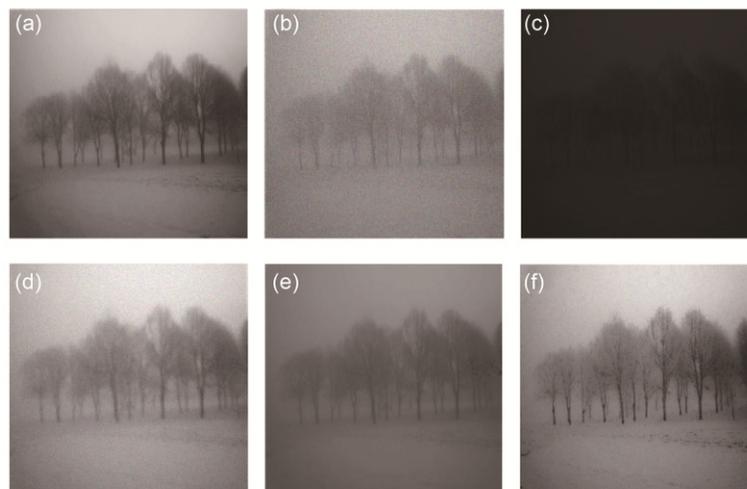


图 4 实验结果一。(a) 树。(b) 降质图像。(c) 传统 PCNN。(d) 参考文献[8]。(e) 参考文献[9]。(f) 本文。

Fig. 4 The first experimental results. (a) Tree. (b) Degraded image. (c) Original PCNN. (d) Ref. [8]. (e) Ref. [9]. (f) This paper.

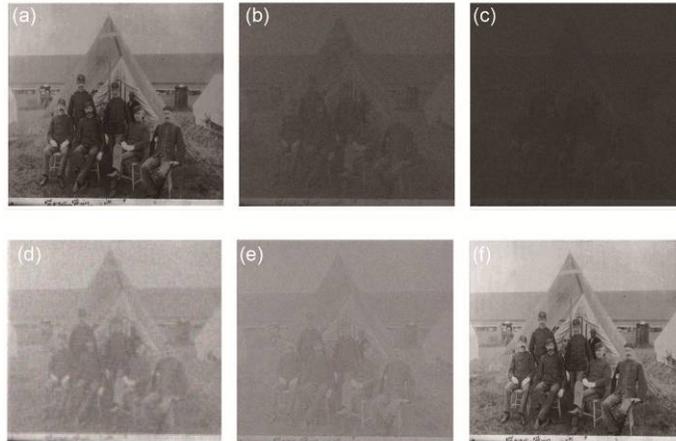


图 5 实验结果二. (a) 人. (b) 降质图像. (c) 传统 PCNN. (d) 参考文献[8]. (e) 参考文献[9]. (f) 本文.
Fig. 5 The second experimental results. (a) People. (b) Degraded image. (c) Original PCNN. (d) Ref. [8]. (e) Ref. [9]. (f) This paper.

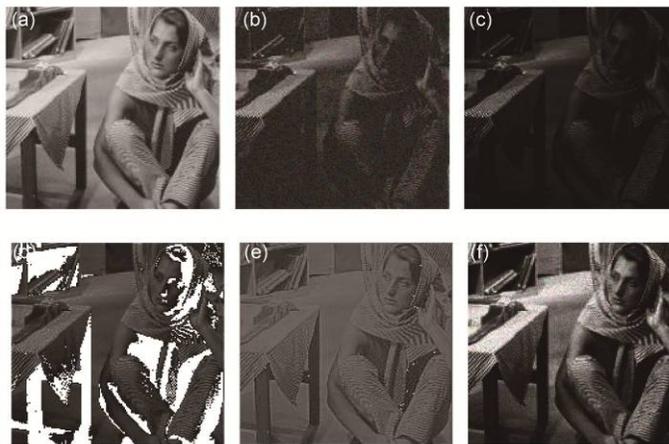


图 6 实验结果三. (a) Barbara. (b) 降质图像. (c) 传统 PCNN. (d) 参考文献[8]. (e) 参考文献[9]. (f) 本文.
Fig. 6 The third experimental results. (a) Barbara. (b) Degraded image. (c) Original PCNN. (d) Ref. [8]. (e) Ref. [9]. (f) This paper.

为了直观分析不同算法的计算复杂度,统计了上述四种 PCNN 增强方法的运行时间。传统 PCNN 增强的平均运行时间 3.49 s,文献[8]为 10.46 s,文献[9]为 11.41 s,本文所提的基于 IGM 和改进 PCNN 的图像增

强方法为 7.97 s。尽管与传统 PCNN 增强方法相比,本文方法在提高图像质量的同时增加了部分计算量,但是与文献[8]和[9]相比本文方法在运行效率方面仍然略胜一筹。

表1 不同增强方法的定量评价结果.

Table 1 Performance comparison of different enhancement methods.

