

文章编号: 1672-8785(2018)07-0029-06

一种基于核回归插值的自适应 非均匀性校正算法

刘明忠 孟 军 王雨蒙 李东涛 郭 然

(中国洛阳电子装备试验中心, 河南 济源 454650)

摘 要: 针对基于神经网络的场景自适应非均匀性校正(Non-Uniformity Correction, NUC)算法在消除红外成像系统输出图像噪声时容易产生的“鬼影”现象, 提出了一种改进的自适应非均匀性校正算法, 将核回归插值技术应用到神经网络算法中, 有效降低了自适应非均匀性算法产生“鬼影”现象的概率。实验结果表明, 与传统的神经网络算法相比, 本文算法在相同条件下既能有效消除非均匀噪声, 又能大大抑制“鬼影”现象的产生。

关键词: 红外探测器; 非均匀性校正; 神经网络; 核回归; 边缘保护

中图分类号: TP391.4 **文献标志码:** A **DOI:** 10.3969/j.issn.1672-8785.2018.07.006

An Adaptive Non-uniformity Correction Algorithm Based on Kernel Regression Interpolation

LIU Ming-zhong, MENG Jun, WANG Yu-meng, LI Dong-tao, GUO Ran

(Luoyang Electronic Equipment Test Center of China, Jiyuan 454650, China)

Abstract: Since the scene adaptive nonuniformity correction (NUC) algorithm based on neural network is easy to generate the phenomenon of "ghost" when it removes the noise in the images output by infrared imaging systems, an improved adaptive nonuniformity correction algorithm is proposed. By applying kernel regression interpolation to the neural network algorithm, the probability of "ghost" phenomenon caused by the adaptive nonuniformity algorithm is reduced effectively. The experimental results show that compared with the traditional neural network algorithm, the proposed algorithm not only can eliminate nonuniformity noise effectively, but also can restrain the generation of "ghost" phenomenon greatly under the same conditions.

Key words: infrared detector; non-uniformity correction; neural network; kernel regression; edge-preserving

0 引言

红外焦平面阵列(Infrared Focal Plane Array, IRFPA)是红外成像系统的核心器件, 然而受材料和工艺水平的限制, IRFPA 的各个

探测器单元通常都会存在相应的非均匀现象, 导致红外成像系统最终输出的图像具有明显的非均匀性噪声, 进而大大制约红外成像系统的应用。因此, 在实际的工程应用中, 通常需要采用适当的 NUC 技术来消除非均匀性噪声。

收稿日期: 2018-03-27

作者简介: 刘明忠(1977-), 男, 河南南阳人, 硕士, 主要研究方向为信号处理与图像识别。

E-mail: lmz7710@163.com

目前,非均匀性校正算法总体上可以分为两类:一种是基于标准参考辐射源的校正方法^[1];另一种是基于场景的自适应 NUC 算法^[2]。在不预先对 IRFPA 进行黑体标定的条件下,后者能够根据场景变化不断调整非均匀性校正系数。

迄今为止,研究人员已经提出了多种基于场景的自适应 NUC 算法,主要包括时域高通滤波算法^[3]、恒定统计法^[4]、卡尔曼滤波算法^[5-6]以及基于神经网络的 NUC 算法^[7]等。然而,大多数基于场景的自适应 NUC 算法严重依赖于场景数据,这也是很多时候算法性能严重退化的原因。特别是如果场景中的某个目标由静止状态突然转变为运动状态,那么校正后的图像中就特别容易出现“鬼影”现象。这些缺陷也限制了基于场景的自适应 NUC 算法的应用范围。1998 年, Harris J G 等人^[8]提出了一种基于恒定统计法的 NUC 算法来尽可能地消除“鬼影”现象。他们考虑在目标移动速度非常缓慢的情况下对修正系数进行修正。Torres S N 等人^[9]提出在基于神经网络的 NUC 算法中通过自适应地选择学习速率参数来消除“鬼影”现象。然而以上提到的这些算法都没有达到预期的理想目标。

本文在基于神经网络的 NUC 算法的基础上提出了一种改进型算法,即利用可控核回归(Steer Kernel Regression, SKR)^[10]插值来代替传统神经网络 NUC 算法中的均值滤波。作为一种拥有边缘保护功能的插值算法,SKR 算法在具有强边缘时可以获得更加可靠的空间估计,进而消除由目标边缘引起的“鬼影”现象。

