

基于深度置信网络的随机脉冲噪声快速检测算法

徐少平 张贵珍 李崇禧 刘婷云 唐祎玲*

(南昌大学信息工程学院 南昌 330031)

摘要: 为提高现有随机脉冲噪声(RVIN)检测算法的检测准确率和执行效率, 该文试图从构建描述能力更强的特征矢量和训练非线性映射更为准确的预测模型两个方面入手, 实现一种基于训练策略的快速RVIN检测算法。一方面, 提取多个不同阶的对数绝对差值排序统计值并结合一个能够反映图像边缘特性的统计值作为刻画图块中心像素点是否为噪声的特征矢量。在计算量增加极少的情况下, 显著提升了特征矢量的描述能力。另一方面, 基于深度置信网络(DBN)训练RVIN预测模型(RVIN检测器)将特征矢量映射为噪声类型标签, 实现了比浅层预测模型更为准确的映射。大量实验数据表明: 与现有的RVIN检测算法相比, 所提算法在检测准确率和执行效率两个方面都更有优势。

关键词: 随机脉冲噪声; 噪声检测; 图像局部统计值; 深度置信网络; 计算效率

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2019)05-1130-07

DOI: 10.11999/JEIT180558

A Fast Random-valued Impulse Noise Detection Algorithm Based on Deep Belief Network

XU Shaoping ZHANG Guizhen LI Chongxi LIU Tingyun TANG Yiling

(School of Information Engineering, Nanchang University, Nanchang 330031, China)

Abstract: To improve the detection accuracy and execution efficiency of the existing Random-Valued Impulse Noise (RVIN) detectors, a fast training-based RVIN detection algorithm is implemented by constructing a more descriptive feature vector and training a detection model with more accurate nonlinear mapping. On the one hand, multiple Rank-Ordered Logarithmic absolute Deviation (ROLD) statistics are extracted and combined with a statistical value reflecting the edge characteristics in the form of feature vector to describe how RVIN-like the center pixel of a patch is. The description ability of the feature vector is improved significantly while the computational complexity is just increased in small amount. On the other hand, an RVIN prediction model (RVIN detector) is obtained by training a Deep Belief Network (DBN) to map the feature vectors to noise labels, which is more accurate than the shallow prediction model. Extensive experimental results show that, compared with the existing RVIN detectors, the proposed one has better performance in terms of detection accuracy and execution efficiency.

Key words: Random-Valued Impulse Noise (RVIN); Noise detection; Local image statistic; Deep Belief Network (DBN); Computational efficiency

1 引言

由于传感器损坏、存储单元失效和传输信道干

扰等原因, 数字图像在采集、存储和传输过程中常常会受到脉冲噪声的干扰, 给后继的图像处理任务带来困难^[1-8]。脉冲噪声可以分为固定脉冲噪声(Fixed-Valued Impulse Noise, FVIN)和随机脉冲噪声(Random-Valued Impulse Noise, RVIN)两种^[1-3]。FVIN是指像素点亮度值为0或255(8 bit图像亮度值可取范围的最小和最大值), 而RVIN值则在0~255之间随机确定。虽然许多已经提出的脉冲噪声检测算法^[9,10]对FVIN的检测效果很好, 但是对于RVIN来说却不理想。这是因为受RVIN干扰的像素点很多时候与其对应原像素点之间亮度值差别并不是很大, 导致检测难度较大。本文主要研究

收稿日期: 2018-06-06; 改回日期: 2018-12-07; 网络出版: 2018-12-13

*通信作者: 唐祎玲 tangyiling@ncu.edu.cn

基金项目: 国家自然科学基金(61662044, 61163023, 51765042, 81501560), 江西省自然科学基金(20171BAB202017), 江西省研究生创新项目(YC2018-S066)

Foundation Items: The National Natural Science Foundation of China (61662044, 61163023, 51765042, 81501560), The Project of Jiangxi Province Natural Science Foundation (20171BAB202017), The Jiangxi Provincial Graduate Innovation Special Fund (YC2018-S066)

