

基于变邻域变步长 LMS 背景 预测检测红外小目标

吴一全, 吴文怡

(南京航空航天大学信息科学与技术学院, 南京 210016)

摘要: 在分析强起伏背景信号的基础上,利用背景局部信号统计特征和目标运动特性,提出了一种基于变邻域变步长 LMS 自适应背景预测的红外弱小目标检测方法。首先将两类背景交界处像素的邻点按最大类间平均离差准则分成两类,和中心像素点相近的一类构成预测邻域,而背景内部区域采用固定预测邻域;然后提出了一种改进的变步长 LMS 自适应算法,在所得预测域上进行背景预测,由实际值和预测值相减得到残差图像;最后采用二维 Tsallis-Havrda-Charvat 熵阈值选取方法对残差图像进行分割,并根据目标运动的连续性和一致性确认真实小目标。针对实际红外图像序列的实验结果表明:该算法能有效地抑制强起伏杂波,增强目标能量,降低虚警率,对强起伏背景下弱小目标具有很好的检测性能。

关键词: 红外弱小目标; 变邻域背景预测; 变步长 LMS 算法; 二维 Tsallis-Havrda-Charvat 熵阈值分割

中图分类号: TP391.4

文献标识码: A

文章编号: 1000-1328(2009)02-0735-05

DOI: 10.3873/j.issn.1000-1328.2009.00.058

0 引言

红外小目标的检测是精确制导中的一个重要组成部分,如何有效地抑制自然背景对目标检测的影响,是提高检测准确性和可靠性的关键问题^[1,2]。云层和天空背景在空间上往往呈大面积的连续分布状态,从而使其红外图像灰度空间分布具有较大的相关性和连续性,可认为在一个小的局域内背景不会有大的起伏。而运动目标的红外辐射强度与其周围自然背景的辐射强度无关,且一般都高于背景的辐射强度。红外弱小目标检测中的背景预测法就是利用背景的这种相关性,用预测邻域中像素灰度值估计中心像素点的背景灰度值。这类方法主要包括固定权值预测法^[3]、固定邻域和固定步长的 LMS 自适应预测法^[4]、分块区域最大化预测法^[5]等。这些方法在图像信噪比较高的情况下,检测效果良好,但若背景起伏较大,图像信噪比较低时,背景起伏边缘就会出现较多的虚警。固定权值预测法的权值无法适应输入图像的特点,对于背景复杂的图像检测效果很差;固定邻域和固定步长的 LMS 自适应预测法,权值虽然能对输入图像自适应,但存在两个问

题:其一,当像素位于两种背景区域交界处时,简单地用所有邻域点作为预测域进行预测极不准确,对于背景的去噪效果不佳,在这些区域会产生大量虚假目标;其二,步长对预测结果有很大的影响,固定步长 LMS 算法存在收敛速度与收敛精度的矛盾,选取步长需凭经验折衷考虑;分块区域最大化预测法,虽然不是用所有邻域点来进行预测,在某些情况下可实现对边缘的准确预测,但其预测域大小形状固定,只用简单的平均,且当弱小目标灰度值较低并位于亮云层边缘时,残差图中的目标点与背景点的对比度较低,无法正确检测到目标。

鉴于上述原因,本文提出了一种基于变邻域变步长 LMS 自适应背景预测的红外弱小目标检测方法。首先将两类背景交界处像素的邻点按最大类间平均离差准则分成亮暗两类,和中心像素点相近的一类像素点构成预测邻域,而背景内部区域采用固定预测邻域;然后提出了一种改进的变步长 LMS 自适应滤波算法,在所得预测域上进行背景预测,由实际值和预测值相减得到残差图像;最后采用我们提出的二维 Tsallis-Havrda-Charvat 熵阈值选取方法对残差图像进行分割,并利用目标运动的连续性和一

致性确认真实小目标。

1 背景预测方法的基本思想

本文研究对象为远距离的空中目标,主要包括飞机和导弹,在红外图像上呈现为小弱亮点,无形状信息,但与周围的背景相比具有较突出的亮度特征。空中背景为大气和云层,一般情况下温度低、亮度弱,有时也有较亮的云团,但其内部分布较为均匀,有时云层边缘起伏比较剧烈。

