

第5章

图像噪声消除



教学视频

图像中常伴有各种噪声,它们会对图像的视觉质量造成比较明显的影响。噪声常干扰人们对图像全貌的感受和对细节的观察。例如大气雾霾对室外场景的影响就可以看作一种噪声,使得图像中景物的能见度降低,不易被看清楚。

噪声常在图像记录过程中产生,也可在图像加工或传输过程中产生。图像噪声可来源于采集环境、采集设备、测量误差、记数误差、传输中断、不恰当的图像加工等。噪声是一个比较广泛的概念,来源多样,影响和效果也多样。相对于有用的信号,人们一般认为噪声是烦人的。例如,无线电中的静电干扰或道路上的喧闹声能影响人们对话或欣赏音乐,电视上的雪花点或模糊的纸张打印效果降低了人们观看和理解的能力。消除或减弱噪声的影响是图像增强中的重要工作。

与一般的信号相比,噪声的频谱中常包含较多的高频分量,所以在图像增强中常考虑噪声的高频特性,使用相应的滤波器来进行消除。当然,由于噪声的来源和种类很多,且各有不同的特性,所以也需要设计不同类型的滤波器。近年来,结合深度学习技术的图像噪声消除也得到了较多关注。

消除噪声既可以采取图像增强的方法(包括第3章介绍的空域方法和第4章介绍的频域方法,以及本章后面几节的方法),也可以采取图像恢复的方法(参见本书第2单元)。

根据上述讨论,本章各节将安排如下。

5.1节分析一些典型图像噪声的来源和特点并给出描述它们的概率密度函数。

5.2节介绍用于消除噪声的各类典型滤波器,既包括基本的均值类滤波器和排序类滤波器,也包括结合它们特点的混合滤波器。

5.3节介绍几种主要用于消除脉冲类噪声的开关中值滤波器,包括它们的基本原理、改进方法和效果比较。

5.4节介绍一些结合深度学习技术进行图像噪声消除的示例。

5.1 噪声概述

噪声是最常见的导致图像质量下降的因素之一。噪声的概念比较宽泛,实际中的噪声有许多不同来源,也有许多不同特性,对图像质量的影响也各不相同。需要指出,因为噪声主要影响人类的感知,人们常将噪声看作与信号相对立,所以有关噪声的问题常常不能完全看作一个纯科学或纯数学问题[Libbey 1994]。

5.1.1 噪声描述

下面先讨论噪声与信号的关系,然后具体介绍几种典型的噪声及其特点,最后举一个综合示例。

1. 噪声与信号

相对于所关心的信号来说,图像中的噪声可定义为图像中不希望有的部分,或图像中不需要的部分[Bracewell 1995]。对信号来说,噪声是一种外部干扰。但噪声本身实际上也是一种信号,只不过它携带的是噪声源的信息(信号携带了信号源的信息)。噪声可以与信号无关,也可以与信号相关。如果噪声与信号无关,那就无法根据信号的特性来预测噪声的特性。然而,如果噪声是(与信号)独立的,则可以在完全没有所需信号的情况下对噪声进行研究。很多情况下将噪声看成不确定的随机现象,主要采用概率论和统计学的方法来处理。注意,人们所关心的信号本身也可能有随机性,例如用于对地测量的热微波或红外辐射就有这种特点。由上面的讨论可知,图像中的噪声并不需要与信号完全对立,它有可能与信号有密切的联系(例如,乘性噪声对图像质量的影响与信号强度成比例)。此时如果改变信号,噪声也可能发生变化。

噪声既可能有一定的随机性,如电视屏幕上的雪花噪声;也可能比较规则或有规律(systematic),如电视屏幕上的移动条纹。当电视图像由于电冰箱的电机干扰或行驶中摩托车的发动机干扰而产生独立的亮点时,这种噪声既有随机特性也有规则特性。

在很多情况下,噪声的(随机/规则)特性并不是很重要,重要的是它的强度,特别是其相对于人们所关心信号的强度。常用的信噪比(SNR)就反映了噪声相对于信号的强度比值。信噪比是一个重要的放大器或通信系统的质量指标。典型的信噪比是用能量比(或电压平方比)来定义的:

$$\text{SNR} = 10 \lg \left(\frac{V_s^2}{V_n^2} \right) \quad (5.1.1)$$

但在一些特殊的应用中,也有一些变型。例如,在电视应用中,信号电压 V_s 用峰-峰值为单位,而噪声电压 V_n 用均方根(RMS)为单位。此时得到的数值要比都用均方根为单位得到的数值高 9.03dB。

另外,在图像合成时常采用如下定义的信噪比进行控制[Kitchen 1981]:

$$\text{SNR} = \left(\frac{C_{\text{ob}}}{\sigma} \right)^2 \quad (5.1.2)$$

其中, C_{ob} 为目标与背景间的灰度对比度, σ 为噪声均方差。

2. 几种常见噪声类型

噪声形成的原因是多种多样的,其性质也千差万别,下面介绍几种常见的噪声[Libbey 1994]、[Siau 2002]。

1) 热(heat)噪声

热噪声是指物质中导电载流子由于热扰动而产生的噪声。这种由热导致的噪声在从零频率直到很高的频率范围之间分布一致,一般认为它可以产生对不同波长有相同能量的频谱(或者说在噪声频谱上任何相同频率间隔内的能量相同)。这种噪声也称为**高斯噪声**(其空间幅度符合高斯分布)或**白噪声**(其频率覆盖整个频谱)。

2) 闪烁(flicker)噪声

闪烁噪声是由电子运动导致的一种噪声。事实上,电子或电荷的流动并不是一个连续的完美过程,它们的随机性会产生一个很难量化和测量的交流成分(随机 AC)。这种噪声一般具有反比于频率($1/f$)的频谱,所以也称 $1/f$ 噪声,一般在 1000Hz 以下的低频时比较明显。也有人称其为粉色噪声。粉色噪声在对数频率间隔内具有相同的能量(例如,在 1~10Hz 和 10~100Hz 之间的粉色噪声能量是相同的)。

3) 发射(shot)噪声

发射噪声也是电流非均匀流动,或者说电子运动有随机性而产生的结果。例如显像管中的电流除根据图像信号变化外,还会根据电子的随机运动而变化。这样,在本应该稳定的直流分量中实际上还保留(或叠加)了一个交流分量。发射噪声也常形象地称为“房顶雨(rain on the roof)”噪声。它也是一种高斯分布的噪声,可以用统计和概率的原理来量化。

4) 有色(colored)噪声

有色噪声指具有非白色频谱的宽带噪声。典型的例子如运动的汽车、计算机风扇、电钻等产生的噪声。另外,白噪声通过一些信道后也会被“染色”为有色噪声。两种常见的有色噪声——粉色(pink)噪声和褐色(brown)噪声的各一个示例分别见图 5.1.1。相对于白噪声来说,有色噪声中低频分量占了较大比重。




图 5.1.1 粉色噪声和褐色噪声示例

3. 成像过程中的多种噪声

噪声不仅种类繁多,而且多种噪声还可能在一个成像过程中同时出现。在传感器工作过程中产生的噪声称为传感器噪声。以利用 CCD 器件成像的整个过程为例,其中多种噪声不可避免地都有体现(按拼音顺序排列)。

(1) 暗电流噪声:源于 CCD 的信号转换电路中的暗电流,即使在没有光线时也会产生,且一般随图像采集时间长度而增加。

(2) 放大噪声:也称为放大器噪声,指由放大器引起的噪声,一般放大器增益越高,产生的噪声越大。

(3) 固定模式噪声:也称为有偏噪声,其均值对某些像素总不为零,常源于特定设备或器件。

(4) 光子噪声:由连续自然光到达一个像素范围内的光子数量值的起伏所带来的噪声,它与光源、光路、成像环境等的特性都有关联。

(5) 量化噪声:对应在将模拟信号转换为数字信号时所带来的误差,这是因为不管使用多少个量化比特值,都无法穷尽由单个像素中光电子引起的模拟电压值。

(6) 片上电子噪声:也称为读出噪声,它与 CCD 读出像素值的速率成比例,读出速率越高,读出噪声越明显。

(7) 热噪声:与 CCD 的工作温度密切相关,随着 CCD 的工作温度增高,更多的电子从 CCD 的硅材料中释放出来并生成电子空穴,而这些电子与由光子到达像素所激发出来的光电子是无法通过亮度量化器加以区分的。