RVIN的检测问题。

早期, 研究者们提出了一些基于图像局部统计值的RVIN检测算法并且取得了不错的成果^[9]。例如: Garnett等人^[10]引入绝对差值排序(Rank-Ordered Absolute Difference, ROAD)统计值进行RVIN的检测。ROAD统计值是先求出窗口内中心像素点与其邻域所有像素点的亮度绝对差值并排序, 然后用前 m 个最小绝对差值的累积和作为图像局部统计值并与预设阈值进行比较来检测噪声像素点。该算法对RVIN的检测正确率高, 而且还适用于高斯和脉冲的混合噪声检测, 但当噪声比例比较高的时候, 检测正确率开始下降。随后, Dong等人^[11]利用对数函数来放大噪声和非噪声像素之间的差异, 提出了对数差值排序(Rank Ordered Logarithmic absolute Deviation, ROLD)统计值, 利用ROLD值完成噪声检测后再利用边缘保持正则化(Edge Preserving Regularization, EPR)方法完成图像的降噪。2012年, Xiong等人^[12]提出了基于鲁棒离群比率的非局部均值(Robust Outlyingness Ratio Non-Local Mean, ROR-NLM)算法。该算法在噪声检测时依据像素点ROR值的不同, 设置不同的阈值进行判断, 从而获得更好的噪声检测准确率。但它采用从粗到精的迭代预测方式, 需要设置很多不同的阈值才能完成检测任务, 故执行效率较低。上述降噪算法中实现RVIN检测模块的关键机制多是将单一的某种图像局部统计值与预设阈值进行比较来判定中心像素点是否为噪声, 检测正确率较低。为此, 这些算法常常采用将噪声检测算法与某个降噪算法绑定以串行迭代运行的方式实现。在迭代开始前, 由于噪声比例比较高, 首次使用较大阈值进行噪声检测。而在随后的迭代过程中, 随着图像质量的改善, 逐次降低阈值的大小。故这些噪声检测算法的性能与阈值设置以及具体使用的降噪算法密切相关, 执行效率较低, 限制了它们在对时间有严格要求的图像处理系统中的应用。

近年来, 基于训练的噪声检测算法利用预测模型直接判定图像中的像素点是否为噪声像素点, 无需与某种降噪算法绑定以及采用迭代执行方式完成噪声检测, 较传统的统计值-阈值比较的实现方法在执行效率上有显著改进。2016年, Roy等人^[13]利用支持向量机(Support Vector Machine, SVM)实现了一种FVIN检测算法。该检测算法使用的特征矢量包括预测误差、当前像素点值、局部窗口内像素点亮度中值、当前像素点值亮度值与中值的绝对差值和局部窗口内像素点亮度的均值共5个特征值。该噪声检测算法在人工生成的图像上提取训练

数据集合, 然后利用SVM构建噪声预测模型。Roy等人提出的噪声检测算法仅能适用于FVIN, 处理随机脉冲噪声时预测正确率大幅度下降。Turkmen^[14]基于多层感知(Multi-Layer Perception, MLP)神经网络以ROAD和ROLD两个统计值所构成的特征矢量作为网络预测模型的输入设计噪声检测算法, 完成噪声检测后用经典的EPR算法完成降噪。Turkmen提出的MLP-EPR算法在执行效率上具有明显优势, 不足之处是没有考虑图像的边缘特性, 检测正确率仍有待进一步提高。文献^[15]提出了一种基于神经网络分类器的随机脉冲噪声检测算法。训练网络模型的输入由ROLD和ROAD等5种局部特征值组成。该检测方法在脉冲噪声图像上能达到一定的检测正确率, 但是其预测模型的输入特征值个数过多, 导致提取过程的计算复杂度比较高, 在一定程度上影响执行效率。总体来说, 相对于传统的统计值-阈值比较判定机制的检测方法, 基于训练的噪声检测算法采用预测模型实现RVIN检测, 具有很高的执行效率。尽管如此, 其在检测正确率方面相对传统检测方法来说仍有较大差距, 这主要受制于特征矢量对RVIN的描述能力和预测模型本身的非线性映射能力。

为此, 本文从构建描述能力更为强大的特征矢量和提高预测模型映射能力2个方面入手, 提出一种基于深度置信网络(Deep Belief Network, DBN)的快速RVIN检测算法, 大力提高现有基于训练策略实现的RVIN检测算法的检测正确率, 同时进一步提高执行效率。本文算法充分利用多个不同阶的ROLD统计值和反映图像边缘细节特性的统计值作为描述噪声的特征矢量, 比现有方法所使用的特征值的描述能力更强, 而提取这些特征值的计算量并没有增加。此外, DBN强大的非线性映射能力可以将特征矢量更为准确地映射为噪声类型标签(noise label, 用0标记正常像素点, 1标记噪声像素点)。

2 ROLD统计值及其存在的问题

2.1 ROLD统计值

ROLD统计值被广泛应用于各类RVIN检测算法中。文献^[11]对像素点亮度差值取对数以更好地描述中心像素点 $y_{i,j}$ 与其邻域内其他像素点的差异

$$D_{s,t}(y_{i,j}) = \log_a |y_{i+s,j+t} - y_{i,j}|, \forall (s,t) \in \Omega_N^0 \quad (1)$$