包含有目标的红外图像 $x(i, j)$ 描述为:

$$x(i, j) = x_T(i, j) + x_N(i, j) + x_B(i, j) \quad (1)$$

式中, $x(i, j)$ 为红外图像的灰度值, $x_T(i, j)$ 、 $x_N(i, j)$ 和 $x_B(i, j)$ 分别为目标点、噪声和背景图像的灰度值。在红外图像中,噪声和弱小目标同为高频分量,背景为低频分量。背景预测方法的基本思想是:背景点的灰度值与周围像素点的灰度值相关性较强,而潜在的小目标不具备这一特性。因此,将图像中各点的灰度值用它周围预测邻域上像素的灰度值进行预测,则背景点的实际灰度值与预测值相近,两者相减得到的残差很小;而由潜在的目标点得到的残差较大,从而使残差图像中背景尽可能被对消,目标变得更为突出。

背景线性预测模型为:

$$\hat{x}(i, j) = \sum_{(m, n) \in S_p} W_p(m, n) x(i - m, j - n) \quad (2)$$

式中, $x(i, j)$ 为 $M \times N$ 输入图像的实际值, $\hat{x}(i, j)$ 为预测值, W_p 为第 p 级的权系数, S_p 为预测域。预测值 $\hat{x}(i, j)$ 与实际值 $x(i, j)$ 之间的残差为:

$$E(i, j) = |\hat{x}(i, j) - x(i, j)| \quad (3)$$

这样目标检测转化为残差图像上进行阈值检测。

2 变邻域变步长 LMS 的自适应背景预测

2.1 可变预测邻域的构成及其背景预测方法

首先计算邻域灰度值的方差,若其值小于某个阈值,则该邻域视为内部区域,否则邻域应由两种灰度背景区域组成。当像素位于背景内部区域时采用固定邻域进行背景预测;而当被预测像素点位于两类灰度背景交界处时,首先利用我们提出的一维最大类间平均离差法^[6]将邻近像素点分成亮暗两类,然后用和中心像素点相近的一类像素点构成预测邻域。具体做法如下:

假定邻近像素亮点区的灰度均值为 f_b ,暗点区的灰度均值为 f_d ,目标点的灰度值为 f_t 。设灰度级为 i

的邻点像素数目为 $n_i, i \in [l_{\min}, l_{\max}]$, l_{\min} 和 l_{\max} 分别为邻点像素灰度级的最小值和最大值。现用阈值 t 将邻点像素按灰度级分为两类: $C_0 = \{l_{\min}, l_{\min} + 1, \dots, t\}$, $C_1 = \{t + 1, t + 2, \dots, l_{\max}\}$, 则 C_0 的灰度级出现的频数 ω_0 和灰度级均值 μ_0 分别为:

$$\omega_0 = \sum_{i=l_{\min}}^t n_i / \sum_{i=l_{\min}}^{l_{\max}} n_i \quad (4)$$

$$\mu_0 = (\sum_{i=l_{\min}}^t i n_i) / \sum_{i=l_{\min}}^t n_i$$

C_1 的灰度级出现的频数 ω_1 和灰度级均值分别为:

$$\omega_1 = \sum_{i=t+1}^{l_{\max}} n_i / \sum_{i=l_{\min}}^{l_{\max}} n_i \quad (5)$$

$$\mu_1 = (\sum_{i=t+1}^{l_{\max}} i n_i) / (\sum_{i=l_{\min}}^{l_{\max}} n_i - \sum_{i=l_{\min}}^t n_i)$$

图像灰度级总体均值:

$$\mu = \sum_{i=l_{\min}}^{l_{\max}} i n_i / \sum_{i=l_{\min}}^{l_{\max}} n_i \quad (6)$$

显然有

$$\mu = \omega_0 \mu_0 + \omega_1 \mu_1 \quad (7)$$

C_0 和 C_1 两类间的平均离差 $d_B(t)$ 由下式给出:

$$d_B(t) = \omega_0 |\mu_0 - \mu| + \omega_1 |\mu_1 - \mu| \quad (8)$$

在 $l_{\min} - l_{\max}$ 之间改变 t 值,类间平均离差最大值 $\max d_B(t)$ 对应的 t 值即为最佳阈值。分类后,中心像素在亮点区(记为情况 1)时,根据亮像素点计算的预测值为 \hat{f}_b ;中心像素在暗点区(记为情况 2)时,根据暗像素点计算的预测值为 \hat{f}_d 。不分类时,亮像素点为多数的预测值为 \hat{f}_{a1} ,暗像素点为多数的预测值为 \hat{f}_{a2} 。显然, $f_b > f_t > \hat{f}_{a1} > \hat{f}_{a2} > f_d$ 。