(8) 散粒噪声:也称为发射噪声,是一种由电子运动的随机性而导致的噪声,与光电流的直流分量、电子电荷及滤波器的频率有关。散粒噪声随光频率的增大而线性增加。

采集到的图像中存在的最终噪声量不仅取决于所有这些量,而且与入射光(由场景的辐射度和照相机光圈所控制)、曝光时间和传感器增益等都有关系。

5.1.2 噪声概率密度函数

噪声对图像的影响最直观的就是使图像像素的灰度发生了变化。噪声本身的灰度可看作

随机变量,其分布可用**概率密度函数**(PDF)来刻画。下面介绍 4 种重要的噪声概率密度函数。

1. 高斯噪声

一个高斯随机变量 z 的 PDF 可表示为

$$p(z) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[-\frac{(z-\mu)^2}{2\sigma^2} \right] \quad (5.1.3)$$

其中, z 代表灰度, μ 是 z 的均值, σ 是 z 的标准差。该函数的一个示例如图 5.1.2 所示。**高斯噪声**的灰度值多集中在均值附近,随着与均值的距离增加而数量减少。

高斯噪声模型在数学上比较好处理,许多分布接近高斯分布的噪声也常用高斯噪声模型近似地处理。高斯噪声模型是更广泛的指数型噪声模型的一个特例。




图 5.1.2 一个高斯噪声的概率密度函数

2. 均匀噪声

均匀噪声的 PDF 可表示为

$$p(z) = \begin{cases} 1/(b-a) & a \leq z \leq b \\ 0 & \text{其他} \end{cases} \quad (5.1.4)$$

均匀噪声的均值和方差分别为

$$\mu = (a+b)/2 \quad (5.1.5)$$

$$\sigma^2 = (b-a)^2/12 \quad (5.1.6)$$

它的一个示例如图 5.1.3 所示。均匀噪声灰度值的分布在一定的范围内是均衡的。

均匀噪声常作为许多随机数发生器的基础,例如可用它(借助大数定理)来产生高斯噪声。

3. 脉冲噪声

脉冲噪声也常称**椒盐噪声**(严格地说,仅指饱和的脉冲噪声),其 PDF 可用下式表示(对应的一个示例如图 5.1.4 所示):

$$p(z) = \begin{cases} P_a & z = a \\ P_b & z = b \\ 0 & \text{其他} \end{cases} \quad (5.1.7)$$




图 5.1.3 一个均匀噪声的概率密度函数




图 5.1.4 一个脉冲噪声的概率密度函数

噪声脉冲可以是正的或负的(叠加在像素的灰度值上可能增加灰度也可能减小灰度)。因为脉冲的影响常比图像中信号的强度要大(受噪声影响的像素的灰度值与无噪声像素的灰度值会明显不同),脉冲噪声一般量化成图像中的极限灰度(显示为白或黑)。

实际中,一般假设 a 和 b 都是“饱和”值,即它们取图像所允许的最大灰度和最小灰度(更多讨论还可见 5.3.1 小节)。如果 $b > a$,灰度为 b 的像素在图像中显示为白点,而灰度为 a 的像素在图像中显示为黑点。在特殊情况下,如果 P_a 或 P_b 为 0,则脉冲噪声称为单极性的(unipolar)。一般 P_a 和 P_b 均不为 0,且两者大小很接近,此时饱和的脉冲噪声就像(深色)椒

粒和(浅色)盐粒随机撒在图像上。因为这个原因,双极性的(bipolar)脉冲噪声也称为椒盐噪声。在图像显示时,负脉冲显示为黑色(椒)而正脉冲显示为白色(盐)。对 8 个比特的图像,则有 $a=0$ (黑)和 $b=255$ (白)。发射噪声、尖峰噪声和错误交换导致的误差等都可以用脉冲噪声来表示。

4. 瑞利噪声

瑞利噪声所对应的随机变量的 PDF 可表示为(a 和 b 都是常数)

$$p(z) = \begin{cases} \frac{2}{b}(z-a)e^{-(z-a)^2/b} & z \geq a \\ 0 & z < a \end{cases} \quad (5.1.8)$$

瑞利噪声的均值和方差分别是

$$\mu = a + \sqrt{\pi b/4} \quad (5.1.9)$$

$$\sigma^2 = b(4 - \pi)^2/4 \quad (5.1.10)$$




图 5.1.5 一个瑞利噪声的概率密度函数

瑞利噪声概率密度函数的一个示例见图 5.1.5。瑞利噪声的分布与原点有一定的偏移(由 a 确定)且整体形状右偏/右倾(右拖尾)。

除上述几种噪声概率密度函数外,在描述噪声时还会用到伽马、指数等噪声概率密度函数。还有些噪声根据情况不同需要使用多种噪声概率密度函数来描述。例如,在超声断层扫描成像系统中常见的斑点噪声就是一例。当每单元中散射体数目大于 10 时,斑点噪声服从信噪比为 1.92 的瑞利分布;而当每单元中散射体数目很小时,斑点噪声服从 K 分布,也称莱斯分布或广义瑞利分布(瑞利分布是其一种特例)。莱斯概率密度函数是正弦波加窄带高斯分布的包络形式。

5.2 典型噪声滤波器

为消除不同类型的噪声,常需要设计和使用各种相应的滤波器。从原理上说,空域滤波器和频域滤波器(或更广泛的变换域滤波器)都可用于消除噪声。在本章中,仅考虑对灰度图像的滤波消噪,对彩色图像的滤波消噪可见 14.4.4 小节。

5.2.1 均值类滤波器

均值滤波器实际上代表一大类空域噪声滤波器。3.3.1 小节介绍的邻域平均就是最基本的均值滤波操作。由于均值可以有不同的定义,所以均值滤波器也有不同类型(也可以是非线性滤波器)。

1. 算术均值滤波器

给定一个 $m \times n$ 模板,它所覆盖的图像 $f(x, y)$ 中以 (x, y) 为中心的邻域 $N(x, y)$ 的算术均值为

$$\bar{f}(x, y) = \frac{1}{mn} \sum_{(s, t) \in N(x, y)} f(s, t) \quad (5.2.1)$$

当退化图像用 $g(x, y)$ 表示时,用算术均值滤波器得到的输出图像 $f_e(x, y)$ 为

$$f_e(x, y) = \frac{1}{mn} \sum_{(s, t) \in N(x, y)} g(s, t) \quad (5.2.2)$$

注意,该滤波器(就是 3.3.1 小节介绍的平均滤波器)在消除一些噪声的同时也模糊了图像。

2. 几何均值滤波器

根据几何均值的定义,用几何均值滤波器得到的输出图像 $f_e(x, y)$ 为

$$f_e(x, y) = \left[\prod_{(s, t) \in N(x, y)} g(s, t) \right]^{\frac{1}{mn}} \quad (5.2.3)$$

几何均值滤波器对图像的平滑作用与算术均值滤波器相当,但相比算术均值滤波器它能在输出图像中保持更多的细节。

3. 调和均值滤波器

调和均值也称谐波均值。根据其定义,用调和均值滤波器(谐波均值滤波器)得到的输出图像 $f_e(x, y)$ 为

$$f_e(x, y) = \frac{mn}{\sum_{(s, t) \in N(x, y)} 1/g(s, t)} \quad (5.2.4)$$

调和均值滤波器对高斯噪声有较好的滤除效果。它对椒盐噪声的两部分作用不对称,对盐噪声的滤除效果要比对椒噪声好得多(因为椒噪声对求和的贡献远大于盐噪声对求和的贡献)。