其中, $\Omega_N^0 = \Omega_N \setminus (0,0)$ 表示去除中心像素点坐标的坐标集合, N 为邻域的半径。对于任意 $a > 1$, 差值 $D_{s,t}$ 总是在区间 $(-\infty, 0]$ 上, 为了让 $D_{s,t}$ 的取值范围在 $[0, 1]$ 之间, 采用式(2)进行处理

$$D_{s,t}(y_{i,j}) = 1 + \max \{ \log_a |y_{i+s,j+t} - y_{i,j}|, -b \} / b \quad (2)$$

$$\forall (s, t) \in \Omega_N^0$$

其中, $a = 2$ 和 $b = 5$ 。在这种参数设置下 $D_{s,t}$ 取值范围为 $[0, 1]$, 但前提是像素点亮度值的范围必须归一化到 $[0, 1]$ 之间。在实践中, 式(2)中亮度值范围仍可采用 $[0, 255]$ 表示, 这样 $D_{s,t}$ 取值范围较原定义的范围要大一些。基于此, 对所有的 $D_{s,t}$ 进行升序排序后, ROLD 统计值可以被定义为

$$\text{ROLD}_m(y_{i,j}) = \sum_{k=1}^m R_k(y_{i,j}) \quad (3)$$

其中, R_k 表示在排序后的 $D_{s,t}$ 序列中第 k 个值。基于 ROLD 统计值和预设阈值 T 可以定义一个简单的噪声检测机制。如果像素点 $y_{i,j}$ 的 $\text{ROLD}_m(y_{i,j})$ 值大于 T , 就被检测为是噪声, 否则为非噪声。

2.2 ROLD 存在的问题

ROLD 统计值主要依据其与预设阈值简单的大小关系来判断当前中心像素点是否为噪声点, 具有一定的局限性。如图1所示, 在受比例为40%的RVIN干扰的Lena图像中, 大小为 5×5 的图块a1和图块b1的 ROLD_{12} 值分别为20.45和20.46, 它们的值非常接近且比较大(相对于图像所有像素点 ROLD 值的整体分布)。如果仅使用1个阈值, 这2个像素点均应被划分为噪声像素点。但是实际上它们却分别是噪声和非噪声像素点。由上文可知, 为了提高检测正确率, 这些基于统计值设计的噪声检测算法主




图 1 噪声图像中不同位置处2个图块中心像素点ROLD统计值比较

要采用多次迭代执行的工作方式, 且需要在某种特定降噪算法协助下才能完成。虽然ROLD最终的检测正确率尚可, 但是其执行效率非常低下。其实, 从表1中可以很容易看出, 噪声和非噪声像素点从 ROLD_1 到 ROLD_m 之间不同阶上的 ROLD 值有较大差别, 具有很好的区分度。基于此, 本文采用多个不同阶的 ROLD 统计值作为描述中心像素点的特征矢量来增强检测算法的判定依据, 从而设计更为准确的噪声检测算法。

3 改进的随机脉冲检测算法

3.1 改进思路

基于训练的随机脉冲噪声检测算法性能的高低主要取决于: (1) 特征矢量(由多个能刻画图块中心像素点为噪声可能性的特征值构成)是否有强大的描述能力, 当像素点受噪声干扰后, 在特征值上能有相应的显著变化; (2) 预测模型是否具有强大的非线性逼近能力, 能将特征矢量准确映射为噪声类型标签。为此, 本文所采取的主要技术路线为: 首先, 在具有代表性的图像上施加各种比例的随机脉冲噪声构成失真图像库。其次, 采用多个不同阶的 ROLD 统计值并结合一个能描述像素点边缘特性的统计值构成描述图块中心像素点是否为噪声的特征矢量。再次, 将失真图像集合中的每一张图像分解为图块并提取相应的特征矢量和对应中心像素点是否为噪声的标记, 构成训练数据集合。最后, 利用非线性映射能力更强的 DBN 技术(相对于 SVR 和 MLP 而言)训练预测模型, 更为准确地完成从特征矢量到相应噪声标签的映射。

3.2 特征矢量提取

基于式(3), 取前 m 个 ROLD_m 统计值作为描述图块中心像素点是否为噪声的特征矢量

$$\mathbf{F}_{\text{ROLD}} = (\text{ROLD}_1 \text{ROLD}_2 \cdots \text{ROLD}_m) \quad (4)$$