表 1 两种不同邻域下残差值的比较

Table 1 The comparison of the residual value under two different neighborhoods

		预测邻域可变	预测邻域固定
背景点	情况 1	$ f_b - \hat{f}_b \approx 0$	$ f_b - \hat{f}_{a1} > 0$
	情况 2	$ f_d - \hat{f}_d \approx 0$	$ f_d - \hat{f}_{a2} > 0$
非背景点	情况 1	$ f_t - \hat{f}_b $	$ f_t - \hat{f}_{a1} $
	情况 2	$ f_t - \hat{f}_d $	$ f_t - \hat{f}_{a2} $

表 1 列出了两种不同邻域下残差值的比较。可以看出,预测邻域可变情况下,背景点的预测值非常接近实际值,能很好地去掉背景;而预测邻域固定时因背景点不能去除,会出现虚警点。非背景点的预测结果不能明显看出,尚需进一步求残差图像中目标与背景的反差值来进行判断。

(a) 情况 1: 预测邻域可变时,

$|f_i - \hat{f}_b| - |f_b - \hat{f}_b| \approx f_i - f_b$; 预测邻域固定时, $|f_i - \hat{f}_{a_1}| - |f_b - \hat{f}_{a_1}| = f_i - f_b$ 。结果相同, 说明该情况下对于目标点的预测效果一样。

(b) 情况 2: 预测邻域可变时,

$|f_i - \hat{f}_d| - |f_d - \hat{f}_d| \approx f_i - f_d$; 预测邻域固定时, $|f_i - \hat{f}_{a_2}| - |f_d - \hat{f}_{a_2}| = f_i + f_d - 2\hat{f}_{a_2}$ 。由于

$f_i - f_d - (f_i + f_d - 2\hat{f}_{a_2}) = 2(\hat{f}_{a_2} - f_d) > 0$, 所以分类后目标点残差值更大, 更利于目标的分割和检测。

由以上分析可知, 在边界区域中, 当被预测点是背景点时, 能准确地对其进行预测; 而当被预测点是目标点时, 也能得到更有利于分割的预测值。下面就可以在按上述方式构成的预测邻域上进行变步长 LMS 自适应背景预测的处理。

2.2 变步长 LMS 自适应背景预测算法

现在考虑对预测域内的点进行自适应估计。由式 (2) 可见, 预测估计值是通过预测域内的点进行加权求和得到的。式 (3) 中的 $E(i, j)$ 即为预测误差。每次迭代时, 根据预测误差和预测域点的实际值, 对权系数修正如下:

$$W_{p+1}(m, n) = W_p(m, n) + 2\mu E(m, n)x(m, n) \quad (9)$$

式中 μ 代表收敛因子, 即步长, 它对预测效果有很大的影响。在固定步长 LMS 算法中, 当步长选得较小时, 稳态误差就比较小, 但需较长的收敛时间; 而当步长选得较大时, 收敛较快, 但收敛过程中会出现振荡。选取步长需凭经验折衷考虑。为解决这一问题, 并进一步提高 LMS 算法的性能, 人们发展了各种变步长 LMS 自适应滤波算法。其优越性在于: 自适应算法的初始阶段, 误差比较大, 步长 μ 也相应较大, 从而有较快的收敛速度; 当接近收敛时, 误差逐渐减小, μ 变小, 因此稳态误差也很小。这样就较好地解决了固定步长 LMS 算法存在的收敛速度与稳态误差的矛盾。

目前已提出了多种变步长 LMS 自适应滤波算法, 其中基于 Sigmoid 函数的变步长 LMS 算法 (SVS-LMS) 在收敛速度、跟踪速度及稳定性等方面效果较好, 但在稳态阶段仍有较大的步长变化。2004 年文献 [7] 提出了基于箕舌线的变步长 LMS 自适应算法, 在自适应初始阶段, 误差相等情况下比 SVSLMS 算法具有较大步长, 而收敛阶段有较小的步长, 且计算量和稳态误差都明显小于 SVSLMS 算法, 但是受观测噪声的影响非常大。2007 年文献 [8] 建立了一

