

基于 PM 扩散的红外焦平面阵列神经网络非均匀校正算法

杨 硕 赵保军 毛二可 唐林波*
(北京理工大学电子与信息学院 北京 100081)

摘要: 该文针对红外图像中含有非均匀性噪声和高斯噪声的退化模型,提出了一种基于各向异性 (Perona Malik, PM)扩散的神经网络非均匀校正(PM-NN-NUC)算法。建立了关于非均匀校正的极小化模型。通过对新模型的最陡下降方程和偏微分方程的推导,可以看出 PM-NN-NUC 算法利用了神经网络校正和 PM 扩散在滤波过程中的相似性,不仅直接用于产生神经网络校正的期望值,还作用于计算迭代步长,而校正系数又反作用于 PM 的扩散过程,更好地将 PM 扩散和神经网络校正统一地结合在一起。通过对实际含噪红外图像进行实验,证明新模型可抑制非均匀噪声,并防止图像产生退化。

关键词: 图像处理;神经网络非均匀校正法;各向异性扩散;最陡下降方程;偏微分方程;图像退化

中图分类号: TN911.73

文献标识码: A

文章编号: 1009-5896(2013)11-2744-07

DOI: 10.3724/SP.J.1146.2012.01051

Neural Network Non-uniformity Correction for Infrared Focal Plane Array Based on Perona Malik Diffusion

Yang Shuo Zhao Bao-jun Mao Er-ke Tang Lin-bo

(Electronic Information Engineering Institute, Beijing Institute of Technology, Beijing 100081, China)

Abstract: A new Neural Network Non-Uniformity Correction (PM-NN-NUC) algorithm is proposed for InfraRed Focal Plane Array (IRFPA) based on Perona Malik (PM) diffusion for the situation of degradation model both containing fix pattern noise and Gaussian noise in infrared image. A minimize model is established concerning Non-Uniformity Correction (NUC). It can be seen that PM-NN-NUC uses a similarity in the filtering process on Neural Network Non-Uniformity Correction and PM diffusion, and not only generates the expectation directly but also calculates the iterative step. Correction coefficient reacts on PM diffusion process and combines with PM diffusion and Neural Network Non-Uniformity Correction uniformly. The results of real infrared thermal image show that the proposed algorithm eliminates the fixed pattern noise effectively, but also has excellent performance for the image degraded with fade-out.

Key words: Image processing; Neural Network Non-Uniformity Correction (NN-NUC) algorithm; Perona Malik (PM) diffusion; Steepest descent equation; Partial Differential Equation (PDE); Image fade-out

1 引言

红外焦平面阵列(InfraRed Focal Plane Array, IRFPA)成像噪声^[1]主要分成带状噪声和随机噪声:带状噪声主要由红外探测器本身响应率的不均匀所产生;而随机噪声主要由信号读出和处理电路的附加噪声引起,所以在实际应用中必须进行非均匀性校正(Non-Uniformity Correction, NUC)等去噪处理。

基于定标的校正算法^[2]原理简单且易于实现,不足之处在于噪声发生漂移时需要重新标定。基于场景的校正(Scene-Based Non-Uniformity Correction, SBNUC)算法以恒定统计(Constant Statistics Non-

Uniformity Correction, CS-NUC)算法^[3]和神经网络算法^[4](Neural Network Non-Uniformity Correction, NN-NUC)为代表可以弥补以上缺陷。但这些算法存在着目标退化(fade-out)和“伪像”(ghosting artifact)等问题。为了去除鬼影, Vera 等人^[5]和施长城等人^[6]提出根据场景的空间邻域方差调整神经网络校正算法的迭代步长;刘秀等人^[7]和桑红石等人^[8]提出通过判断场景的变化是否超过运动检测阈值来决定校正系数是否更新。这两年神经网络算法在非线性和滤波领域有了突破性的发展,具有代表性的是 Vera 等人^[9]提出的基于总变分的非均匀校正算法(Total Variation Non-Uniformity Correction, TV-NUC),通过最小化 TV(Total Variation)模型求解校正系数,但是算法没有充分利用 TV 模型各向异性扩散特性,校正后图像的纹理信息丢失严重。文献[10]

提出了基于偏微分方程的自适应非均匀校正算法 (Partial Differential Equation Non-Uniformity Correction, PDE-NUC), 利用非线性滤波方法获取期望图像, 利用扩散系数保持图像的边缘特征, 但其缺点是非线性滤波过程与校正过程没有并行进行, 扩散系数的取经验值, 过分依赖非线性滤波的效果。

据此, 本文提出了一种基于 PM(Perona Malik) 模型的神经网络非均匀校正(PM-NN-NUC)算法, 建立关于非均匀校正的极小化模型。采取校正和 PM 扩散交替进行的处理思路, 实现了 PM 扩散和神经网络校正的统一结合。