4. 逆调和均值滤波器

计算逆调和均值是一种比较通用的均值类滤波方法,由逆调和均值滤波器得到的输出图像 $f_e(x, y)$ 为

$$f_e(x, y) = \frac{\sum_{(s, t) \in N(x, y)} g(s, t)^{k+1}}{\sum_{(s, t) \in N(x, y)} g(s, t)^k} \quad (5.2.5)$$

其中, k 为滤波器的阶数。逆调和均值滤波器对椒盐类噪声的滤除效果比较好,但不能同时滤除椒噪声和盐噪声。当 k 为正数时,滤波器适合滤除椒噪声;当 k 为负数时,滤波器适合滤除盐噪声。另外,当 k 为 0 时,逆调和均值滤波器退化为算术均值滤除器;当 k 为 -1 时,逆调和均值滤波器退化为调和均值滤除器。

例 5.2.1 均值类滤波器效果示例

参见图 5.2.1。图 5.2.1(a) 为一幅叠加了均值为零、方差为 256 的高斯噪声的图像。图 5.2.1(b)~图 5.2.1(e) 依次分别为用算术均值滤波器、几何均值滤波器、调和均值滤波器以及逆调和均值滤波器(取 k 为正数)得到的结果。由图可见,它们都能较好地滤除高斯噪声,互相之间的效果差距不大。



图 5.2.1 几种均值类滤波器滤除高斯噪声的效果

再来看图 5.2.2。图 5.2.2(a)为一幅叠加了 20% 的脉冲噪声的图像。图 5.2.2(b)~图 5.2.2(e)依次分别为用算术均值滤波器、几何均值滤波器、调和均值滤波器以及逆调和均值滤波器(取 k 为正数)得到的结果。由图可见,除算术均值滤波器获得了脉冲噪声滤除的效果外,另外三种滤波器反而加强了脉冲噪声对图像的影响。




图 5.2.2 几种均值类滤波器滤除脉冲噪声的效果

对比前面的两组图,可见一般情况下使用均值滤波器滤除高斯噪声的效果比滤除脉冲噪声的效果好,或者说均值滤波更适合于消除高斯噪声。□

5. 非线性均值滤波器

计算非线性均值也是一种比较通用的均值类滤波方法。给定 N 个数 $x_i, i=1, 2, \dots, N$, 它们的 1-D(2-D 可类似地定义)非线性均值为[Mitra 2001]

$$g = f(x_1, x_2, \dots, x_N) = h^{-1} \left[\frac{\sum_{i=1}^N w_i h(x_i)}{\sum_{i=1}^N w_i} \right] \quad (5.2.6)$$

其中, $h(x)$ 一般是非线性单值解析函数; w_i 是权重。非线性均值滤波器的性质取决于函数 $h(x)$ 和权重 w_i 。如果 $h(x) = x$, 则得到算术均值 $\bar{x}$ 。如果 $h(x) = 1/x$, 则得到调和均值 g_H 。如果 $h(x) = \ln(x)$, 则得到几何均值 g 。如果权重是常数, 则非线性均值滤波器就简化为同态滤波器(见 4.5 节)。如果权重不是常数, 则得到其他类型的非线性滤波器。

5.2.2 排序类统计滤波器

排序滤波器也代表一大类空域噪声滤波器, 可实现序统计滤波。它们全部都是非线性滤波器。

1. 基本排序滤波器

3.4.1 小节介绍的中值滤波器、最大值滤波器、最小值滤波器和中点滤波器都是基本的排序滤波器。

例 5.2.2 基本排序滤波器效果示例

作为对比, 下面给出基本排序类滤波器消除高斯噪声和脉冲噪声的一些效果, 参见图 5.2.3。图 5.2.3(a)为一幅叠加了均值为零、方差为 256 的高斯噪声的图像。图 5.2.3(b)~图 5.2.3(e)依次分别为用中值滤波器、最大值滤波器、最小值滤波器和中点滤波器得到的结果。



图 5.2.3 基本排序滤波器滤除高斯噪声的效果

再来看图 5.2.4。图 5.2.4(a)为一幅叠加了 20% 的脉冲噪声的图像。图 5.2.4(b)~图 5.2.4(e)分别为用中值滤波器、最大值滤波器、最小值滤波器和中点滤波器得到的结果。




图 5.2.4 基本排序滤波器滤除脉冲噪声的效果

对比前面的两组图,可见一般情况下中值滤波器滤除脉冲噪声的效果比滤除高斯噪声的效果好,而其他几种排序统计滤波器对双极性的脉冲噪声效果并不好。□

2. 剪切均值滤波器

利用排序结果把 (x, y) 的邻域 $N(x, y)$ 中的 $d/2$ 个最小的灰度值和 $d/2$ 个最大的灰度值剪切掉,再对剩下的 $mn-d$ 个像素值(用 $g_r(s, t)$ 表示剩下的 $mn-d$ 个像素)求平均就得到剪切均值滤波器。该滤波器的输出为

$$f_e(u, v) = \frac{1}{mn-d} \sum_{(s, t) \in N(x, y)} g_r(s, t) \quad (5.2.7)$$

其中, d 的值可在 $0 \sim mn-1$ 选取。如果选 $d=0$,则没有剪切只取均值,剪切均值滤波器简化为算术均值滤波器。如果选 $d=mn-1$,则把比中值大或小的值都剪切掉,剪切均值滤波器成为中值滤波器。如果 d 选取其他值,则剪切均值滤波器可用于消除有多种噪声(如椒盐和高斯噪声)的情况。

理论分析和实验都表明,中值滤波器滤除脉冲噪声的效果好但滤除加性高斯噪声的效果差,而均值滤波器滤除脉冲噪声的效果差但滤除加性高斯噪声的效果好。剪切均值滤波器是对两者的一个综合和妥协。通过选取合适的 d ,既可平滑图像还可消除噪声。

3. 自适应中值滤波器

当图像上叠加的脉冲噪声密度不是很大时(P_a 和 P_b 均小于0.2),标准中值滤波器就可取得较好的效果。如果脉冲噪声的密度更大时就需要使用具有自适应能力的中值滤波器。自适应中值滤波器在滤除非脉冲噪声时可以比标准中值滤波器更好地保留图像细节。

自适应中值滤波器的自适应体现在滤波器的模板尺寸可以根据图像特性进行调节。设用 $g_{\min}$ 表示模板区域 W 中像素的最小值,用 $g_{\max}$ 表示模板区域 W 中像素的最大值,用 g_{med} 表示模板区域 W 中像素的中值,用 g_{xy} 表示噪声图像在 (x, y) 处的灰度值,用 S_W 表示对模板允许的最大尺寸。自适应中值滤波器有两种工作模式,分别记为A模式和B模式[Umbaugh 2005]。

A 模式: $A_1 = g_{\text{med}} - g_{\min}, A_2 = g_{\text{med}} - g_{\max}$

如果 $A_1 > 0$ 且 $A_2 < 0$,转到B模式

否则增大模板尺寸(一般每个方向增加两个像素)

如果模板尺寸 $\leq S_W$,重复A模式

否则 $f(x, y) = g_{xy}$

B 模式: $B_1 = g_{xy} - g_{\min}, B_2 = g_{xy} - g_{\max}$

如果 $B_1 > 0$ 且 $B_2 < 0$, $f(x, y) = g_{xy}$

否则 $f(x, y) = g_{\text{med}}$

这里 A 模式的功能是确定标准中值滤波器的输出是否为脉冲噪声。如果该输出值等于最大值或最小值,就有可能是脉冲噪声,就需要增大模板尺寸再试。如果该输出不等于最大值或最小值,就转向 B 模式,看当前像素是否为脉冲噪声。如果是,则输出中值;如果不是,则输出当前值,这样做能保持图像中的边缘。