图像	参数	原始图像	降质图像	传统 PCNN ^[7]	文献[8]	文献[9]	本文算法
Tree	DV/BV	13.145	8.381	3.520	9.342	7.551	11.681
	SSIM	1	0.621	0.506	0.719	0.632	0.769
	信息熵	5.119	4.012	3.461	4.334	4.260	4.819
	SNR	21.688	12.428	13.825	17.643	16.267	18.764
	EPI	1	0.671	0.701	0.742	0.713	0.817

续表 1

图像	参数	原始图像	降质图像	传统 PCNN ^[7]	文献[8]	文献[9]	本文算法
People	DV/BV	8.492	4.113	2.583	5.219	4.763	8.313
	SSIM	1	0.617	0.592	0.716	0.691	0.812
	信息熵	5.337	4.405	3.933	4.863	4.361	5.105
	SNR	22.183	14.064	13.651	17.971	16.539	21.001
	EPI	1	0.611	0.653	0.732	0.709	0.841
Barbara	DV/BV	9.328	5.194	4.360	6.256	7.633	9.194
	SSIM	1	0.602	0.551	0.468	0.632	0.627
	信息熵	5.629	3.370	4.338	4.459	5.012	5.410
	SNR	19.865	11.306	14.467	10.465	15.871	16.306
	EPI	1	0.642	0.659	0.583	0.816	0.831

5 结论

针对噪声大、灰度对比度低的图像,提出一种基于 IGM 和改进 PCNN 的图像增强方法。首先,基于 IGM 理论将原始图像分解为粗糙子图和细节子图;然后,对于细节子图利用改进的 PCNN 模型来增强其细节,对于粗糙子图采用 PCNN 与模糊集结合的方法进行增强以提高整体对比度;最后,将增强后的粗糙子图和细节子图进行重构得到最终的增强图像。该方法不仅改善了图像的对比度和细节信息,而且减少和抑制了部分噪声。但是,去除噪声点和保持纹理细节二者有所矛盾,如何在去除噪声的同时最大程度地保持图像纹理细节是下一步需要重点研究的课题。

基金项目

国家自然科学基金资助项目(61379105)。

参考文献

- Magudeeswaran V, Ravichandran C G, Thirumurugan P. Brightness preserving bi-level fuzzy histogram equalization for MRI brain image contrast enhancement[J]. *International Journal of Imaging Systems and Technology*, 2017, **27**(2): 153–161.
- Xu F Y, Zeng D G, Zhang J, et al. Detail enhancement of blurred infrared images based on frequency extrapolation[J]. *Infrared Physics and Technology*, 2016, **76**: 560–568.
- Wu Yanyan, Wang Yajie, Shi Xiangbin, et al. Color night vision method combing NSST with color contrast enhancement[J]. *Opto-Electronic Engineering*, 2016, **43**(11): 88–94.
吴燕燕, 王亚杰, 石祥滨, 等. 结合 NSST 和颜色对比度增强的彩色夜视方法[J]. *光电工程*, 2016, **43**(11): 88–94.
- Kaur A, Singh C. Contrast enhancement for cephalometric images using wavelet-based modified adaptive histogram equalization[J]. *Applied Soft Computing*, 2017, **51**: 180–191.
- Bai T B, Zhang L B, Duan L X, et al. NSCT-based infrared image enhancement method for rotating machinery fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2016, **65**(10): 2293–2301.
- Wang Y F, Wang H Y, Yin C L, et al. Biologically inspired image enhancement based on Retinex[J]. *Neurocomputing*, 2016, **177**: 373–384.
- Johnson J L, Ritter D. Observation of periodic waves in a pulse-coupled neural network[J]. *Optics Letters*, 1993, **18**(15): 1253–1255.
- Xu G Z, Li C L, Zhao J J, et al. Multiplicative decomposition based image contrast enhancement method using PCNN factoring model[C]// *Proceedings of the 11th World Congress on Intelligent Control and Automation, Shenyang, China*, 2014: 1511–1516.
- Su Juan, Li Bing, Wang Yanzhao. Infrared image enhancement based on PCNN segmentation and fuzzy set theory[J]. *Acta Optica Sinica*, 2016, **36**(9): 0910001.
苏娟, 李冰, 王延钊. 结合 PCNN 分割和模糊集理论的红外图像增强[J]. *光学学报*, 2016, **36**(9): 0910001.
- Peter D, Geoffrey E H, Radford M N, et al. The Helmholtz machine[J]. *Neural computation*, 1995, **7**(5): 889–904.
- Wu J J, Lin W S, Shi G M, et al. Perceptual quality metric with internal generative mechanism[J]. *IEEE Transactions on Image Processing*, 2013, **22**(1): 43–54.
- Zhang K H, Zhang L, Yang X. Infrared image adaptive enhancement based on fuzzy sets theory[C]// *Proceedings of the 2nd IEEE International Asia Conference on Informatics in Control, Automation and Robotics*, 2010, **2**: 242–245.
- Li C F, Bovik A C, Wu X J. Blind image quality assessment using a general regression neural network[J]. *IEEE Transactions on Neural Networks*, 2011, **22**(5): 793–799.
- Mao Ruiquan, Gong Xiaolin, Liu Kaihua. Image de-noising algorithm with neighborhood based on PCNN segmentation[J]. *Opto-Electronic Engineering*, 2010, **37**(2): 122–127.
毛瑞全, 宫霄霖, 刘开华. 基于 PCNN 区域分割的图像邻域去噪算法[J]. *光电工程*, 2010, **37**(2): 122–127.
- He Shengzong, Liu Yingjie, Ma Yide, et al. Medical X-ray image enhancement based on PCNN image factorization[J]. *Journal of Image and Graphics*, 2011, **16**(1): 21–26.
何胜宗, 刘映杰, 马义德, 等. 基于 PCNN 图像因子分解的 X 线医学图像增强[J]. *中国图象图形学报*, 2011, **16**(1): 21–26.
- Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, **13**(4): 600–612.
- Gupta S, Kaur L, Chauhan R C, et al. A versatile technique for visual enhancement of medical ultrasound images[J]. *Digital Signal Processing*, 2007, **17**(3): 542–560.