2 传统的神经网络算法和 PM 模型

2.1 神经网络校正算法

Scribner 等人^[4]提出了利用神经网络来实现非均匀校正: 将像元视为神经元, 通过隐含层, 使每个神经元像水平细胞元那样与邻近的像元连接起来, 获得平均值后送到它的下层神经元去计算非均匀性, 然后采用最陡下降法对校正参数进行逐次迭代, 直至达到最佳校正状态。输入图像 $X_{i,j}$ 的非均匀校正方程可以写成

$$Y_{i,j} = G_{i,j}X_{i,j} + O_{i,j} \quad (1)$$

式中 $G_{i,j}$ 和 $O_{i,j}$ 分别为像元 (i,j) 的增益和偏置校正系数, 像元 (i,j) 期望的校正输出 $f_{i,j}$ 采用像元 (i,j) 和其四邻域的空间加权均值, 文献[11]给出了神经网络校正算法的一般形式为

$$f_{i,j} = \frac{Y_{i,j} + w_N Y_{i-1,j} + w_S Y_{i+1,j} + w_W Y_{i,j-1} + w_E Y_{i,j+1}}{1 + w_N + w_S + w_W + w_E} \quad (2)$$

其中 N, S, W 和 E 代表北南西东 4 个方向。令校正输出值与期望值之差的平方为误差信号 $e_{i,j}$, 则

$$e_{i,j} = (Y_{i,j} - f_{i,j})^2 = (G_{i,j} \cdot X_{i,j} + O_{i,j} - f_{i,j})^2 \quad (3)$$

2.2 PM 模型

针对高斯噪声退化模型 $X_{i,j,k} = Y_{i,j,k} + N_{i,j,k}$, Perona 和 Malik 于 1990 年提出了各向异性扩散 PM 模型^[12]:

$$\frac{\partial Y}{\partial t} = \text{div}[c(|\nabla Y|)\nabla Y] \quad (4)$$

其中 div 为散度算子, ∇ 为梯度算子, $||$ 表示幅度, $c(|\nabla Y|)$ 为边缘函数。

$$c(|\nabla Y|) = 1/(1 + |\nabla Y|^2/S^2) \quad (5)$$

式中 $S > 0$ 为阈值。如果 $|\nabla Y| \gg S$, $c(|\nabla Y|) \rightarrow 0$, 则扩散被抑制; $|\nabla Y| \ll S$, $c(|\nabla Y|) \rightarrow 1$, 则扩散被加强。其对应的正则化能量泛函为

$$E(Y) = \iint_{\Omega} S^2 \ln(1 + |\nabla Y|^2/S^2) \text{d}i \text{d}j \quad (6)$$

3 本文提出的基于 PM-NN-NUC 算法

对于第 k 帧像元 (i,j) , 图像退化模型可以用原始图像 $Y_{i,j,k}$ 和被污染观测图像 $X_{i,j,k}$ 的线性关系表示为

$$X_{i,j,k} = A_{i,j,k} \cdot Y_{i,j,k} + B_{i,j,k} + N_{i,j,k} \quad (7)$$

其中 $A_{i,j,k}$ 和 $B_{i,j,k}$ 是各像元 (i,j) 的增益和偏置非均匀性噪声, $N_{i,j,k}$ 是读出电路引入的加性噪声。

本文根据式(7)建立关于非均匀校正的极小化模型。考虑到增益噪声 $A_{i,j,k}$ 在时域相对于高斯噪声 $N_{i,j,k}$ 为低频噪声量, 式(7)可近似变换为

$$X_{i,j,k}/A_{i,j,k} - B_{i,j,k}/A_{i,j,k} = Y_{i,j,k} + N_{i,j,k} \quad (8)$$

式中 $X_{i,j,k}/A_{i,j,k} - B_{i,j,k}/A_{i,j,k}$ 近似为神经网络校正算法中理想的期望值 $f_{i,j,k}$, 所以退化模型即为

$$f_{i,j,k} = Y_{i,j,k} + N_{i,j,k} \quad (9)$$

在图像复原领域, 从 $X_{i,j,k}$ 中恢复 $Y_{i,j,k}$ 归结为求解式(10)的极小化模型:

$$E = \frac{1}{2} \iint_{\Omega} (\hat{Y}_{i,j,k} - f_{i,j,k})^2 \text{d}i \text{d}j + \lambda \iint_{\Omega} S^2 \ln \left(1 + \frac{|\nabla Y|^2}{S^2} \right) \text{d}i \text{d}j \quad (10)$$

式中 $\hat{Y}_{i,j,k} = \hat{G}_{i,j,k} X_{i,j,k} + \hat{O}_{i,j,k}$ 。等式右边第 1 项为保真项, 控制着估计图像 $\hat{Y}_{i,j,k}$ 与期望值 $f_{i,j,k}$ 的逼近程度。第 2 项为正则项, 作用为平滑图像从而去除噪声。 λ 为尺度参数, 在保真项和正则项中起着重要平衡作用。