总结一下,自适应中值滤波器可以达到三个目的:滤除脉冲噪声,平滑非脉冲噪声,减少对目标边界过度细化或粗化而产生的失真。从统计的角度讲,即便 $g_{\min}$ 和 $g_{\max}$ 不是图像中可能的最小和最大灰度值,它们仍被看作类似脉冲的噪声成分。

5.2.3 选择性滤波器

均值滤波器能有效地消除高斯噪声和均匀噪声,但对脉冲噪声的消除效果较差。中值滤波器能有效地消除脉冲噪声,且不会对图像带来过多的模糊效果,但对高斯噪声的消除效果不是很好。当图像同时受到不同噪声影响时,可以采用选择性滤波的方式,在受到不同噪声影响的位置选择不同的滤波器,以发挥不同滤波器的各自特点,取得较好的综合效果。下面介绍一种具体方法作为示例[李 2006]。

1. 滤波器模块框图

用于消除高斯噪声和脉冲噪声的选择性滤波器的模块框图和工作流程如图 5.2.5 所示,其中包括 4 个功能模块,分别为椒盐噪声检测、滤波器选择、滤除椒盐噪声和滤除高斯噪声。对输入的噪声图像,先用椒盐噪声检测器检测出受椒盐噪声影响(也可能还受其他噪声的较小影响)的像素,对这些像素可用中值滤波器一类的滤波器进行噪声滤除,对其余的像素则可用均值滤波器一类的滤波器进行噪声滤除,最后将两部分结果组合起来得到对高斯噪声和椒盐噪声都滤除的结果。




图 5.2.5 选择性滤波器模块框图

2. 椒盐噪声检测

受椒盐噪声影响的像素的灰度值会取到图像灰度范围的两个极端值。因此,椒盐噪声检测可根据下面两个准则来判断:

1) 灰度范围准则

设图像灰度范围为 $[L_{\min}, L_{\max}]$, 那么如果一个像素的灰度值在 $[L_{\min}, L_{\min} + T_g]$ 或 $[L_{\max} - T_g, L_{\max}]$ 范围中, 则它很有可能受到了椒盐噪声的影响, 其中 T_g 是检测椒盐噪声的灰度阈值, 确定了灰度极端值的范围。

2) 局部差别准则

考虑一个像素的邻域(如 8-邻域), 如果其中有较多的邻域像素与该像素的灰度值有较大的差别, 则该像素为受椒盐噪声影响的像素的可能性就比较大。具体可设计两个阈值, T_v 和 T_n , T_v 用来判断邻域像素间灰度值的差别是否足够大, T_n 用来判断灰度差别足够大的像素个数是否足够多。如果对一个待检测像素, 其邻域中灰度值与其灰度值的差别大于 T_v 的像素个数又多于 T_n , 则它很有可能是受椒盐噪声影响的像素。

实际中,设位于 (x,y) 处像素的邻域为 $N(x,y)$,属于该邻域的像素用 $f(s,t)$ 表示,则可将上面两个准则结合到如下公式($\#[\cdot]$ 代表个数,分子代表与邻域像素间灰度值差别大于阈值 T_v 的像素数,分母代表邻域像素总个数,这样 T_n 对应百分比阈值)中:

$$\frac{\#[|f(x,y) - f(s,t)| > T_v]}{\#[N(x,y)]} > T_n \quad (5.2.8)$$

这里结合使用了两个准则。因为如果仅使用灰度范围准则,有可能会把图像中一些原来灰度值在 $[L_{\min} + T_g, L_{\max} - T_g]$ 范围中的正常像素也误判为受脉冲噪声影响的像素;而如果仅使用局部差别准则,则有可能将许多正常的边缘像素都误判为受脉冲噪声影响的像素。同时满足两个准则的像素是受脉冲噪声影响真实可能性很大的像素。

3. 滤波器选择

当图像同时受到脉冲噪声和高斯噪声影响时,在如上检测出受脉冲噪声影响的像素集合后,可以将图像分为两个集合,一个集合仅受到高斯噪声影响,另一个集合不仅受到高斯噪声影响还受到脉冲噪声影响。由于受到脉冲噪声影响的像素的灰度会取到图像灰度范围的两个极端值,所以在这些像素上高斯噪声的影响可以忽略。这样一来,图像可分为仅受到高斯噪声影响和仅受到脉冲噪声影响的两个集合。对仅受到脉冲噪声影响的像素,可利用中值滤波器来消除噪声。而对仅受到高斯噪声影响的像素,可以用均值类滤波器来消除噪声。

图 5.2.6 给出了运用选择性滤波器消除混合噪声的一个示例。图 5.2.6(a)是原始图像,图 5.2.6(b)是受到混合噪声影响的图像(其中高斯噪声均值为 0,方差为 162;脉冲噪声的比例为 20%),图 5.2.6(c)是用选择性滤波器消除噪声后获得的图像。两种噪声都得到了较好的消除效果。




图 5.2.6 选择性滤波示例

实验结果表明,在消除各种混合比例的混合脉冲噪声和高斯噪声时使用选择性滤波器的效果比单独使用其中任何一个滤波器的效果都要好。

5.3 开关中值滤波器

椒盐噪声对图像的影响有其特点,一方面,椒盐噪声在空间上的分布是离散的,或者说,它并不对所有像素都造成影响;另一方面,椒盐噪声在幅度上是很大的,受噪声影响的像素或者很接近白色,或者很接近黑色,均极大地改变了像素原来的灰度。根据椒盐噪声的这些特点,有一些方法在消除椒盐噪声时先对椒盐噪声像素进行检测或判断然后再进行处理。如果像素没有受到噪声影响,就完全不用处理,如果受到了噪声影响,才针对性地进行处理。

一种借助这种思路、在中值滤波器基础上提出的专门消除椒盐噪声的滤波器是**开关中值滤波器**(也可称切换中值滤波器)。下面先介绍基本的方法,再讨论一些改进措施。

5.3.1 开关中值滤波原理

开关中值滤波消除脉冲噪声的第一步是确定、辨识噪声像素,然后是对辨识出的噪声像素

进行滤波消除。其中第一步既是后续消除噪声的基础,也有一定的难度。下面主要讨论第一步。

1. 噪声模型

式(5.1.7)给出的脉冲噪声所对应的随机变量的 PDF 是一种基本的情况。事实上脉冲噪声所对应的 PDF 由特殊到通用可以分成 4 种模型,下面依次介绍(仍使用那里的约定)。

1) 模型 1

在这个模型中,图像像素被两个极端值(对 8 比特灰度图,分别是 0 和 255)所影响/损坏(污染)。这里设两个极端值的概率是相同的,即噪声密度 $P = P_a = P_b$ 。如果设在位置 (x, y) 的像素 $f(x, y)$ 受噪声影响后变为 $g(x, y)$,则此时模型 1 的概率密度函数为

$$p^{(1)}(z) = \begin{cases} P/2 & z = 0 \\ 1 - P & z = g(x, y) \\ P/2 & z = 255 \end{cases} \quad (5.3.1)$$

2) 模型 2

在这个模型中,图像像素仍被两个极端值(对 8 比特灰度图,分别是 0 和 255)所影响(污染)。与模型 1 不同,模型 2 中不设两个极端值有相同的概率,而设被污染的像素既可能受椒噪声影响也可能受盐噪声的影响,即噪声密度是椒噪声密度与盐噪声密度之和, $P = P_a + P_b$ (且 $P_a \neq P_b$)。如果设在位置 (x, y) 的像素 $f(x, y)$ 受噪声影响后变为 $g(x, y)$,则此时模型 2 的概率密度函数为

$$p^{(2)}(z) = \begin{cases} P_a/2 & z = 0 \\ 1 - P & z = g(x, y) \\ P_b/2 & z = 255 \end{cases} \quad (5.3.2)$$