为了进一步提高检测正确率, 引入一个描述边缘特征(Edge Feature, EF)的统计值。首先计算以下这4组值

$$y_{i,j}^h = \{d_n^h | d_n^h = |y_{i,j} - y_{i,j-N+n}|\} \quad (5)$$

$$y_{i,j}^v = \{d_n^v | d_n^v = |y_{i,j} - y_{i-N+n,j}|\} \quad (6)$$

$$y_{i,j}^l = \{d_n^l | d_n^l = |y_{i,j} - y_{i-N+n,j-N+n}|\} \quad (7)$$

表 1 图1中a1和b1图块上所提取的前 m 阶 ROLD 值比较

图块	阶数 m											
	1	2	3	4	5	6	7	8	9	10	11	12
a1	1.63	3.29	4.99	6.68	8.37	10.09	11.80	13.52	15.24	16.98	18.72	20.46
b1	1.00	2.20	3.66	5.12	6.84	8.62	10.50	12.44	14.40	16.40	18.42	20.45

$$y_{i,j}^r = \{d_n^r | d_n^r = |y_{i,j} - y_{i-N+n,j+N-n}|\} \quad (8)$$

其中, $0 \leq n \leq 2N$, $n \neq N$ 。这4组值实际上是中心像素点和它4个方向(水平、垂直、左斜对角线和右斜对角线)上的邻域像素点之间的差异。然后对每个方向上的差异进行累加求和, 以4个方向上距离累积和的最小值作为反映边缘特征的特征值

$$EF = \log_2 \left(\min \left(\sum_{n=1}^{2N} d_n^h, \sum_{n=1}^{2N} d_n^v, \sum_{n=1}^{2N} d_n^l, \sum_{n=1}^{2N} d_n^r \right) + 1 \right) \quad (9)$$

EF特征值的工作原理是: 如果图块中心像素点属于正常的边缘像素点, 那么它在某个方向上累积值理论上不会很大, 故可以利用EF特征值辅助判断该像素点是属于正常的图像边缘还是脉冲噪声。

需要说明的是: $ROLD_1 \sim ROLD_{m-1}$ 统计值原本就是计算 m 阶累积值 $ROLD_m$ 的中间步骤, 而边缘特征信息也是将中心像素点与邻域像素点之间的距离按照4个边缘方向重新组织利用而已。因此, 改进算法在提取特征值方面的计算代价并没有比经典的ROLD检测算法的计算量大很多, 但是这些特征值的描述能力却增强不少。本文设置 m 值为12, 这意味着中心像素点的邻域范围为 5×5 大小的图块。

3.3 RVIN检测模型

假设有 n 张用于训练的噪声图像, 这些图像被施加了不同比例的随机脉冲噪声构成噪声图像库。将噪声图像库中每一张图像分解为图块构成训练图块集合, 第 k 个训练图块记为 y^k , 这样在图块 y^k 上提取描述其中心像素点是否为噪声的特征矢量可以定义为

$$\mathbf{F}_{y^k} = (ROLD_1 \ ROLD_2 \ \cdots \ ROLD_m \ EF) \quad (10)$$

同时, 根据图块 y^k 中心像素点的亮度值是否发生变化设置其噪声类型标签(0为正常像素点, 1为噪声像素点), 记为 $L_k \in \{0, 1\}$ 。这样可构建训练数据集 $\{(\mathbf{F}_{y^1}, L_1), (\mathbf{F}_{y^2}, L_2), \dots, (\mathbf{F}_{y^k}, L_k)\} \subset \mathbb{F} \times L$ 。设计噪声检测算法就是从所有训练数据中找到一个函数(预测模型) $\varphi(\mathbf{F}_{y^k})$, 使得该预测模型在训练数据集上映射所获得的预测值与目标值 L_k 之间的累积差值尽可能小。

本文利用DBN在训练中不断学习原始数据(反映图块中心像素点是否为噪声点的特征矢量)中的高阶表示特征(中心像素点的噪声类型标签)。DBN是对观测数据和标签的联合分布建模的生成式模型, 它能够从高维的复杂数据中提取特征信息, 克服传统浅层网络结构容易陷入局部极小点^[16]的问题。DBN网络中的每2个相邻的层都被初始化为受