离散梯度值 $\nabla \hat{Y}_{i,j,k}$ 一般用前向或者后向的一阶差分近似表示, 即

$$|\nabla \hat{Y}_{i,j,k}| = |\hat{Y}_{i,j,k} - \hat{Y}_{i-1,j,k}| + |\hat{Y}_{i,j,k} - \hat{Y}_{i,j-1,k}| \quad (11)$$

或者

$$|\nabla \hat{Y}_{i,j,k}| = |\hat{Y}_{i,j,k} - \hat{Y}_{i+1,j,k}| + |\hat{Y}_{i,j,k} - \hat{Y}_{i,j+1,k}| \quad (12)$$

以前向一阶差分为例(后向一阶差分同理), 将式(11)代入到关于 $\hat{G}_{i,j,k}$ 和 $\hat{O}_{i,j,k}$ 的偏导方程得到

$$\left. \begin{aligned} \frac{\partial E}{\partial \hat{G}_{i,j,k}} &= (\hat{Y}_{i,j,k} - f_{i,j,k})X_{i,j,k} + 2\lambda \frac{|\nabla \hat{Y}_{i,j,k}|}{1 + |\nabla \hat{Y}_{i,j,k}|^2/S^2} \cdot \left[\frac{\hat{Y}_{i,j,k} - \hat{Y}_{i-1,j,k}}{|\hat{Y}_{i,j,k} - \hat{Y}_{i-1,j,k}|} + \frac{\hat{Y}_{i,j,k} - \hat{Y}_{i,j-1,k}}{|\hat{Y}_{i,j,k} - \hat{Y}_{i,j-1,k}|} \right] X_{i,j,k} \\ \frac{\partial E}{\partial \hat{O}_{i,j,k}} &= (\hat{Y}_{i,j,k} - f_{i,j,k}) + 2\lambda \frac{|\nabla \hat{Y}_{i,j,k}|}{1 + |\nabla \hat{Y}_{i,j,k}|^2/S^2} \cdot \left[\frac{\hat{Y}_{i,j,k} - \hat{Y}_{i-1,j,k}}{|\hat{Y}_{i,j,k} - \hat{Y}_{i-1,j,k}|} + \frac{\hat{Y}_{i,j,k} - \hat{Y}_{i,j-1,k}}{|\hat{Y}_{i,j,k} - \hat{Y}_{i,j-1,k}|} \right] \end{aligned} \right\} \quad (13)$$

从式(13)可以看出求导方程的第1项和第2项均含有 $+\hat{Y}_{i,j,k}$, $-\hat{Y}_{i-1,j,k}$ 和 $-\hat{Y}_{i,j-1,k}$ 这3个因子。若令 $w_N = 1/|Y_{i,j} - Y_{i-1,j}|$, $w_W = 1/|Y_{i,j} - Y_{i,j-1}|$, $w_S = 1/|Y_{i,j} - Y_{i+1,j}| = 0$, $w_E = 1/|Y_{i,j} - Y_{i,j+1}| = 0$, 则

$$w_N(\hat{Y}_{i,j,k} - \hat{Y}_{i-1,j,k}) + w_W(\hat{Y}_{i,j,k} - \hat{Y}_{i,j-1,k}) \\ = (1 + w_N + w_W)(\hat{Y}_{i,j,k} - f_{i,j,k}) \quad (14)$$

将式(13)中第1项和第2项的相同部分 $(\hat{Y}_{i,j,k} - f_{i,j,k})$ 合并可以得到关于 $\hat{G}_{i,j,k}$ 和 $\hat{O}_{i,j,k}$ 的迭代公式为

$$\left. \begin{aligned} \hat{G}_{i,j,k+1} &= \hat{G}_{i,j,k} - \eta \left[1 + \frac{2\lambda |\nabla \hat{Y}_{i,j,k}| (1 + w_N + w_W)}{1 + |\nabla \hat{Y}_{i,j,k}|^2 / S^2} \right] \\ &\quad \cdot (\hat{Y}_{i,j,k} - f_{i,j,k}) X_{i,j,k} \\ \hat{O}_{i,j,k+1} &= \hat{O}_{i,j,k} - \eta \left[1 + \frac{2\lambda |\nabla \hat{Y}_{i,j,k}| (1 + w_N + w_W)}{1 + |\nabla \hat{Y}_{i,j,k}|^2 / S^2} \right] \\ &\quad \cdot (\hat{Y}_{i,j,k} - f_{i,j,k}) \end{aligned} \right\} \quad (15)$$

其中 η 一般取值为 10^{-8} 。由于 $1 + |\nabla \hat{Y}_{i,j,k}|^2 / S^2$ 的计算值大约为几百左右, 其与 η 的乘积近似为常量。所以PM-NN-NUC的最终梯度下降迭代方程为

$$\left. \begin{aligned} \hat{G}_{i,j,k+1} &= \hat{G}_{i,j,k} - \frac{\tau}{1 + |\nabla \hat{Y}_{i,j,k}|^2 / S^2} (\hat{Y}_{i,j,k} - f_{i,j,k}) X_{i,j,k} \\ \hat{O}_{i,j,k+1} &= \hat{O}_{i,j,k} - \frac{\tau}{1 + |\nabla \hat{Y}_{i,j,k}|^2 / S^2} (\hat{Y}_{i,j,k} - f_{i,j,k}) \end{aligned} \right\} \quad (16)$$