3) 模型 3

在这个模型中,图像像素不再仅被两个固定的极端值(对 8 比特灰度图,分别是 0 和 255)所影响(污染),而是被两个极端的数值范围所影响。设这两个数值范围的概率相同,宽度都为 W ,如当 $W=6$ 时,这两个范围分别为 $[0, 5]$ 和 $[250, 255]$ 。这样一来,如果设在位置 (x, y) 的像素 $f(x, y)$ 受噪声影响后变为 $g(x, y)$,则此时模型 3 的概率密度函数为

$$p^{(3)}(z) = \begin{cases} (P/2)W & 0 \leq z < W \\ 1 - P & z = g(x, y) \\ (P/2)W & 255 - W < z \leq 255 \end{cases} \quad (5.3.3)$$

4) 模型 4

在这个模型中,既如模型 3 那样考虑图像像素不再被两个固定的极端值(对 8 比特灰度图,分别是 0 和 255)所影响(污染),而是被两个极端的数值范围所影响;又类似于从模型 1 到模型 2 的扩展那样,不再设这两个数值范围的概率相同(但仍如模型 2 那样设噪声密度是椒噪声密度与盐噪声密度之和, $P = P_a + P_b$ (且 $P_a \neq P_b$),并设它们的宽度分别为 W_a 和 W_b 。这样一来,如果设在位置 (x, y) 的像素 $f(x, y)$ 受噪声影响后变为 $g(x, y)$,则此时模型 4 的概率密度函数为

$$p^{(4)}(z) = \begin{cases} (P_a/2)W_a & 0 \leq z < W_a \\ 1 - P & z = g(x, y) \\ (P_b/2)W_b & 255 - W_b < z \leq 255 \end{cases} \quad (5.3.4)$$

可见模型 4 是最通用或最一般的模型。

2. 噪声检测

为检测受到脉冲噪声影响的像素,可以使用一种称为“边界判别噪声检测”(BDND)的方法[Ng 2006]。这个方法使用局部直方图来自适应地确定无噪声像素和有噪声像素之间的决策边界。具体来说,它对噪声图像中的每个像素都检查其是否被噪声所污染,并输出一幅与噪声图像对应的二值图像,其中 0 代表对应像素没有被污染,而 1 代表对应像素被污染了。为进行这样的判断,对每个像素选一个以其为中心的邻域,并根据对邻域像素的计算,利用两个阈值把所有像素分成三个聚类,分别是低灰度像素类、中间灰度像素类以及高灰度像素类。这里两个阈值 T_a 和 T_b 分别用于将受椒噪声影响的像素与未受污染的像素分开以及将受盐噪声影响的像素与未受污染的像素分开。具体说来,考虑像素 $g(x, y)$,如果 $0 \leq g(x, y) \leq T_a$,则把 $g(x, y)$ 划分到低灰度像素类;如果 $T_b < g(x, y) \leq 255$,则把 $g(x, y)$ 划分到高灰度像素类;如果 $T_a < g(x, y) < T_b$,则把 $g(x, y)$ 划分到中间灰度像素类。分类的结果可以写成

$$C[g(x, y)] = \begin{cases} \text{椒噪声} & g(x, y) \leq T_a \\ \text{无噪声} & T_a < g(x, y) \leq T_b \\ \text{盐噪声} & g(x, y) > T_b \end{cases} \quad (5.3.5)$$

很明显,如果 $g(x, y)$ 被划分到中间灰度像素类,即其灰度值不是极端值,则它应按没有被污染来处理;如果 $g(x, y)$ 被划分到低灰度像素类或高灰度像素类,则它很有可能是受噪声污染的像素。这里设原始图像不是曝光严重不足或严重过度的图像,即各种灰度的总体分布是比较均衡的。在这样的条件下,脉冲噪声会导致像素邻域直方图的两端有较高的峰,这两个峰与原始图像中各自邻近的直方条之间有较明显的谷。这两个峰与两个谷之间的部分就构成前述的三个聚类。

根据上面的分析,把噪声检测步骤归纳如下:

- (1) 对有噪声图像中的每个像素 $g(x, y)$,以其为中心,选择一个较大的窗口作为该像素的邻域;
- (2) 将窗口中的像素根据灰度排序组成一个灰度值矢量 $\mathbf{V}_g$,并确定序列的中值 m ;
- (3) 计算 $\mathbf{V}_g$ 的差分矢量 $\mathbf{V}_d$,即序列中前后相邻两个像素的灰度差所组成的矢量;
- (4) 在 $\mathbf{V}_d$ 中分别确定对应 $[0, m]$ 和 $[m, 255]$ 两个区间范围具有最大值的像素,将这两个像素的灰度值作为聚类划分的阈值 T_a 和 T_b ;
- (5) 根据确定的阈值 T_a 和 T_b ,将处于窗口中心的像素根据式(5.3.5)划分到三个类别中;
- (6) 如果处于窗口中心的像素属于中间灰度像素类,即认为它是无噪声的;
- (7) 如果处于窗中心的像素属于低灰度像素类或属于高灰度像素类,则用一个较小的窗口再按步骤(2)到步骤(5)进行一次计算和判断。

可见,对根据边界判别噪声检测而判断出属于低灰度像素类或高灰度像素类的像素要进行两次计算,第 1 次用一个较大的窗口,第 2 次用一个较小的窗口,以实现从粗到细的判断。这两个窗口的尺寸可根据经验选择,例如,[Ng 2006]中将较大的窗口选为 21×21 ,而将较小的窗口选为 3×3 。

3. 噪声适应滤波

检测出噪声像素后,需要进行滤波以消除噪声。这里可使用噪声适应滤波器[Eng 2001]。该滤波器从最小滤波窗口尺寸开始,如果窗口中的噪声密度比较大,则扩大窗口继续计算。设用 N 代表窗口中无噪声像素的数量,用 S 代表窗口中所有像素的数量,用 W_l 代表窗口边长

的当前尺寸,用 W_M 代表窗口边长的最大尺寸,则窗口尺寸的迭代选择步骤为

- (1) 初始化 $W_l = 3$;
- (2) 计算当前窗口中的 N ;
- (3) 如果 $(N < S) \text{ OR } (N = 0)$, 则 $W_l = W_l + 2$;
- (4) 如果 $W_l \leq W_M$, 则返回步骤(2); 否则迭代结束。

在迭代选择前,需先确定最大允许的窗口尺寸,以避免过度模糊图像。该尺寸与噪声密度有关,这里可根据第一次计算得到的矢量 V_d 里中值为 1 的数量来确定,即将窗中为 1 的元素除以窗中尺寸看作噪声密度,根据表 5.3.1 来经验地选择。

表 5.3.1 最大窗口尺寸的选择

噪声密度范围	最大窗口尺寸
$0\% < P < 20\%$	3×3
$20\% < P < 40\%$	5×5
$P > 40\%$	7×7

最后,在滤波窗口 $W_l \times W_l$ 里计算中值:

$$g_e(x, y) = \text{median}_{(s, t) \in W} \{g(x - s, y - t)\} \quad (5.3.6)$$

其中

$$W = \{(s, t) \mid -(W_l - 1)/2 \leq s, t \leq (W_l - 1)/2\} \quad (5.3.7)$$

这里可将中心像素排除在排序操作之外,因为进入滤波的都是有噪声的像素,将中心像素排除在外会得到失真较小的结果。

5.3.2 基于开关的自适应加权均值滤波器

前述使用边界判别噪声检测方法需要对图像中每个像素进行,在第一次迭代计算时使用了尺寸为 21×21 的较大窗口,所以需要较大的计算量。为克服这个问题,可以使用基于开关的自适应加权均值(SAWM)滤波器。它将方向差分噪声检测器与自适应加权均值滤波器相结合来消除图像中的噪声[Zhang 2009a]。