本文首先介绍传统神经网络 NUC 算法的基本结构,然后介绍 SKR 算法的数学原理并将其应用到 NUC 算法中,接着对所提出的改进型 NUC 算法进行性能测试和分析,并最终给出结论。

1 基于神经网络的 NUC 算法

本文提出的自适应 NUC 算法主要是在 Scribner D A 等人^[7]研究的神经网络 NUC 算法

的基础上对其进行了改进。图 1 所示为基于神经网络的 NUC 算法的基本原理。




图 1 基于神经网络的 NUC 算法的原理框图

IRFPA 中每个探测器单元的相应曲线在一定范围之内通常被认为是一个线性函数。因此,对于第 n 帧图像,位于第 i 行、第 j 列的探测器单元的输出响应 Y_{ij} 可由式(1)表示:

$$Y_{ij}(n) = g_{ij}(n) \cdot X_{ij}(n) + b_{ij}(n) \quad (1)$$

式中, $g_{ij}(n)$ 和 $b_{ij}(n)$ 分别为探测器单元相应的增益系数和偏置系数; $X_{ij}(n)$ 为探测器单元所接收到的真实红外辐射信号。可将式(1)转换为用 $Y_{ij}(n)$ 表示 $X_{ij}(n)$ 的形式:

$$X_{ij}(n) = a_{ij}(n) \cdot Y_{ij}(n) + o_{ij}(n) \quad (2)$$

式中, $a_{ij}(n)$ 和 $o_{ij}(n)$ 可以分别由增益和偏置表示:

$$a_{ij}(n) = \frac{1}{g_{ij}(n)} \quad (3)$$

$$o_{ij}(n) = \frac{b_{ij}(n)}{g_{ij}(n)} \quad (4)$$

在式(2)所描述的 NUC 模型中,每个探测器单元可以被看成是一个简单的神经网络结构,它们都是由参数 $a_{ij}(n)$ 和 $o_{ij}(n)$ 构成的简单线性模型。探测器单元的输出信号 $Y_{ij}(n)$ 可以看成是神经元的输入,而神经元的输出则是我们期望得到的真实红外信号 $X_{ij}(n)$ 。图 1 给出了基于神经网络的 NUC 算法的基本框架。这个框架最早是由 Scribner D A 等人提出的。其中,目标信号值 $T_{ij}(n)$ 通过用一个局部线性平均滤波来估计得到:

$$T_{ij}(n) = \frac{1}{4} [X_{i,j+1}(n) + X_{i-1,j}(n) + X_{i,j-1}(n) + X_{i+1,j}(n)] \quad (5)$$

误差值 $E_{ij}(n)$ 可表示为

$$E_{ij}(n) = \hat{X}_{ij}(n) - T_{ij}(n) \quad (6)$$

根据最小均方 (Least Mean Square, LSM) 误差算法, 待估参数可通过以下迭代方式进行计算:

$$a_{ij}(n+1) = a_{ij}(n) - \eta \cdot E_{ij}(n) \cdot Y_{ij}(n) \quad (7)$$

$$o_{ij}(n+1) = o_{ij}(n) - \eta \cdot E_{ij}(n) \quad (8)$$

式中, η 为参数的学习速率, 它可以控制参数 a_{ij} 和 o_{ij} 在迭代过程中的更新速度。

可以看出, 在迭代过程中, 目标信号值 $T_{ij}(n)$ 估计的精确程度会直接影响误差值 $E_{ij}(n)$ 的计算精度, 进而影响最终的 NUC 效果。因此, 获得高精度的目标信号值估计变得至关重要。

2 可控核回归插值

在 Scribner D A 等人提出的 NUC 算法中, 目标信号值 $T_{ij}(n)$ 是通过局部平均获得的。然而这种方法并没有考虑图像中强边缘的影响。图像中目标的强边缘是“鬼影”现象产生的主要原因之一。从式(5)中可以看出, 如果第 ij 个像素正好处在图像中的边缘处, 那么我们算得的目标信号值 $T_{ij}(n)$ 则会存在较大误差, 此时根据式(6)算得的误差 $E_{ij}(n)$ 将会变得非常大。这个较大的误差会直接影响后续式(7)和式(8)计算的校正参数的精度, 使得第 $n+1$ 帧的校正参数相对于第 n 帧来说具有一个较大变化。如果第 $n+1$ 帧图像的第 ij 个像素不是处在图像边缘处, 那么在此处则会产生一个伪边缘, 就像是目标移动之后的残影, 这就是“鬼影”产生的原因。