式中 τ 可设定为 10^{-6} 。通过上述推导和分析可见, 本文PM扩散正则化项本身就含有神经网络非均匀校正的因素, 可与神经网络校正算法共同控制校正系数的更新, 真正实现了最陡下降法求解方式的一体化。

继续求解式(10)关于 $\hat{Y}_{i,j,k}$ 的偏微分方程, 得到其离散格式为

$$\frac{\partial \hat{Y}_{i,j,k}}{\partial t} = \lambda (c_N \nabla_N \hat{Y} + c_S \nabla_S \hat{Y} + c_E \nabla_E \hat{Y} \\ + c_W \nabla_W \hat{Y}) - (\hat{Y}_{i,j,k} - f_{i,j,k}) \quad (17)$$

其中E, S, W和N代表东南西北4个方向, 扩散系数 c 和梯度 ∇ 可表示为

$$\left. \begin{aligned} c_N &= 1 / \left(1 + |\nabla_N \hat{Y}|^2 / S^2 \right), \quad c_S = 1 / \left(1 + |\nabla_S \hat{Y}|^2 / S^2 \right) \\ c_E &= 1 / \left(1 + |\nabla_E \hat{Y}|^2 / S^2 \right), \quad c_W = 1 / \left(1 + |\nabla_W \hat{Y}|^2 / S^2 \right) \end{aligned} \right\} \quad (18)$$

其中 $\nabla_N \hat{Y} = \hat{Y}_{i-1,j} - \hat{Y}_{i,j}$, $\nabla_S \hat{Y} = \hat{Y}_{i+1,j} - \hat{Y}_{i,j}$, $\nabla_W \hat{Y} =$

$\hat{Y}_{i,j-1} - \hat{Y}_{i,j}$, $\nabla_E \hat{Y} = \hat{Y}_{i,j+1} - \hat{Y}_{i,j}$ 。扩散门限 S 一般采用自适应估计方法, 即当前邻域内梯度的绝对偏差中值。

$$S = M \left[\left| \nabla \hat{Y} - M \left(\left| \nabla \hat{Y} \right| \right) \right| \right] / 0.6745 \quad (19)$$

式中 M 为中值滤波。常数的设置是因为0均值和1方差的正态分布的绝对偏差中值为0.6745。

$\hat{Y}_{i,j,k} - f_{i,j,k}$ 可以进行逆推, 并令 $w_N = c_N$, $w_S = c_S$, $w_W = c_W$ 和 $w_E = c_E$, 得到

$$\hat{Y}_{i,j,k} - f_{i,j,k} \\ = - \frac{c_N \nabla_N \hat{Y} + c_S \nabla_S \hat{Y} + c_W \nabla_W \hat{Y} + c_E \nabla_E \hat{Y}}{1 + c_N + c_S + c_W + c_E} \quad (20)$$

可以得到偏微分迭代方程为

$$\hat{Y}_{i,j,k+1} = \hat{Y}_{i,j,k} + \mu \left[\lambda + \frac{1}{1 + c_N + c_S + c_W + c_E} \right] \\ \cdot (c_N \nabla_N \hat{Y} + c_S \nabla_S \hat{Y} + c_W \nabla_W \hat{Y} + c_E \nabla_E \hat{Y}) \quad (21)$$

式中 μ 一般取值为 10^{-9} 。由于 $1 + c_N + c_S + c_W + c_E$ 数值范围为 $1 \sim 5$, 对比 μ 值的大小可以忽略, 这样 $\mu / (1 + c_N + c_S + c_W + c_E)$ 为迭代步长, PM-NN-NUC的最终偏微分迭代方程为

$$\hat{Y}_{i,j,k+1} = \hat{Y}_{i,j,k} + \frac{\mu}{1 + c_N + c_S + c_W + c_E} \\ \cdot (c_N \nabla_N \hat{Y} + c_S \nabla_S \hat{Y} + c_W \nabla_W \hat{Y} + c_E \nabla_E \hat{Y}) \quad (22)$$

新模型与PM模型具有相似的偏微分方程形式, 新模型的迭代步长更能精确控制噪声图像的进化和还原效果, 可与PM算法共同控制无噪图像的更新, 实现了偏微分求解方式的一体化。

PM-NN-NUC算法流程如下(用符号 $\hat{Y}_{i,j,k}^{\text{NUC}}$ 和 $\hat{Y}_{i,j,k}^{\text{PM}}$ 表示校正估计值和PM扩散值):