1. 方向差分噪声检测器

设以噪声图像 $g(x, y)$ 中像素位置 (x, y) 为中心的正方形窗口为 $W(x, y)$, 窗口边长为 L , 则 $W(x, y) = \{(x + s, y + t) \mid -(L - 1)/2 \leq s, t \leq (L - 1)/2\}$ 。如果将窗口中的像素(按增或减)排序,则噪声像素主要集中在序列的头和尾两端。如果用 g_k 代表序列中的第 k 个像素,则可将窗口中的噪声候选像素写成

$$N(x, y) = \{(x + s, y + t) \mid (x + s, y + t) \in W(x, y) \wedge (g_{x+s, y+t} \leq g_r \vee g_{x+s, y+t} \geq g_{L \times L - r + 1})\} \quad (5.3.8)$$

其中, r 是根据噪声种类选定的整数,满足 $1 \leq r \leq (L^2 - 1)/2$ 。

在图像中,沿同一边缘方向的像素常具有接近的像素值。为利用这个特性以便将边缘与脉冲噪声区别开,可将检测窗口分解成 4 个方向子窗口。对边长 $L = 3$ 的分解结果可见图 5.3.1。对更大的窗口,已有仿真表明:更多方向的分解只能增加很少的噪声检测准确度,但计算代价的增加更多。所以只考虑 4 个方向在实际中比较合适。用以消除噪声的 4 个方向子窗口可写为

$$W^{(1)}(x, y) = \{(x, y + s) \mid (x, y + s) \in W(x, y) \wedge (x, y + s) \notin N(x, y)\} \quad (5.3.9)$$

$$W^{(2)}(x, y) = \{(x + s, y - s) \mid (x + s, y - s) \in W(x, y) \wedge (x + s, y - s) \notin N(x, y)\} \quad (5.3.10)$$

$$W^{(3)}(x, y) = \{(x+s, y) \mid (x+s, y) \in W(x, y) \wedge (x+s, y) \notin N(x, y)\} \quad (5.3.11)$$

$$W^{(4)}(x, y) = \{(x+s, y+s) \mid (x+s, y+s) \in W(x, y) \wedge (x+s, y+s) \notin N(x, y)\} \quad (5.3.12)$$




图 5.3.1 对 3×3 检测窗口的方向子窗口分解

对任一个子窗口 $W^{(k)}(x, y) (1 \leq k \leq 4)$, 其中心像素与邻域像素之间差的绝对加权均值为

$$\bar{d}^{(k)}(x, y) = \begin{cases} \frac{\sum_{(x+s, y+t) \in W^{(k)}(x, y)} V(x+s, y+t) d(x+s, y+t)}{\sum_{(x+s, y+t) \in W^{(k)}(x, y)} V(x+s, y+t)} & W^{(k)}(x, y) \neq \emptyset \\ g_{L \times L - r + 1} - g_r & W^{(k)}(x, y) = \emptyset \end{cases} \quad (5.3.13)$$

其中, $\emptyset$ 代表空集, $d(x+s, y+t)$ 表示 $g(x+s, y+t)$ 与 $g(x, y)$ 之间的差, $V(x+s, y+t)$ 是 $g(x+s, y+t)$ 的权重。这里设 $V(x+s, y+t)$ 是随着 $d(x+s, y+t)$ 的绝对值增加而减少的, 以削弱大的差的绝对加权平均值的影响。仿真实验表明, $V(x+s, y+t)$ 可选择如下:

$$V(x+s, y+s) = \frac{1}{1 + |d(x+s, y+s)|^2} \quad (5.3.14)$$

令 $D(x, y)$ 代表 4 个绝对加权平均值中最小的, 即 $D(x, y) = \min_k [\bar{d}^{(k)}(x, y)]$ 。最小的 $D(x, y)$ 依赖于噪声图像的局部特征。如果中心像素被脉冲噪声所污染, $D(x, y)$ 将取一个很大的值, 即任一个子窗口中的 $g(x+s, y+t)$ 与 $g(x, y)$ 都有很大的差别, 且 4 个均值都很大。当处在平滑区域的中心像素没有受到噪声影响时, 在任一个子窗口 $W^{(k)}(x, y)$ 中的 $\bar{d}^{(k)}(x, y)$ 都会很小, 因为 $W^{(k)}(x, y)$ 中的像素具有相似的灰度值, 所以 $D(x, y)$ 的值会很小。类似地, 如果中心像素是没有受到噪声影响的像素, $D(x, y)$ 的值也会很小, 因为边缘的特性保证了 4 个均值之一会很小。

上述分析表明, 可以使用 $D(x, y)$ 作为检测脉冲噪声的一个测度。通过将 $D(x, y)$ 与一个事先确定的阈值 T 进行比较, 如果 $D(x, y) \geq T$, 则在 (x, y) 处的像素应是一个噪声像素, 此时用二值标记 $b(x, y) = 1$ 标识; 如果 $D(x, y) < T$, 则在 (x, y) 处的像素应是一个无噪声像素, 此时用二值标记 $b(x, y) = 0$ 标识。实验表明选择 $0 < T < 10$ 可以得到较好的检测效果。

2. 自适应加权均值滤波器

前面检测到的脉冲噪声可以使用自适应加权均值滤波器来消除。对在 (x, y) 处检测到的噪声像素, 可使用尺寸为 $L_g \times L_g$ 的滤波窗口。设 $N_{(x, y)}$ 为以 (x, y) 为中心的滤波窗口中的无噪声像素个数, 则滤波窗口的尺寸将会按照 $N_{(x, y)}$ 进行自适应调整。从 $L_g = 3$ 开始, 将窗口迭代地每次向 4 个方向各扩展一个像素直到 $N_{(x, y)} \geq 2$ 。相比于 BDND 滤波器将窗口迭代地扩展到 $N_{(x, y)} \geq (1/2)(L_g \times L_g)$, 自适应加权均值滤波器得到的滤波窗口要小, 计算效率要高, 细节保持能力也较好。

如果用 $U(x, y)$ 表示以 (x, y) 为中心的滤波窗口中的无噪声像素的坐标集合, 即 $U(x, y) = \{(x+s, y+t) \mid b(x+s, y+t) = 0 \wedge -(L_g - 1)/2 \leq s, t \leq (L_g - 1)/2\}$, 则滤波窗口中的无噪声像素的加权均值为

$$g'(x, y) = \frac{\sum_{(x+s, y+t) \in U(x, y)} V(x+s, y+t) g(x+s, y+t)}{\sum_{(x+s, y+t) \in U(x, y)} V(x+s, y+t)} \quad (5.3.15)$$

其中, $V(x+s, y+t)$ 是 $g(x+s, y+t)$ 的权重。这些权重的计算要基于两个像素之间的兼容度(DOC)来进行,而两个像素之间的兼容度可根据下式来确定:

$$\begin{aligned} & \text{DOC}(x+s, y+t; x+p, y+q) \\ &= \exp \left[-\frac{1}{N_{(x, y)} \sqrt{\sum_{(x+p, y+q) \in U(x, y)} [g(x+s, y+t) - g(x+p, y+q)]^2}} \right] \end{aligned} \quad (5.3.16)$$

从式(5.3.16)可知, $\text{DOC}(x+s, y+t; x+p, y+q)$ 会随着 $g(x+s, y+t)$ 和 $g(x+p, y+q)$ 之间的绝对差的减少而增加。进一步,如果有更多数量的无噪声像素其灰度值接近 $g(x+s, y+t)$,那就应该用更大的 $V(x+s, y+t)$ 以加强 $g(x+s, y+t)$ 对滤波输出的贡献。所以将 $V(x+s, y+t)$ 确定为 $g(x+s, y+t)$ 和它的邻域像素的兼容度之和:

$$V(x+s, y+t) = \sum_{(x+p, y+q) \in U(x, y)} v(x+s, y+t; x+p, y+q) \quad (5.3.17)$$