本文采用 SKR 插值方法来代替传统的局部均值滤波。核函数回归^[12]算法是一种建立在多项式回归的基础上的插值方法, 其优劣主要取决于核函数的选择。经典的核回归等价于一个自适应的局部线性滤波器, 但是其核函数的选择只考虑到图像的灰度信息, 因此对于边缘区域来说则会存在很大的缺陷。为此, Takeda H 等人^[10]考虑图像的灰度信息和结构

后提出了一种可控核回归算法, 即用局部的协方差矩阵来估计图像结果。

SKR 算法不仅考虑了数据采样点的位置和采样密度, 而且还考虑了这些采样点的灰度值特性。因此, 核的有效尺寸和形状能够根据图像特征进行局部自适应调整。这种自适应的性质如图 2 所示。图中给出了图像边缘处经典核的形状和自适应核的形状。SKR 可用式(9)描述:

$$\min_{\{\beta_i\}} \sum_{i=1}^P [y_i - \beta_0 - \beta_1^T(\mathbf{x}_i - \mathbf{x}) - \beta_2^T \text{vech}\{(\mathbf{x}_i - \mathbf{x})(\mathbf{x}_i - \mathbf{x})^T\} - \dots]^2 K_{H_i^{\text{seer}}}(\mathbf{x}_i - \mathbf{x}) \quad (9)$$

式中, $K_{H_i^{\text{seer}}}(\mathbf{x}_i - \mathbf{x})$ 为自适应核函数, 它依赖于采样点的坐标 $\mathbf{x}_i$ 、采样密度以及采样数据值 y_i 。vech($\cdot$) 为半向量化算符, 它可以将一个对称矩阵的下三角部分转换为向量形式:

$$\text{vech} \left[\begin{bmatrix} a & b \\ b & d \end{bmatrix} \right] = [a \quad b \quad d]^T$$

$$\text{vech} \left[\begin{bmatrix} a & b & c \\ b & e & f \\ c & f & i \end{bmatrix} \right] = [a \quad b \quad c \quad e \quad f \quad i]^T \quad (10)$$

H_i^{seer} 为数据自适应控制矩阵, 其定义为

$$H_i^{\text{seer}} = h\mu_i \mathbf{C}_i^{-1/2} \quad (11)$$

式中, $\mathbf{C}_i$ 为一个基于局部灰度值差异的对称协方差矩阵, 它可以有效地将核的范围沿着边缘方向扩展, 如图 2 所示。若选择 K 为高斯核, 则自适应可控核函数可以表示为

$$K_{H_i^{\text{seer}}}(\mathbf{x}_i - \mathbf{x}) = \frac{\sqrt{\det(\mathbf{C}_i)}}{2\pi h^2 \mu_i^2} \times \exp \left\{ -\frac{(\mathbf{x}_i - \mathbf{x})^T \mathbf{C}_i (\mathbf{x}_i - \mathbf{x})}{2h^2 \mu_i^2} \right\} \quad (12)$$

直觉上, 实现这种可控核回归需要两步: 首先, 利用梯度估计器(如二阶经典核回归)对图像梯度进行初步估计, 并利用该梯度估计来计算图像的局部梯度主方向; 其次, 利用前面计算出来的局部梯度主方向来自适应地控制局部核, 最终获得一个拉伸的椭圆的与图像局部边缘结构相匹配的核。如果利用自适应核函数




图 2 (a)经典核仅依赖于采样密度；(b)可控核沿着边缘方向拉伸

进行图像滤波降噪，那么在沿着边缘方向上的滤波强度就要大于垂直边缘方向上的滤波强度。这样便可在降噪的同时有效保护图像边缘，防止边缘模糊现象的产生。根据式(9)，采用零阶估计可以将 SKR 插值表示为一个更为简单的形式：

$$\hat{z}(\mathbf{x}_i) = \frac{\sum_{j \in N(i)} K_{H^{\text{err}}}(\mathbf{x}_j - \mathbf{x}_i) y_j}{\sum_{j \in N(i)} K_{H^{\text{err}}}(\mathbf{x}_j - \mathbf{x}_i)} \quad (13)$$