(1) 初始化各探测元的增益系数估计 $\hat{G}_{i,j,0}$ 和偏置系数估计 $\hat{O}_{i,j,0}$ 。

(2) 对于输入噪声图像 $X_{i,j,k}$ 利用增益系数 $\hat{G}_{i,j,k}$ 和偏置系数 $\hat{O}_{i,j,k}$ 计算校正估计值 $\hat{Y}_{i,j,k}^{\text{NUC}}$:

$$\hat{Y}_{i,j,k}^{\text{NUC}} = \hat{G}_{i,j,k} X_{i,j,k} + \hat{O}_{i,j,k} \quad (23)$$

(3) 根据校正估计值 $\hat{Y}_{i,j,k}^{\text{NUC}}$ 计算一步PM扩散结果 $\hat{Y}_{i,j,k}^{\text{PM}}$, 并作为新算法的最终输出结果, 其表达式为

$$\hat{Y}_{i,j,k}^{\text{PM}} = \hat{Y}_{i,j,k}^{\text{NUC}} + \frac{\mu}{1 + c_N + c_S + c_W + c_E} \\ \cdot (c_N \nabla_N \hat{Y}_{i,j,k}^{\text{NUC}} + c_S \nabla_S \hat{Y}_{i,j,k}^{\text{NUC}} \\ + c_W \nabla_W \hat{Y}_{i,j,k}^{\text{NUC}} + c_E \nabla_E \hat{Y}_{i,j,k}^{\text{NUC}}) \quad (24)$$

(4) 当 $k > \max K$ (最大迭代次数) 或者 $\delta \leq \xi$ (迭代终止阈值) 时, PM-NN-NUC算法停止迭代, 否则进入步骤(5)。其中迭代误差 δ 定义为

$$\delta = \frac{\sum_{i=1}^M \sum_{j=1}^N (\hat{Y}_{i,j,k+1}^{\text{PM}} - \hat{Y}_{i,j,k}^{\text{PM}})^2}{\sum_{i=1}^M \sum_{j=1}^N (\hat{Y}_{i,j,k}^{\text{PM}})^2} \quad (25)$$

(5) 令 PM 扩散结果 $\hat{Y}_{i,j,k}^{\text{PM}}$ 参与期望值 $f_{i,j,k}$ 的计算并对 k 值进行奇偶判断：当 k 为奇数时，令 $w_S = 0$, $w_E = 0$ ；当 k 为偶数时，令 $w_N = 0$, $w_W = 0$ 。通过最陡下降方程估计增益系数 $\hat{G}_{i,j,k+1}$ 和偏置系数 $\hat{O}_{i,j,k+1}$ ，返回第(2)步循环上述过程。最陡下降方程表达式如下：

$$\left. \begin{aligned} \hat{G}_{i,j,k+1} &= \hat{G}_{i,j,k} - \frac{\tau}{1 + \left| \nabla \hat{Y}_{i,j,k}^{\text{NUC}} \right|^2 / S^2} \left(\hat{Y}_{i,j,k}^{\text{NUC}} - f_{i,j,k} \right) X_{i,j,k} \\ \hat{O}_{i,j,k+1} &= \hat{O}_{i,j,k} - \frac{\tau}{1 + \left| \nabla \hat{Y}_{i,j,k}^{\text{NUC}} \right|^2 / S^2} \left(\hat{Y}_{i,j,k}^{\text{NUC}} - f_{i,j,k} \right) \end{aligned} \right\} \quad (26)$$

其中

$$f_{i,j,k} = \frac{\hat{Y}_{i,j,k}^{\text{PM}} + w_N \hat{Y}_{i-1,j,k}^{\text{PM}} + w_W \hat{Y}_{i,j-1,k}^{\text{PM}} + w_S \hat{Y}_{i+1,j,k}^{\text{PM}} + w_E \hat{Y}_{i,j+1,k}^{\text{PM}}}{1 + w_N + w_W + w_S + w_E}$$

4 实验结果与分析

为了测试算法的有效性，设计了模拟红外图像和实际红外图像的神经网络校正处理实验，计算机配置为：Intel 酷睿 i7 2670 qm, 基准频率为 2.2 GHz, 4 核睿频为 2.8 GHz, 内存为 4 G, 处理软件平台为 Matlab R2012(a)。

4.1 PM-NN-NUC 的单帧图像校正性能

为了客观地评价校正性能，采用如下评判标准。

第 1 个是均方根误差 RMSE(Root Mean Square Error):

$$\text{RMSE} = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (\hat{Y}_{i,j} - Y_{i,j})^2} \quad (27)$$

式中 $\hat{Y}_{i,j}$ 和 $Y_{i,j}$ 表示校正图像和理想图像。RMSE 越小，效果越好。

第 2 个是信噪比 SNR(Signal to Noise Ratio):

$$\text{SNR} = \frac{\sum_{i=1}^M \sum_{j=1}^N \hat{Y}_{i,j}^2}{\text{RMSE}^2} \quad (28)$$