最后,基于开关的自适应加权均值滤波器的输出为

$$g(x, y) = b(x, y) g'(x, y) + [1 - b(x, y)] g(x, y) \quad (5.3.18)$$

5.3.3 进一步的改进

对前述两种方法的三个进一步改进如下[Duan 2010]。

1. 改进分类准则

基于边界判别噪声检测(BDND)的方法是一种基于统计的方法。根据 5.3.1 小节中的噪声检测步骤可知,为判断噪声图像中的像素是否为有噪声(污染)或无噪声(没污染),使用了一个从粗到细的搜索策略。开始先使用较大的 21×21 窗口,这从统计的角度来说还比较合理。但在接下来的精炼阶段,只使用了 3×3 的窗口,这个数量级严重缺乏统计意义,所获得的决策边界可能不太可靠。例如,图 5.3.2 给出从被 20% 的椒盐噪声所污染的 Lena 图像中抽取了两个 7×7 的窗口,对它们借助 BDND 方法进行检测都会产生错误的分类。其中,对图 5.3.2(a)的检测会产生虚警结果,而对图 5.3.2(b)的检测会产生漏检结果。

12	7	9	9	5	255	39
9	7	5	7	4	5	30
4	5	9	8	4	9	39
4	5	5	4	4	0	255
3	255	4	4	4	16	255
11	6	5	255	7	15	255
0	4	8	9	255	78	118
(a)						
119	124	119	118	125	255	115
122	116	118	0	0	255	118
121	117	123	255	118	115	115
255	123	255	255	255	120	255
122	120	255	255	119	116	120
116	120	0	119	118	120	119
121	125	125	255	119	122	0
(b)						

图 5.3.2 使用 BDND 方法会产生错误分类的两个示例

为克服错误分类的问题,可以将式(5.3.5)的分类规则改为

$$C[g(x, y)] = \begin{cases} \text{椒噪声} & g(x, y) \leq \min(T_a, W) \\ \text{盐噪声} & g(x, y) \geq \max(T_b, 255 - W) \\ \text{无噪声} & \text{其他} \end{cases} \quad (5.3.19)$$

式(5.3.19)将有关噪声特性的先验知识嵌入分类器中,从局部直方图计算出来的决策边界将有机会得到调整。其中强度不位于“噪声”间隔范围内的无噪声像素将没有机会进入第二次迭代计算。

2. 改进窗口设计

为了提高决策边界的可靠性,在第二次迭代中简单地扩大窗口大小显然并不是明智的选择,因为这种操作有可能将窗口扩展得过大而导致计算效率的降低。这里可考虑借助 5.3.2 小节中在 4 个代表性方向上准确量化当前像素与其邻域像素之间强度差的方法。不过考虑到准确性和计算效率,将 4 个窗口尺寸选取为 7×7 重新进行了设计,如图 5.3.3 所示。

0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	0	0	0	0	0	0	0	0	-1	-1	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	0
-1	-1	-1	6	-1	-1	-1	-1	0	0	0	6	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	6	0	0	0
0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	0	0	0	-1	0	0	0	0	0	0	0	0	0	-1	0	0
0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	0	0	0	-1	0	0	0	0	0	0	0	0	0	0	-1	0
0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	-1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1

图 5.3.3 4 个尺寸为 7×7 的窗口

将这些窗口作为与噪声图像进行卷积的模板,对每个像素可得到 4 个卷积结果。可以用卷积值的绝对值作为当前像素邻域强度均匀性 H 的度量。这种计算策略可以表述为

$$H^{(k)}(x, y) = |g(x, y) \otimes W_c^{(k)}(x, y)| \quad k = 1, 2, 3, 4 \quad (5.3.20)$$

其中, $W_c^{(k)}(x, y)$ 代表第 k 个卷积模板。

3. 改进决策规则

在 5.3.2 小节中,仅使用了 4 个窗口的绝对加权平均值中的最小值。因为强度均匀性信息是存在于所有 4 个窗口中的,所以这种决策规则没有能充分利用所有的检测信息。另外,仅通过将最小值与给定阈值进行比较来确定当前像素是否损坏,会趋向于仅检测孤立的脉冲噪声像素。如果噪声密度比较高,则常出现特定类型的脉冲噪声(“盐噪声”或“椒噪声”)会沿着特定方向粘连而形成簇。在这些情况下,前述决策规则将会完全失败。为克服这个问题,可以同时使用 4 个窗口里绝对加权平均值中的最大值和最小值,以提供更可靠的决策。最大值和最小值的计算如下:

$$D^{(\max)}(x, y) = \max\{H^{(1)}(x, y), H^{(2)}(x, y), H^{(3)}(x, y), H^{(4)}(x, y)\} \quad (5.3.21)$$

$$D^{(\min)}(x, y) = \min\{H^{(1)}(x, y), H^{(2)}(x, y), H^{(3)}(x, y), H^{(4)}(x, y)\} \quad (5.3.22)$$

最终的分类规则如下:如果 $D^{(\min)}(x, y) > T_l$ 或 $D^{(\max)}(x, y) - D^{(\min)}(x, y) > T_h$, 则判断像素 $g(x, y)$ 损坏;否则像素 $g(x, y)$ 无噪声。这里, T_l 和 T_h 是两个预先定义的阈值(实验值分别为 $5/255$ 和 $1/255$)。

最终分类规则的逻辑如下:

- (1) 如果当前像素对应于孤立的脉冲噪声,则 4 个卷积值中的每一个都必然很大;
- (2) 如果在当前像素的邻域中只有很少的噪声,则所有 4 个卷积值都必然很小,并且这些值之间的差异不那么明显;
- (3) 如果当前像素未损坏但被分类为损坏类别,则 4 个卷积值之间的差异应低于一定水平,因为脉冲噪声在给定图像上是均匀分布的。

4. 效果比较

对前面三种方法在一些公开图像上叠加脉冲噪声进行了仿真实验比较。

对每幅测试图像,分别选择噪声密度 10%、20%、30%、40%、50%、60%、70%、80%、

90%,对每种噪声密度叠加20次并进行20次检测,然后取20次结果的平均值作为最终结果。所用的评价测度是漏检(有噪声未被检测到)像素数量和虚警(无噪声被判断为有噪声)像素数量。它们都可借助将检测值与真值比较而获得。

表5.3.2和表5.3.3分别给出对Lena图像和Baboon图像叠加噪声密度20%、40%、60%、80%、90%得到的检测结果。

表 5.3.2 三种方法对 Lena 图像中噪声的检测结果

噪声密度	漏检			虚警		
	BDND	SAWM	改进	BDND	SAWM	改进
20%	0	0	0	2	0	0
40%	0	0	0	5	0	0
60%	0	0	0	6	0	0
80%	21	0	0	10	0	0
90%	190	0	0	5	0	0

表 5.3.3 三种方法对 Baboon 图像中噪声的检测结果

噪声密度	漏检			虚警		
	BDND	SAWM	改进	BDND	SAWM	改进
20%	0	6	0	30	51	4
40%	0	9	0	29	2	3
60%	0	8	0	24	1	1
80%	6	5	0	21	1	1
90%	272	2	0	16	0	1

5.4 结合深度学习的图像去噪

随着深度学习技术的发展,其在图像去噪中的应用也越来越广泛。深度网络已被用于提取噪声的特性,用于获取去噪图像中的上下文信息,用于实现从噪声空间到原始无噪空间的图像映射,用于进行去噪效果的质量控制等。下面给出几个应用示例,主要介绍其原理和流程。

5.4.1 非开关随机值脉冲噪声消除

脉冲噪声可分为两类:固定值脉冲噪声(FVIN)和随机值脉冲噪声(RVIN)。相对于前几节主要介绍的 FVIN 噪声,RVIN 噪声像素的亮度值可以是图像像素点亮度值的允许范围内的任何值。该值通常与邻域中像素点的亮度值相差不大,很难区分。因此,RVIN 噪声的检测和去除更具挑战性。