限波尔曼机(Restricted Boltzmann Machine, RBM), RBM由可见层若干个神经元 v_i 和隐含层若干个神经元 h_j 组成, 处于同一层的神经元之间互不连接。在RBM中, 输出单元对于输入状态是条件独立的, 因此给定1个输入, 可以得到后验分布的无偏样本, 该样本可以表示为

$$P(h_j = 1 | \mathbf{v}, \theta) = \sigma \left(b_j + \sum_{i=1}^V v_i W_{i,j} \right) \quad (11)$$

$$P(v_i = 1 | \mathbf{h}, \theta) = \sigma \left(a_i + \sum_{j=1}^H h_j W_{i,j} \right) \quad (12)$$

其中, $\sigma(\cdot)$ 为sigmoid函数。基于此, 能量函数 $E(\mathbf{v}, \mathbf{h})$ 可以定义为

$$E(\mathbf{v}, \mathbf{h} | \theta) = - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i W_{i,j} h_j \quad (13)$$

其中, $\theta = (W_{i,j}, a_i, b_j)$ 为模型的参数, v_i 和 h_j 分别表示第 i 个可见层神经元与第 j 个隐含层神经元的状态, a_i 和 b_j 分别为第 i 个可视变量和第 j 个隐藏变量的偏置值, $W_{i,j}$ 为节点 v_i 与节点 h_j 之间的边的权重。RBM的训练过程是通过求解最小化能量函数以更新两个相邻层之间的权重和各层之间的偏差。

DBN深度网络模型的训练过程中分为2步:

(1)无监督的预训练阶段: 利用Hinton等人^[16]提出的对比散度(Contrastive Divergence, CD)方法逐层训练RBM网络, 更新每一层的模型参数 $\theta = (W_{i,j}, a_i, b_j)$ 。在DBN网络的最后一层设置了一个回归层(Regression Layer, RL), 其主要功能是将底层RBM结构中学习的高层抽象特征表示映射为目标值。训练RBM网络的目的是对回归网络的权值参数进行初始化, 从而克服回归网络容易因随机初始化权值参数而陷入局部最优和训练时间过长的缺点。网络的整个训练过程是贪婪的、逐层的且无监督的, 其任务是尽可能地保留特征信息, 而不需要使用标签来改善网络的权重;

(2)有监督的微调阶段: 以预测误差为优化目标函数, 利用反向传播学习算法来调整DBN各层的模型参数。预测误差定义为

$$\hat{\phi} = \arg \min \sum_{k=1}^n (L_k - \phi(g_k))^2 \quad (14)$$

其中, g_k 和 L_k 分别表示关于特征矢量 $\mathbf{F}_{y^k}$ 经过多个RBM层映射后在最后一个隐藏层的输出值(特征向

量)和相应的噪声标签值, $\phi(\cdot)$ 是回归层的核函数。式(14)的解可表述为

$$\hat{\phi}(g) = \sum_{k=1}^n w_k \cdot K(g, g_k) + b \quad (15)$$

其中, w_k 和 b 分别表示回归层的权重和偏置。 $K(\cdot)$ 为核函数, 形式上定义为

$$K(g_h, g_k) = \exp\left(-\frac{\|g_h - g_k\|_2^2}{\gamma^2}\right) \quad (16)$$

其中, γ 用于控制 K 的宽度。这个阶段的主要任务是利用反向传播算法对各RBM层的参数进行微调, 尽可能地使得DBN所预测的噪声类型标签与真实值的误差最小, 完成深度网络模型DBN的整个学习过程。不同目的的两个阶段训练使得DBN网络比一步到位整体训练的模式更容易收敛。本文根据在不同网络参数配置下预测模型的实际预测准确率和执行效率, 最终确定将网络输入层神经元个数设置为13(12个ROLD统计值和1个EF特征值), 将网络中各隐含层神经元个数分别设置为8, 4和2(共使用3层RBM), 最后一层为回归层。

4 实验与分析

4.1 测试环境


为评估所提出的随机脉冲噪声检测算法的检测能力, 将其与经典的ASWM^[8]、PSMF^[17]、ROLD-EPR^[11]、ROR-NLM^[12]和MLP-EPR^[14]共5个随机脉冲噪声降噪算法中所使用的噪声检测算法进行对比实验, 全部实验统一在Matlab R2016编程环境下完成。测试图像选用来自于各类文献中常用的公开图像, 包括Lena, Bridge, House, Cameraman, Barbara, Peppers, Hill, Butterfly, Man和Couple, 共10张。评价噪声检测正确率的指标采用漏检数(Miss-hit)、误检数(False-hit)、错检总数(Total)和

MEMH(Mean Error of Miss Hit)^[11]。对于一个噪声检测算法来说, 上述4个指标同时保持较低的水平则表示其预测性能更好, 但以错检总数和MEMH为主。