SNR 用于衡量图像质量高低，降噪效果越好，则 SNR 越大。

第 3 个是图像佳数 FOM(Figure Of Merit)^[13]:

$$\text{FOM} = \frac{1}{\max\{N_r, N_i\}} \sum_{i=1}^{N_r} \frac{1}{1 + d_i^2 e} \quad (29)$$

式中 N_r 和 N_i 表示检测边缘和理想边缘点数， d_i 表示第 i 个检测边缘与最近的理想边缘之间的欧氏距离， e 为常数。FOM 越接近于 1 表明检测到边缘越理想。

第 4 个是结构相似度 SSIM(structure similarity):

$$\text{SSIM}(I, J) = [l(I, J)]^\alpha \cdot [c(I, J)]^\beta \cdot [s(I, J)]^\gamma \quad (30)$$

式中 I, J 表示待比较的两幅图像， $l(\cdot)$, $c(\cdot)$ 和 $s(\cdot)$ 表示亮度、对比度和结构比较函数，所有参数根据文献[14]的方法设置，SSIM 越接近于 1 表明处理结果越理想。

最后一个是非均匀性 NU(Non-Uniformity):

$$\text{NU} = \frac{1}{\bar{Y}_{i,j}} \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (Y_{i,j} - \bar{Y}_{i,j})^2} \quad (31)$$

式中 $Y_{i,j}$ 为校正后图像输出灰度， $\bar{Y}_{i,j}$ 为阵列的空间响应均值。

为了检验 PM-NN-NUC 算法单帧去噪的能力，采用了从实际 128×128 规格 LW MCT IRFPA 所采集的 1 幅图像，场景为室外楼顶处的霓虹灯广告“源”字及其背后的支架。本文采用传统的 NN-NUC, TV-NUC, PDE-NUC 和 PM-NN-NUC 算法进行实验，各算法的增益系数和偏移系数初始值为 1 和 0，最大迭代次数 $\max K$ 设定为 600 次，迭代终止阈值 ξ 选用为实验值 2×10^{-3} 。NN-NUC 算法的迭代步长选为 10^{-6} ，PDE-NUC 算法的校非线性扩散的迭代步长为 0.25，迭代步长为 10^{-5} ，扩散系数为 100。根据上述 5 个评价标准进行性能比较。图 1 给出了几种算法的校正结果，其中图 1(a)为噪声图像，图 1(b),1(c),1(d),1(e)分别是 NN-NUC 算法，TV-NUC 算法，PDE-NUC 算法和本文算法迭代 100 次后的校正结果，图 1(f)是两点定标校正结果。

从图 1 可以看出，由于 NN-NUC 算法的期望值为邻域平均，所以随着迭代次数增加，图像出现了模糊和退化现象；TV-NUC 算法校正后图像的边缘得到保留，但是“源”字部分的纹理发生退化。这是由于 TV-NUC 算法期望值的计算以线性平均运算为主的缘故。PDE-NUC 算法利用了各向异性扩散特性，校正后图像的边缘和纹理保持的很好。但存留了大量的剩余噪声。这是由于校正期望值主要取决于非线性滤波的结果，一旦非线性滤波效果不好，直接影响整幅图像的校正质量。而本文提出的新算法经过多次迭代，“源”字的质感依然存在，旁边的栏杆也清晰可见。校正后图像的剩余噪声最少，这是由于新算法中校正和扩散过程是交替进行，扩散系数和迭代步长又是自适应调整的，所以校正效果要优于其它几种算法。

图 2 为不同方法进行 100 次迭代后所得到的 RMSE 曲线，以两点校正后的图像作为参考的理想图像，如图 1(f)所示。可以看出本文提出的算法只经过二十多次迭代就基本达到稳定，且对应的




图 1 单帧红外图像校正结果比较

RMSE 也最小, 校正后的图像与真实图像最接近。利用信噪比 SNR 来量化对比不同校正方法经 100 次迭代后的校正效果。实验结果如图 3 所示, 本文提出的算法校正后图像对应的 SNR 值最大, 因此校正效果最好。

表 1 为各算法的 FOM, SSIM 和 NU 参数性能比较, 依然以两点校正后的图像作为参考的理想图像。比较结果表明本文提出的新算法边缘保留程度最高, 与理想图像的结构最相似。NN-NUC 算法的剩余非均匀性最低, 但是其校正后的图像整体模糊,

最不理想。所以 PM-NN-NUC 算法的校正效果最好。

4.2 PM-NN-NUC 的多帧图像抑制鬼影性能

为了描述 NN-NUC 算法中引起鬼影的原因, 本文采用另外一组采用 HgCdTe 长波 IRFPA 所采集的 200 帧红外图像序列进行试验, 场景内容是室外天空冷背景下的飞机目标。图 4 为 NN-NUC 算法中边缘点(64,59)的偏移校正系数。可以看出, 偏移校正系数在第 120 帧图像处发生了明显的异常。图 5 为第 120 帧原始图像和 NN-NUC 算法校正后图像。从图 5(b)上可以看出校正后图像上存在鬼影。