式中， $N(i)$ 为像素 i 的邻域。从式(13)中可以看出，SKR 插值与传统的插值算法的根本区别在于插值时权重系数的计算。

由以上分析可知，SKR 算法具有良好的边缘保护功能，它可以在计算目标信号值 $T_{ij}(n)$ 的同时尽量减小强边缘的影响。这样可以大大提高估测的目标信号值 $T_{ij}(n)$ 的可靠性，进而有效降低“鬼影”出现的概率。而传统的均值滤波没有考虑图像中的灰度分布，所以会带来严重的平滑效应，使得校正后的图像容易产生残影等“鬼影”现象。

3 实验与分析

为了验证本文算法的性能表现，我们开展了仿真实验和真实红外图像实验。Scribner D A 等人^[7]提出的 NUC 算法和 Torres S N 等人^[9]提出的自适应学习参数的方法都将用于参考对比。

3.1 仿真实验

本文采用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)来定量评估经非均匀性校正后的红外图像的质量。PSNR 的定义为

$$PSNR = 20 \cdot \log_{10} \left[\frac{2^b}{\sqrt{\frac{1}{NM} \sum_{ij} (X_{ij} - \hat{X}_{ij})^2}} \right] \quad (14)$$

式中， X_{ij} 为未受非均匀噪声污染的原始图像的第 i 行/第 j 列像素的像素值； $\hat{X}_{ij}$ 为非均匀性校正后的像素值。图像的尺寸为 $N \times M$ 。较大的 PSNR 值通常意味着更好的非均匀性校正效果。

增益参数的估测精确度是用归一化的均方误差(Mean Square Error, MSE)来衡量的：

$$MSE_{\text{gain}}(n) = \frac{\sum_{i=1}^N \sum_{j=1}^M [g_{ij}(n) - \hat{g}_{ij}(n)]^2}{MN \cdot \sigma_g^2} \quad (15)$$

式中， σ_g 为模拟非均匀噪声的增益参数的标准差； $g_{ij}(n)$ 和 $\hat{g}_{ij}(n)$ 分别为模拟非均匀噪声的增益参数和估测出来的增益参数。偏置参数的估测精度也可以表示为同式(15)类似的形式。根据 MSE 指标，我们可以评价用 NUC 算法计算非均匀噪声的增益参数和偏置参数时的精确程度。

在仿真实验中，待校正的红外图像视频是通过向没有非均匀噪声的红外视频中人为添加固定模式噪声来获得的^[5, 11]。模拟非均匀噪声的增益系数符合零均值标准差为 0.02 的高斯分布。模拟非均匀噪声的偏置系数符合零均值标准差为 14.43 的高斯分布。实验中采用的红外视频总共具有 1000 帧。图 3 给出了没有非均匀噪声的红外图像(第 500 帧)以及相应的人为添加非均匀噪声后的图像。

实验中，所有的 NUC 算法在迭代的初始阶段都是分别将增益系数和偏置系数初始化为 0 和 1。图 3 所示为各种 NUC 算法的校正结果。从中可以看出，与其他算法相比，本文算法具有更好的去“鬼影”效果。例如，图 3(c)和图 3(d)中用红圈标记出的“鬼影”，在采用本文算法后几乎消失不见。

根据式(14)，我们可以定量地评价不同 NUC 算法的校正结果，如图 4 所示。从中可以看出，基于 SKR 的 NUC 算法可以更好地消除




图 3 迭代 500 次后的 NUC 校正效果: (a) 未受非均匀噪声污染的原始图像; (b) 添加非均匀噪声后的图像; (c) Scribner D A 等人提出的 NUC 算法的校正结果; (d) Torres S N 等人提出的 NUC 算法的校正结果; (e) 本文算法的校正结果

非均匀噪声。根据式(15), 图 5 给出了用不同算法估测的非均匀噪声的增益参数和偏置参数的误差情况。从比较结果中可以看出, SKR 算法可以帮助获得更加精确的非均匀噪声参数。