4.2 检测准确性

首先, 为验证本文所提出的在特征矢量中加入EF特征值的方法能否有效防止位于图像边缘或者细节上的像素点被误检, 分别在训练图块集合上提取含有ROLD特征值和ROLD+EF特征值作为预测模型的输入, 训练两个预测模型。然后利用所训练的预测模型分别在加了40%随机脉冲噪声的Lena图像(大小为512 × 512)上进行测试, 结果如图2(a), 图2(b)所示, 以噪声标签矩阵伪灰度图像的形式体现(即在图2(a), 图2(b)中白色的像素点表示经检测后被判定为噪声的像素点, 黑色像素点表示经检测后判定为正常的像素点)。由图2(a)可知, 没有引入EF特征值所训练的预测模型将大量正常的图像边缘像素点错误判定为噪声(肉眼可明显看到大量的连续反映人物轮廓的边缘像素点存在), 而这种情况在图2(b)中则大为改观, 基本上很难看到明显的连续边缘, 这说明引入EF特征值后边缘细节像素点被误检的情况已不多了。为便于观察, 在图2(c)中将在EF特征帮助下未被误检为噪声的边缘像素点用白色的像素点表示。由图2(c)可知, Lena图像中很多边缘像素点被正确检测出来, 尤其是帽子和绒毛等细节变化丰富的部分像素点被正确的判别。综上所述, 在特征矢量中引入EF特征值能有效防止边缘像素点被错误检测为噪声像素点。

其次, 为测试所提出随机脉冲噪声检测算法的检测准确性, 在受不同噪声比例干扰的全部测试图像上完成了噪声检测实验, 并将性能指标的平均值记录在表2中, 最小的错检总数和MEMH指标值以黑色粗体表示。一般来说, 漏检率高容易导致图像



(a) 仅使用ROLD特征

(b) 使用ROLD特征和EF特征值

(c) 基于EF特征未被误检的边缘点

图2 引入EF特征对噪声检测效果的影响比较

中仍然遗留较多的噪声, 误检率高则会导致图像模糊, 影响降噪图像的质量。错检总数是前两者之和, 将它除以图像中像素点总数即为检测错误率。错检总数值越小, 意味着漏检数和错检数都较少, 检测错误率越低, 则降噪的图像质量越好。MEMH指标主要是用来衡量有噪声像素点未被检出(漏检)时对图像质量的影响。若MEMH值小于一定程度, 肉眼几乎感觉不出漏检的噪声, 也意味着漏检噪声点不会对图像降噪处理产生较大影响。从表2

中可以看出: 在各种噪声级别下, 所提出的噪声检测算法的错检总数指标值是所有参与比较的检测算法中最低的, 这意味着它的检测正确率是最高的。需要说明的是: 在表2中, MLP-EPR算法的性能指标明显低于所提出的随机脉冲检测算法, 这充分说明了对基于训练策略设计的随机噪声检测算法来说, 本文从增强特征值描述能力和增强预测模型非线性映射能力两个方面提升检测算法的性能是非常有效的。

表 2 各噪声检测算法在常用图像集合上的各项性能指标的平均值比较

方法	含噪20%				含噪40%				含噪60%			
	漏检数	误检数	错检总数	MEMH	漏检数	误检数	错检总数	MEMH	漏检数	误检数	错检总数	MEMH
ASWM	3462	10687	14149	14.23	7478	10005	17483	16.40	14720	9804	24524	23.17
PSMF	10695	3585	14279	15.14	23038	3603	26641	30.27	39096	5634	44730	45.81
ROLD-EPR	6567	5106	11673	18.77	9462	8956	18419	15.95	10417	11616	22034	14.04
ROR-NLM	5068	9354	14421	14.91	11906	8873	20779	17.13	22553	12856	35408	23.60
MLP-EPR	8505	2081	10586	22.78	13244	5759	19003	18.09	15017	10113	25130	16.18
本文方法	4084	5909	9992	11.77	7975	8586	16561	12.17	10076	12594	22670	11.53

最后, 为验证所提出噪声检测算法的实际使用效果, 统一使用图像inpainting修复算法^[18]依据检测结果完成降噪(只有那些被检测为噪声的像素点才会被修复), 实验结果记录在表3中(限于篇幅, 仅列出3张图像的具体数据)。从表3中的数据看

出, 所提出噪声检测算法获得的复原图像质量(用PSNR度量)大部分情况下排名第1, 仅在少数情况下排名第2, 总体上是所有参与比较检测算法中降噪效果最好的, 这意味着所提出的噪声检测算法的检测正确率是最高的。