种步长因子与误差信号之间类似 Sigmoid 函数的非线性函数关系, 具有初始阶段和系统时变阶段步长迅速增大而稳态阶段步长自适应减小的特点, 并且不容易受噪声干扰, 但是涉及指数运算, 计算量较前面两种方法要大。

在上述基础上, 本文提出一种改进的变步长 LMS 自适应算法。其自适应变步长更新公式为:

$$\left. \begin{aligned} \mu(n) &= \beta(n) \left[1 - \frac{1}{\alpha(n) \|J(n)\| + 1} \right] \\ \beta(n) &= \gamma\beta(n-1) + (1-\gamma) \|J(n)\| \\ \alpha(n) &= \|e(n)/e(n-1)\|^k, k > 0 \\ J(n) &= e(n)e(n-1) \end{aligned} \right\} \quad (10)$$

式中 $\mu(n)$ 是滤波器在时刻 n 的调整步长; $e(n)$ 为误差信号; $J(n)$ 是误差信号的函数; $0 < \gamma < 1$, 是接近于 1 的常数, 控制参数 β 的变化; α 控制步长变化的形状和速度。在该算法中, β 随着 $\|J(n)\|$ 的大小作相应的变化。在初始收敛阶段 $\|J(n)\|$ 较大, 对应 β 较大, 有较大的 $\mu(n)$ 及较快的收敛速度; 而逐渐进入稳态时, $\|J(n)\|$ 逐渐变小, 对应 β 亦随之变小, 使 $\mu(n)$ 随 $\|J(n)\|$ 的变化曲线变缓, 从而 $\mu(n)$ 更小, 由此得到更小的稳态误差。采用当前误差与上一步误差的自相关估计来控制 $\|J(n)\|$, 排除了稳态时输入端噪声引起的 $\|J(n)\|$ 变化。与文献 [8] 相比, 该算法不涉及指数运算, 计算量大减少。

3 二维 Tsallis-Havrda-Charvat 熵阈值分割与目标连续性检测

3.1 二维 Tsallis-Havrda-Charvat 熵阈值分割

根据上述变步长 LMS 自适应预测算法获得背景预测图像后, 在所得残差图像上采用我们提出的二维直方图斜分 Tsallis-Havrda-Charvat 熵阈值选取算法^[9]分割目标。该分割算法通过四条平行斜线将直方图分成内点区、边界点区和噪声点区, 并采用与主对角线垂直的斜线进行阈值分割。目标和背景的二熵分别为:

$$H_o^\alpha(T) = \frac{1}{\alpha - 1} \left[1 - \frac{h_o(T)}{[P_o(T)]^\alpha} \right] \quad (11)$$

$$H_b^\alpha(T) = \frac{1}{\alpha - 1} \left[1 - \frac{h_{LL} - h_o(T)^\alpha}{[1 - P_o(T)]^\alpha} \right] \quad (12)$$

式中 T 为阈值, $P_o(T)$ 为目标概率, $h_o(T)$ 为目标熵, $h_{LL} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} [p(i, j)]^\alpha$ 为二维直方图总熵。

使判别函数 $\Phi_{\alpha}(T) = H_0^{\alpha}(T) + H_b^{\alpha}(T) + (1 - \alpha)H_0^{\alpha}(T)H_b^{\alpha}(T)$ 达到最大,求得最佳阈值: $T^* = \text{Argmax}\{\Phi_{\alpha}(T)\}$ 。与最大 Shannon 熵阈值分割算法相比,该算法在分割效果和运行速度上都有非常明显的优势。

3.2 运动的连续性和一致性检测红外小目标


分割后的残差图像中,非背景点包含了目标点和噪声点两类。对噪声点可以根据小目标的运动特性,采用多帧红外图像序列分析进行剔除。因为在图像序列中,噪声点是随机出现的,而目标点的运动具有连续性和一致性,其特点为:(1)帧间运动距离基本相等;(2)帧间运动方向基本一致;(3)帧间灰度变化不显著。