表 1 红外图像校正结果的 FOM, SSIM 和 NU 参数性能比较

	原始图像	NN-NUC	TV-NUC	PDE-NUC	PM-NN-NUC
FOM	0.26	0.39	0.42	0.56	0.62
SSIM	0.52	0.61	0.74	0.80	0.88
NU(%)	13.32	1.26	3.22	4.35	1.57




图 2 几种算法的 RMSE 比较

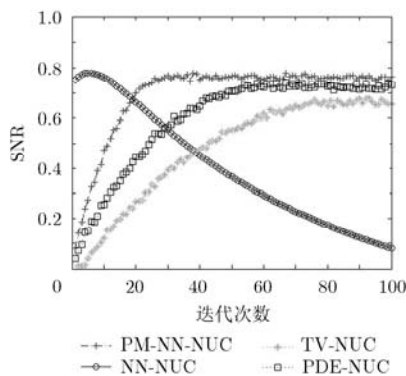


图 3 几种算法的 SNR 比较

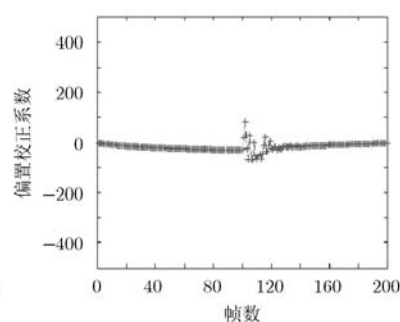


图 4 NN-NUC 算法中边缘点(64,59)的偏移校正系数




图 5 红外图像的鬼影实验

为了说明新算法 PM-NN-NUC 具有抑制鬼影的能力，本节对新算法在边缘像素(64,59)处的相关计算进行了分析。取第 100 帧校正后图像中像素(64, 59)为中心的 3×3 区域，如图 6(a)所示。图 6(b)为中心像素与邻域各像素之间的灰度差值。各向异性扩散由扩散系数控制扩散滤波处理，使得具有较大梯度值的边缘位置停止扩散，避免异常校正。图 6(c)给出了新算法在(64,59)处计算得到的北、南、西、东 4 个方向上的扩散系数，其中扩散门限为 50。通过图 6(c)可以看出由于像素(64,59)的扩散系数非常小，几乎不会产生迭代更新，所以该边缘点滤波后能保留下来。




图 6 边缘像素(64,59)的计算分析




图 7 PM-NN-NUC 算法中点(64,59)的偏置校正系数

图 7 为新算法中像素(64,59)处得到的偏移校正系数。偏移校正系数在第 120 帧图像处无异常变化。

最后比较 NN-NUC, TV-NUC, PDE-NUC 和 PM-NN-NUC 算法的去鬼影效果。都采用像素(64, 59)处偏置系数的时域变化来衡量上述 4 种算法的去鬼影能力。其比较结果如图 8 和图 9 所示，不具有去鬼影能力的 NN-NUC 算法的偏置系数更新至 100 帧左右时校正系数发生异常跳跃，从而产生鬼影。而其它具有去除鬼影能力的算法各自偏置系数的更新相对比较平稳，没有发生异常更新，因此在一定程度上抑制了鬼影产生。其中 PDE-NUC 和 PM-NN-NUC 算法的偏置系数在 100 帧左右时变化相对更加平稳，也进一步说明了扩散系数对边缘区域的滤波处理控制的更好。

5 总结

本文提出了一种基于 PM 模型的神经网络非均匀校正算法(PM-NN-NUC)，建立了关于非均匀校正的极小化模型。通过对新模型的最陡下降方程和偏微分方程的推导和分析，得出了 PM-NN-NUC 算法中存在着神经网络校正和 PM 扩散在滤波过程相似性的结论。不仅直接用于产生神经网络校正的期望值，还作用于计算迭代步长，而校正系数又反作