表 3 各检测算法统一用相同修复算法降噪后在PSNR指标上的比较(dB)

方法	含噪20%			含噪40%			含噪50%			含噪60%		
	Lena	House	Bridge	Lena	House	Bridge	Lena	House	Bridge	Lena	House	Bridge
ASWM	39.06	33.31	25.76	34.27	31.21	24.33	30.66	28.81	23.25	26.04	26.13	21.61
PSMF	30.24	27.82	23.25	29.26	26.03	22.77	26.03	24.09	21.91	22.04	21.98	20.00
ROLD-EPR	34.77	33.31	26.75	31.77	31.21	24.25	30.54	28.81	23.12	28.78	26.13	22.20
ROR-NLM	36.94	28.92	25.28	31.58	28.91	23.59	27.61	27.39	22.35	22.92	24.68	20.39
MLP-EPR	36.45	39.36	27.71	33.83	37.49	24.40	31.86	36.48	23.33	29.42	33.96	22.25
本文方法	40.35	42.95	26.97	35.89	40.31	24.91	33.04	38.27	23.36	29.66	36.12	22.18

4.3 执行效率

噪声检测算法的执行效率是评价其性能好坏的一项重要指标, 表4中列出了各个噪声检测算法在受40%随机脉冲噪声干扰的测试图像上的平均执行时间。从表4可以看出, ASWM, ROLD-EPR和ROR-NLM算法中的噪声检测算法由于必须与降噪算法配合使用才能获得最终的检测结果, 故执行时间都非

常长。MLP-EPR和所提出算法都是基于训练策略实现的噪声检测算法, 可直接对整张输入图像的噪声点进行检测, 执行时间非常短。MLP-EPR算法需要使用ROAD和ROLD两种类型的统计值, 而所提出的噪声检测算法充分利用了在计算ROLD统计值时的中间信息(无需计算ROAD值), 以较小的计算代价获得了描述能力更为强大的特征值, 执行时间最短。

表 4 各噪声检测算法平均执行时间的比较(s)

方法	ASWM	PSMF	ROLD-EPR	ROR-NLM	MLP-EPR	本文方法
时间	102.72	0.86	10.40	77.19	0.79	0.70

5 结束语

本文提出的方法充分利用了计算图块ROLD统计值时产生的多个不同阶的中间结果,与能避免边缘像素点被误判为噪声的EF特征值相结合后,以极小的计算代价大大增强了特征矢量的描述能力。此外,在大量训练数据的支撑下,采用了比浅层神经网络映射能力更强的DBN将特征矢量更为准确地映射为噪声类型标签。与传统的随机脉冲噪声检测算法相比,本文提出的算法在检测准确性和执行效率两个方面都占有优势,为后续的RVIN降噪处理打下了坚实的基础。