使用深度卷积神经网络(DCNN)构建的非开关 RVIN 的降噪模型在降噪效果和执行效率方面通常比主流的开关 RVIN 更好,这种基于训练的(数据驱动的)降噪模型的性能受到其能否准确地确定降噪图像中噪声干扰的严重程度(即数据依赖性问题)的限制。

为了解决数据依赖性问题,已经提出了一种基于浅卷积神经网络的快速 RVIN 噪声比估计(NRE)模型[徐 2020]。这里,将估计出的噪声比用作预测指标,以测量噪声引起的对图像干扰程度。首先通过在大量训练集上训练,获得 NRE 预测模型。其次将所提出的 NRE 预测模型与去噪卷积神经网络(DnCNN)相结合,所构建的非开关降噪算法可以针对特定间隔自适应地调用相应的预训练深度降噪模型(训练图像集中的噪声比值的范围被限制在较窄的范围

内),从而有效地取得高质量的降噪效果。

所使用的网络结构如图 5.4.1 所示。所构建的 NRE 噪声比预测模型的输入是 $n \times n$ 的噪声块,它通过多个卷积层(每个卷积层使用 $3 \times 3 \times 16$ 的卷积核来生成中间特征图),使用 ReLU 激活函数来提取特征,并结合池化和全连接层(FC)来降低维数以获得最终的噪声比值。




图 5.4.1 NRE 噪声比估计模型的网络结构

5.4.2 强噪声图像去噪

为了提高在强噪声(特定高斯噪声和随机高斯噪声)环境中图像去噪的质量,可以采用一种基于对称扩展卷积残差网络的算法[盖 2020]。在强噪声环境中,图像内部可用的有效信息相对较少。因此,在网络训练过程中,有必要更充分地挖掘和利用图像的有效信息来提取和学习图像特征。

算法的总体流程如图 5.4.2 所示,共有 10 层。在设计中,依次考虑了以下因素:




图 5.4.2 强噪声图像去噪方法流程图

(1) 使用**泄漏 ReLU** 函数,可以在网络训练过程中更好地保留图像的有效信息,并获得最佳的去噪效果。

(2) 使用**批归一化**(BN),可用于解决网络内协变量的传递,克服深度神经网络难以训练的缺点,并有效防止梯度分散。它还可以加快训练过程中的收敛速度,提高模型精度,降低模型初始化的敏感性。

(3) 使用扩展卷积技术,在不增加网络计算负担的情况下增加网络的感受野,从而平衡神经网络感受野的大小和网络的深度。这使网络能获得并充分利用去噪图像中的上下文信息并可以用于修复去噪图像中的受损像素,完成图像去噪任务。

(4) 使用残差学习策略,以使得深度卷积神经网络易于训练,从而可以更好地提高图像分类和目标检测的准确性。

5.4.3 基于多通道 GAN 的图像去噪

这里采用的去噪模型如下。令 f 表示噪声图像, h 表示原始无噪图像, 去噪是确定一个从噪声空间到原始空间的映射:

$$M: f \rightarrow h \quad (5.4.1)$$

可以借助生成对抗网络(GAN)来实现这种映射。一种基于多通道 GAN 的图像去噪方法如下[王 2021]。首先将噪声图像分离为 RGB 三通道分别处理。这里对各通道使用了相同的网络结构, 以尽可能保持融合后各通道的细节信息。图 5.4.3 给出了单个通道中的算法流程框图。生成器 G 的输入是噪声图像, 输出则是去噪图像 $G(f)$; 判别器 D 的输入是原始图像 h 及去噪图像 $G(f)$, 输出则为一个二值判断, 表示去噪图像与原始图像的相似性。基于所构造的复合损失函数交替迭代训练判别及生成网络, 使 $G(f)$ 渐次逼近真实图像, 直到使 D 无法准确区分原始及生成图像。最后加权融合各个通道的输出, 以获得最终去噪图像。




图 5.4.3 基于 GAN 的图像去噪框图

这里的生成网络由具有编码/解码器结构的全卷积神经网络 U-net 及 ResNet 构建, 以提取深度特征进而避免丢失细节信息。而判别网络基于全卷积神经网络构建, 其中将传统 CNN 中全连接层替换为卷积层, 以获得像素级分类从而提升判别精确性。

复合损失函数综合考虑了对抗损失、MSE 损失和感知损失。借助对抗损失, 通过反向调节生成器及判别器, 从而提升生成网络的生成图像与原始图像之间的相似性, 进而改善图像去噪性能。常用的目标函数可表示为

$$\min_G \max_D L_{\text{GAN}}(D, G) = E_{h \sim P_h} [\log D(h)] + E_{f \sim P_f} [\log(1 - D(G(f)))] \quad (5.4.2)$$

其中, $E(\cdot)$ 为期望算子, $\log D(h)$ 为判别器正确识别真实图像的概率, $\log[1 - D(G(f))]$ 表示 D 将生成图像识别为虚假图像的概率。

仅使用对抗损失有可能导致高频伪影。为此, 结合具有均值回归特性的 MSE 损失以缓解细节平滑效应。MSE 损失可表示为

$$L_{\text{MSE}} = \|G(f) - h\|^2 \quad (5.4.3)$$

借助 MSE 损失训练网络易产生图像模糊而导致主观信息缺失, 所以又引入了可以度量生成图像与原始图像在感知特征空间距离的感知损失, 以保持主观特征信息:

$$L_{\text{VGG}} = E_{(f, h)} \|C[G(f)] - C(h)\|^2 \quad (5.4.4)$$

其中, $E(\cdot)$ 代表预训练 VGG-19 网络的最后卷积层的输出。

将 3 种损失度量结合起来(如使用加权和), 就可以构造出能体现去噪效果、内容完整性以及主观视觉效果的复合损失函数。

5.4.4 地震图像中噪声滤波结果的分类

地震成像是地下油气勘探的主要技术。原始地震数据常会被噪声和不需要的反射严重污染, 需要在进一步处理之前去除。因此, 噪声消除需在早期阶段进行的, 通常在采集数据时进

行。遥感图像在数字化和传输过程中经常受到噪声的影响。去噪是提高图像质量的一种不可或缺的方法[吴 2020]。

为了使去噪过程更有把握,需要进行质量控制(QC)。它可以确保不需要对昂贵的数据进行重新采集。为此,提出了一种构建自动质量控制系统的监督学习方法[Mejri 2020]。质量控制是一种基于属性的分类器,它被训练为对三种类型的去噪结果进行分类(理想=去噪良好;重度=去噪过度,图像产生失真;轻度=去噪不足,图像中残留噪声),从数据中计算属性,并以地球物理学方式表示,以用于对去噪质量进行统计测量。

实验结果表明,某些属性在不同类型的去噪之间显示出良好的视觉分离水平,尤其是重度的去噪。轻度去噪和理想去噪的属性簇很接近,因为它们反映了先前对两种去噪之间细微差异的观察。

在该系统中,使用了多层感知器(MLP)进行分类。这里基于一个基本假设,即在没有正则化的情况下,随着深度的增加,最优 MLP 的结构趋于过拟合。所以要采用安全 MLP 构建策略,以最小验证的交叉熵误差来构建多层感知器模型。

图 5.4.4 描述了一个一对多(一 vs. 多)的二进制分类过程的流程图。使用提升聚合策略将训练集和验证集拆分(分裂)为大小相等的 K 个子集。训练和验证子集被转换为 $N=3$ 个二进制集合。然后,使用二进制 MLP 生成器来预测所有二进制决策子空间。最后,预测的类别成员被反馈给投票系统,该投票系统根据多数投票决定类别,从而产生更准确的分类结果。




图 5.4.4 多类 MLP 生成器决策的策略和流程

总结和复习

随堂测试