在进行多帧处理时,假设非背景点在相邻帧 f_1 、 f_2 和 f_3 中的坐标分别为 $p_1(x_1, y_1)$ 、 $p_2(x_2, y_2)$ 和 $p_3(x_3, y_3)$,将这三点通过映射转换到同一图像坐标系中,得到矢量 $\overline{op_1}$ 、 $\overline{op_2}$ 和 $\overline{op_3}$ 及其两个矢量差 $\overline{v_1} = \overline{op_2} - \overline{op_1}$ 和 $\overline{v_2} = \overline{op_3} - \overline{op_2}$ 。特点(1)和(2)体现为目标点对应的两个矢量差 $\overline{v_1}$ 和 $\overline{v_2}$ 相似;特点(3)则表现为目标点灰度级相似。故设计非背景点间相似性度量 $\gamma = \|\overline{v_1} - \overline{v_2}\|_2 \cdot \sigma$,其中 σ 为非背景点在连续三帧中的灰度标准差。如果 $\gamma \leq T_1$,则判断为目标点,予以保留;否则视为噪声点去除,其中 T_1 为设定的常数。由此即可检测出真正的红外小目标。

4 实验结果与分析

本文针对多组红外小目标图像序列,分别采用基于固定邻域固定步长的 LMS 背景预测算法和基于变邻域变步长 LMS 自适应背景预测算法来进行红外小目标检测实验。对于选用固定步长的情况,大量的实际数据实验表明比较合适的步长数值约为 10^{-6} 。任取 60 帧图像,基于固定邻域固定步长 LMS 背景预测算法有 53 帧检测正确,检测概率为 88%;而基于变邻域变步长 LMS 自适应背景预测算法有 56 帧检测正确,检测概率为 93%。可见变邻域变步长 LMS 自适应背景预测算法的检测精度要优于固定邻域固定步长 LMS 背景预测算法。

为便于说明,图 1 给出一组红外图像序列的实验结果。其中(a)为一组复杂背景下红外图像序列中的某一帧,其特点是信噪比很低,目标很小且掩盖在云层中较难检测;(b)和(c)分别为基于固定邻域



(a)Original image (b)The residual image based on fixed neighborhood and step-size LMS algorithm (c) Segmentation result of image b (d)The residual image based on variable neighborhood and step-size LMS algorithm (e) Segmentation result of image d (f) Detection result of image c (g) Detection result of image e

图 1 红外图像序列的检测结果

Fig. 1 Detection results of infrared image sequence

固定步长 LMS 背景预测算法得到的残差图及其分割结果;(d)和(e)分别为基于变邻域变步长 LMS 自适应背景预测算法得到的残差图及其分割结果;(f)为图(c)及其前后两帧的检测结果;(g)为图(e)及其前后两帧的检测结果。

对于该实验结果,进一步采用信噪比和信噪比增益来定量评价算法的处理性能。信噪比 SNR 和信噪比增益 G_{SNR} 定义如下:

$$SNR = (G_t - G_b) / \sigma_b \quad (13)$$

$$G_{SNR} = SNR_0 / SNR_t \quad (14)$$

式中 G_t 为目标的灰度值, G_b 代表背景的灰度, σ_b 为

背景的标准差。 SNR_I 和 SNR_0 分别为处理前后图像的信噪比。当 SNR_I 为负值的情况下,采用替代统计公式 $G_{SNR} = (SNR_0 + |SNR_I|) / |SNR_I|$ 。表 2 给出了用现有方法和本文方法处理的性能对比。

表 2 两种方法的性能对比

Table 2 Performance comparison of two algorithms

	SNR_I	SNR_0	G_{SNR}
现有方法	4.345	69.512	15.998
本文方法	4.345	178.267	41.028

由表 2 可以看出,本文算法的性能明显优于基于固定邻域固定步长 LMS 背景预测算法,小目标检测能力明显提高。多组红外小目标图像序列实验结果也表明,无论怎样变化的背景云层,变邻域变步长 LMS 背景预测所得到的残差图像都能更好地滤除大部分的背景,增强弱小目标,降低虚警率,便于后续的检测与跟踪,在收敛精度方面也比固定邻域固定步长 LMS 预测算法做得更好。