参考文献

- [1] LIU Licheng, Chen C L P, and ZHOU Yicong. A new weighted mean filter with a two-phase detector for removing impulse noise[J]. *Information Sciences*, 2015, 315 (September): 4052–4057. doi: [10.1016/j.ins.2015.03.067](#).
- [2] SINGH N, THILAGAVATHY T, LAKSHMIPRIYA R T, *et al.* Some studies on detection and filtering algorithms for the removal of random valued impulse noise[J]. *IET Image Processing*, 2017, 11(11): 953–963. doi: [10.1049/iet-ipr.2017.0346](#).
- [3] DONG Yiqiu and XU Shufang. A new directional weighted median filter for removal of random-valued impulse noise[J]. *IEEE Signal Processing Letters*, 2007, 14(3): 193–196. doi: [10.1109/LSP.2006.884014](#).
- [4] 刘万军, 梁雪剑, 曲海成. 自适应增强卷积神经网络图像识别[J]. *中国图象图形学报*, 2017, 22(12): 1723–1736. doi: [10.11834/jig.170079](#).
LIU Wanjun, LIANG Xuejian, and QU Haicheng. Adaptively enhanced convolutional neural network algorithm for image recognition[J]. *Journal of Image and Graphics*, 2017, 22(12): 1723–1736. doi: [10.11834/jig.170079](#).
- [5] 于海平, 何发智, 潘一腾, 等. 一种基于多特征的距离正则化水平集快速分割方法[J]. *电子学报*, 2017, 45(3): 534–539. doi: [10.3969/j.issn.0372-2112.2017.003.004](#).
YU Haiping, HE Fazhi, PAN Yiteng, *et al.* A fast distance regularized level set method for segmentation based on multi-features[J]. *Acta Electronica Sinica*, 2017, 45(3): 534–539. doi: [10.3969/j.issn.0372-2112.2017.003.004](#).
- [6] 王森, 王余, 王易川, 等. 水下高速目标声谱图特征提取及分类设计[J]. *电子与信息学报*, 2017, 39(11): 2684–2689. doi: [10.11999/JEIT170283](#).
WANG Sen, WANG Yu, WANG Yichuan, *et al.* Feature extraction and classification of spectrum of radiated noise of underwater high speed vehicle[J]. *Journal of Electronics & Information Technology*, 2017, 39(11): 2684–2689. doi: [10.11999/JEIT170283](#).
- [7] 周笋鱼, 汤佳欣. 基于图像稀疏表达的模拟退火图像复原[J]. *光电子·激光*, 2018, 29(2): 218–223. doi: [10.16136/j.joel.2018.02.0088](#).
ZHOU Luoyu and TANG Jiaxin. Image restoration based on simulated annealing with image sparse representation[J]. *Journal of Optoelectronics · Laser*, 2018, 29(2): 218–223. doi: [10.16136/j.joel.2018.02.0088](#).
- [8] AKKOUL S, LEDEE R, LECONGE R, *et al.* A new adaptive switching median filter[J]. *IEEE Signal Processing Letters*, 2010, 17(6): 587–590. doi: [10.1109/LSP.2010.2048646](#).
- [9] YU Hancheng, ZHAO Li, and WANG Haixian. An efficient procedure for removing random-valued impulse noise in images[J]. *IEEE Signal Processing Letters*, 2008, 15(12): 922–925. doi: [10.1109/LSP.2008.2005051](#).
- [10] GARNETT R, HUEGERICH T, CHUI C, *et al.* A universal noise removal algorithm with an impulse detector[J]. *IEEE Transactions on Image Processing*, 2005, 14(11): 1747–1754. doi: [10.1109/TIP.2005.857261](#).
- [11] DONG Yiqiu, RAYMOND H C, and XU Shufang. A detection statistic for random-valued impulse noise[J]. *IEEE Transactions on Image Processing*, 2007, 16(4): 1112–1120. doi: [10.1109/TIP.2006.891348](#).
- [12] XIONG Bo and YIN Zhouping. A universal denoising framework with a new impulse detector and nonlocal means[J]. *IEEE Transactions on Image Processing*, 2012, 21(4): 1663–1675. doi: [10.1109/TIP.2011.2172804](#).
- [13] ROY A, SINGHA J, DEVI S S, *et al.* Impulse noise removal using SVM classification based fuzzy filter from gray scale images[J]. *Signal Processing*, 2016, 128(11): 262–273. doi: [10.1016/j.sigpro.2016.04.007](#).
- [14] TURKMEN I. The ANN based detector to remove random-valued impulse noise in images[J]. *Journal of Visual Communication and Image Representation*, 2015, 34(10): 28–36. doi: [10.1016/j.jvcir.2015.10.011](#).
- [15] SOLEIMANY S and HAMGHALAM M. A novel random-valued impulse noise detector based on MLP neural network classifier[C]. *Artificial Intelligence and Robotics (IRANOPEN)*, Qazvin, Iran, 2017: 165–169. doi: [10.1109/RIOS.2017.7956461](#).
- [16] HINTON G, DENG Li, YU Dong, *et al.* Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups[J]. *IEEE Signal Processing Magazine*, 2012, 29(6): 82–97. doi: [10.1109/MSP.2012.2205597](#).
- [17] WANG Zhou and ZHANG D. Progressive switching median filter for the removal of impulse noise highly corrupted images[J]. *IEEE Transactions on Circuits System II: Analog Digital Signal Processing*, 1999, 46(1): 78–80. doi: [10.1109/82.749102](#).
- [18] CHAN S H, WANG Xiran, and ELGENDY O A. Plug-and-play ADMM for image restoration: Fixed-point convergence and applications[J]. *IEEE Transactions on Computational Imaging*, 2017, 3(1): 84–98. doi: [10.1109/TCI.2016.2629286](#).

徐少平: 男, 1976年生, 博士, 教授, 博士生导师, 研究方向为图形图像处理技术、机器视觉、虚拟手术仿真等。

张贵珍: 女, 1993年生, 硕士生, 研究方向为图像处理与机器学习。

李崇禧: 男, 1994年生, 硕士生, 研究方向为图像处理与机器学习。

刘婷云: 女, 1996年生, 硕士生, 研究方向为图像处理与机器学习。

唐玮玲: 女, 1977年生, 博士生, 研究方向为图像处理与机器学习。