图 4 利用不同 NUC 算法获得的图像的 PSNR 值

3.2 真实红外图像实验

下面我们直接采用真实的受非均匀噪声污染的红外视频来测试 NUC 算法的性能。我们截取了一段总共包含 2000 帧图像的视频。该视频由 320×240 红外热像仪采集得到。工作时热像仪没有开启非均匀性校正功能。算法中的参数设定与仿真实验中一样。图 6 所示为不同 NUC 算法的最终校正结果。可以看出, 本文提出的基于 SKR 的 NUC 算法具有最好的校正效果。




图 5 用不同算法估计的非均匀噪声参数值的 MSE 值

4 结束语

与传统的基于定标的方法相比, 基于场景自适应的非均匀性校正技术无需用黑体定期校




图 6 迭代 500 次后的 NUC 校正效果: (a) 受真实非均匀噪声污染的图像; (b) Scribner DA 等人提出的 NUC 算法的校正结果; (c) Torres S N 等人提出的 NUC 算法的校正结果; (d) 本文算法的校正结果

正, 可以解决由红外焦平面相应参数漂移带来的周期性标定问题。然而在实际应用中, 基于场景自适应的方法容易产生“鬼影”现象。为此, 本文提出了一种改进的基于神经网络的非均匀性校正算法。该算法创新性地将可控核回归插值技术应用到基于神经网络的 NUC 算法中, 利用可控核回归技术的边缘保护特性, 有效降低了自适应非均匀性算法产生“鬼影”现象的概率。实验结果表明, 与传统神经网络算法相比, 本文算法在相同条件下既能有效消除非均匀噪声, 又能大大抑制“鬼影”现象的产生。

参考文献

- [1] Perry D L, Dereniak E L. Linear Theory of Non-uniformity Correction in Infrared Staring Sensors [J]. *Optical Engineering*, 1993, **32**(8): 1854–1859.
- [2] Zhou H, Qin H, Lai R, et al. Nonuniformity Correction Algorithm Based on Adaptive Filter for Infrared Focal Plane Arrays [J]. *Infrared Physics & Technology*, 2010, **53**(4): 295–299.
- [3] Zuo C, Chen Q A, Gu G H, et al. New Temporal High-pass Filter Nonuniformity Correction Based on Bilateral Filter [J]. *Optical Review*, 2011, **18**(2): 197–202.
- [4] Harris J G, 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.
- [5] Torres S N, Hayat M M. Kalman Filtering for Adaptive Nonuniformity Correction in Infrared Focal-plane Arrays [J]. *Journal of the Optical Society of America A Optics Image Science & Vision*, 2003, **20**(3): 470–480.
- [6] Zhou H, Qin H, Jian Y, et al. Improved Kalman-filter Nonuniformity Correction Algorithm for Infrared Focal Plane Arrays [J]. *Infrared Physics & Technology*, 2008, **51**(6): 528–531.
- [7] Scribner D A, Sarkady K A, Kruer M R, et al. Adaptive Retina-like Preprocessing for Imaging Detector Arrays [C]. San Francisco: IEEE International Conference on Neural Networks, 1993.
- [8] Harris J G, Chiang Y M. Minimizing the Ghosting Artifact in Scene-based Nonuniformity Correction [C]. *SPIE*, 1998, **3377**: 106–113.
- [9] Torres S N, Martin C S, Sbarbaro D G, et al. A Neural Network for Nonuniformity and Ghosting Correction of Infrared Image Sequences [J]. *Image Analysis and Recognition*, 2005, **3656**: 1208–1216.
- [10] Takeda H, Farsiu S, Milanfar P. Kernel Regression for Image Processing and Reconstruction [J]. *IEEE Transactions on Image Processing*, 2007, **16**(2): 349–366.
- [11] Tzimopoulou S, Lettington A H. Scene Based Techniques for Nonuniformity Correction of Infrared Focal Plane Arrays [C]. *SPIE*, 1998, **3436**: 172–183.
- [12] Wand M P, Jones M C. Kernel Smoothing, Ser. Monographs on Statistics and Applied Probability [M]. New York: Chapman & Hall, 1995.