5 结论

本文提出的基于变邻域变步长 LMS 自适应背景预测检测方法对于强起伏背景下红外小目标的检测取得了很好的效果,明显优于现有的基于 LMS 自适应背景预测的检测方法。该方法对两类背景交界处像素的邻点分类所构成的预测邻域合理;改进的变步长 LMS 自适应算法,解决了收敛速度和收敛精度的矛盾,计算量大大减少且抗噪声能力强;采用二维 Tsallis-Havrda-Charvat 熵阈值选取算法分割残差图像,并根据目标运动的连续性和一致性确认真实小目标的方法行之有效。

参考文献:

[1] 迟健男,张朝晖,王东署,等.反对称双正交小波在红外图像小目标检测中的应用[J].宇航学报,2007,28(5):1253-1257. [CHI Jian-nan, ZHANG Zhao-hui, WANG Dong-shu, et al. Application of anti-symmetrical biorthogonal wavelet in infrared image small targets detection [J]. Journal of Astronautics, 2007, 28(5): 1253-1257.]

[2] Tzannes A P, Brooks D H. Detecting small moving objects using temporal hypothesis testing [J]. IEEE Trans. Aerosp. Electron.

Syst., 2002, 38(1): 570-585.

- [3] 陈振学,汪国有.基于自适应背景预测的红外弱小目标检测算法[J].激光与红外,2005,35(8):608-610. [CHEN Zhen-xue, WANG Guo-you. Infrared small and weak targets detection based on self-adaptive background forecast [J]. Laser and Infrared, 2005, 35(8): 608-610.]
- [4] 朱红,赵亦工.基于背景自适应预测的红外弱小运动目标检测[J].红外与毫米波学报,1999,18(4):305-310. [ZHU Hong, ZHAO Yi-gong. Detection of weak and small moving infrared targets by adaptive prediction of background [J]. Journal of Infrared and Millimeter Waves, 1999, 18(4): 305-310.]
- [5] 徐军,向建华,梁昌洪.最大化背景模型用于检测红外图像中的弱小目标[J].光子学报,2002,31(12):1483-1486. [XU Jun, XIANG Jian-hua, LIANG Chang-hong. Small target detection based on maximum background model in IR images [J]. Acta Photonica Sinica, 2002, 31(12): 1483-1486.]
- [6] 吴一全,刘冰,王厚枢.液晶显示温度场的数字图像处理[J].数据采集与处理,1990,5(3):23-30. [WU Yi-quan, LIU Bing, WANG Hou-shu. Digital image processing on liquid crystal temperature field [J]. Journal of Data Acquisition and Processing, 1990, 5(3): 23-30.]
- [7] 邓江波,侯新国,吴正国.基于箕舌线的变步长 LMS 自适应算法[J].数据采集与处理,2004,19(3):282-285. [DENG Jiang-bo, HOU Xin-guo, WU Zheng-guo. Variable step adaptive filtering LMS algorithm based on tongue-like curve [J]. Journal of Data Acquisition and Processing, 2004, 19(3): 282-285.]
- [8] 孙恩昌,李于衡,张冬英,等.自适应变步长 LMS 滤波算法及分析[J].系统仿真学报,2007,19(14):3172-3175. [SUN En-chang, LI Yu-heng, ZHANG Dong-ying, et al. Adaptive variable-step size LMS filtering algorithm and its analysis [J]. Journal of System Simulation, 2007, 19(14): 3172-3175.]
- [9] 吴一全,潘喆,吴文怡.基于二维直方图斜分的 Tsallis-Havrda-Charvat 熵阈值分割算法[J].光电工程,2008,35(7):53-58. [WU Yi-quan, PAN Zhe, WU Wen-yi. The Tsallis-Havrda-Charvat's entropy image thresholding algorithm based on two-Dimensional histogram oblique segmentation [J]. Opto-Electronic Engineering, 2008, 35(7): 53-58.]

作者简介:吴一全(1963-),男,博士,副教授,信息与通信工程专业,研究方向为图像处理与视频通信,目标检测与跟踪,信号处理等。

通信地址:南京航空航天大学信息科学与技术学院(210016)

电话:(025)84896490

E-mail:gumtion_s@yahoo.com.cn