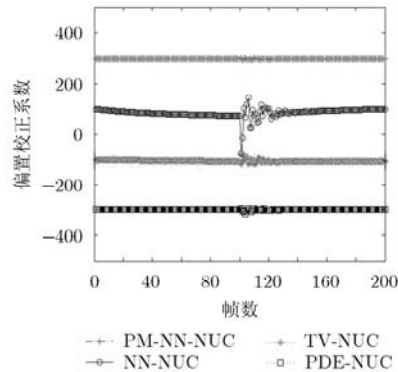


图 8 几种算法对像素(64,59)的时域偏置校正系数




图9 几种算法去鬼影能力的比较

用于PM的扩散过程，真正地实现了PM扩散和神经网络校正一体化。通过对实际非均匀性红外图像进行校正实验，证明新模型可以有效地抑制非均匀噪声和伪像产生。

参考文献

- [1] 卢兆林, 李闰龙, 李涛, 等. 基于全变分理论的红外图像去噪[J]. 激光技术, 2012, 36(2): 194-197.
Lu Zhao-lin, Li Run-long, Li Tao, *et al.* Infrared image denoising based on total variation theory[J]. *Laser Technology*, 2012, 36(2): 194-197.
- [2] 洪闻青, 杨南生, 王晓东, 等. 红外焦平面联合非均匀性校正算法[J]. 光学学报, 2011, 31(6): 81-86.
Hong Wen-qing, Yang Nan-sheng, Wang Xiao-dong, *et al.* Combined nonuniformity correction algorithm of infrared focal plane arrays[J]. *Acta Optica Sinica*, 2011, 31(6): 81-86.
- [3] Harris J G and Chiang Y M. Nonuniformity correction of infrared image sequences using the constant-statistics constraint[J]. *IEEE Transactions on Image Processing*, 1999, 8(8): 1148-1151.
- [4] Scribner D A, Sarkady K A, Krueger M R, *et al.* Adaptive nonuniformity correction for IR focal plane arrays using neural networks[C]. International Society for Optics and Photonics, San Diego, CA, USA, 1991: 100-109.
- [5] Vera E and Torres S. Fast adaptive nonuniformity correction for infrared focal-plane array detectors[J]. *EURASIP Journal on Applied in Signal Processing*, 2005(13): 1994-2004.
- [6] 施长城, 张天序, 刘慧娜, 等. 一种红外焦平面非均匀性组合校正算法[J]. 红外与毫米波学报, 2010, 29(1): 23-26.
Shi Chang-cheng, Zhang Tian-xu, Liu Hui-na, *et al.* Combinational algorithm for nonuniformity correction of infrared focal plane array[J]. *Journal of Infrared and Millimeter Waves*, 2010, 29(1): 23-26.
- [7] 刘秀, 徐超, 金伟其, 等. 基于帧间运动的神经网络非均匀性校正及其硬件实现[J]. 北京理工大学学报, 2010, 30(11): 1331-1335.
Liu Xiu, Xu Chao, Jin Wei-qi, *et al.* Neural network non-uniformity correction by means of frames motion estimation and its hardware implementation[J]. *Transactions of Beijing Institute of Technology*, 2010, 30(11): 1331-1335.
- [8] 桑红石, 袁雅婧, 张天序. 基于运动指导的红外焦平面非均匀性校正方法[J]. 中国图象图形学报, 2011, 16(9): 1577-1582.
Sang Hong-shi, Yuan Ya-jing, and Zhang Tian-xu. Non-uniformity correction of infrared focal plane array based on motion guidance[J]. *Journal of Image and Graphics*, 2011, 16(9): 1577-1582.
- [9] Vera E, Meza P, and Torres S. Total variation approach for adaptive non uniformity correction in focal-plane arrays[J]. *Optics Letters*, 2011, 36(2): 172-174.
- [10] 张天序, 袁雅婧, 桑红石, 等. 基于 PDE 去鬼影的自适应非均匀性校正算法研究[J]. 红外与毫米波学报, 2012, 31(2): 177-182.
Zhang Tian-xu, Yuan Ya-jing, Sang Hong-shi, *et al.* PDE-based deghosting algorithm for correction of nonuniformity in infrared focal plane array[J]. *Journal of Infrared and Millimeter Waves*, 2012, 31(2): 177-182.
- [11] 王炳健, 拜丽萍, 刘上乾. 红外焦平面非均匀性自适应校正算法实时实现[J]. 中国电子科学研究院学报, 2008, 3(2): 174-176.
Wang Bing-jian, Bai Li-ping, and Liu Shang-qian. Adaptive non-uniformity correction algorithm real-time implementation for IRFPA[J]. *Journal of China Academy of Electronics and Information Technology*, 2008, 3(2): 174-176.
- [12] Perona P and Malik J. Scale-space and edge detection using anisotropic diffusion[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, 12(7): 629-639.
- [13] Yu Y and Acton S T. Speckle reducing anisotropic diffusion[J]. *IEEE Transactions on Image Processing*, 2002, 11(11): 1260-1270.
- [14] 韩国强, 李永祯, 王雪松, 等. 基于修正 SSIM 的 SAR 干扰效果评估方法[J]. 电子与信息学报, 2011, 33(3): 711-716.
Han Guo-qiang, Li Yong-zhen, Wang Xue-song, *et al.* Evaluation of jamming effect on SAR based on method of modified structural similarity[J]. *Journal of Electronics & Information Technology*, 2011, 33(3): 711-716.

杨 硕: 男, 1983 年生, 博士, 研究方向为红外图像预处理、包括图像的非均匀校正和增强等技术。

赵保军: 男, 1960 年生, 教授, 博士生导师, 研究方向为多光谱图像融合、识别与跟踪的理论和技术; 高分辨图像实时压缩、恢复与传输的理论和技术; 智能图像处理的理论与技术; 激光成像与识别的理论和技术。

唐林波: 男, 1978 年生, 讲师, 硕士生导师, 研究方向为高速数字信号处理与图像处理。