

基于统计特征空间提取和支持向量机的 极暗弱小天体检测方法

王存远 郑 伟 李明涛

(中国科学院国家空间科学中心 北京 100190)

(中国科学院大学 北京 100049)

摘 要 小天体检测是小天体防御和预警的前提。针对小天体目标信噪比低、检测难的问题,提出了基于统计特征空间提取和支持向量机(SVM)的极暗弱小天体检测方法。区别于传统方法基于时间或空间上目标的能量和背景噪声能量的瞬时能量差别或是瞬时能量差别的累积,对目标进行检测。该方法不依赖目标能量大小,提取运动目标穿过背景时对稳定性产生的扰动来反演运动目标。将输入的图像序列转化为单像元时序信号,划分时序窗口提取统计特征,关联形成统计特征空间,利用更高维度的变化特性检测目标变化。通过 SVM 将暗弱小天体检测问题转化为目标与背景的二分类问题,避开了较难解决的阈值分割问题同时具有更好的泛化性能。利用真实数据与其他经典方法进行对比分析,使得分类准确率提高 4.02%。该方法能够适应更低的信噪比,在极低信噪比下仍表现出稳定的检测性能。

关键词 运动目标检测, 低信噪比, 小天体, 特征空间, 支持向量机

中图分类号 P271

Dim Small Object Detection Method Based on Statistical Feature Space Extraction and SVM

WANG Cunyuan ZHENG Wei LI Mingtao

(National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

(University of Chinese Academy of Sciences, Beijing 100049)

Abstract Small object detection is the premise of small object defense and early warning. Aiming at the problems of low signal-to-noise ratio and difficult detection of small object targets, a very dark and weak small object detection method based on statistical feature space extraction and SVM is proposed. It is different from traditional methods to detect targets based on the instantaneous energy difference or the accumulation of instantaneous energy difference between target energy and background noise energy

2021-12-30 收到原稿, 2022-10-16 收到修定稿

E-mail: wangcunyuan19@mailsucas.ac.cn

©The Author(s) 2023. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

in time or space. This method does not directly depend on the target energy, but extracts the disturbance to the stability when the moving target passes through the background to retrieve the moving target. The input image sequence is transformed into a single pixel timing signal, the timing window is divided, the statistical features are extracted, the statistical feature space is formed by correlation, and the target change is detected by using the change characteristics of higher dimensions. The method is implemented by Support Vector Machine (SVM) transforms the dim small object detection problem into the binary classification problem of target and background, so that the method avoids the thorny threshold segmentation problem and has better generalization performance. Through the comparative analysis between real data and other classical methods, the classification accuracy is increased by 4.02%. This method can adapt to lower signal-to-noise ratio and still perform well at very low signal-to-noise ratio. Stable detection performance.

Key words Moving target detection, Low signal-to-noise ratio, Small celestial body, Feature space, Support Vector Machine (SVM)

0 引言

近年来由于观测技术进步以及观测任务增加,已发现的小行星数量每天都在持续增长,目前每年有多达 3000 颗近地小行星被发现。小行星监测和预警核心在于远距离发现目标,给出足够的预警时间。由于距离远,目标能量弱,信噪比很低,这种情况下传统基于能量的检测方法受到很大的限制。研究极暗弱小天体检测技术,可以提高监视预警系统的作用距离,对于增加反应时间提高防御成功概率具有重要意义。

在天基、空基或地基远程警戒及小行星监控预警系统中,低信噪比暗弱运动目标检测方法是一个关键技术^[1],同时也一直是光学和图像处理领域的研究热点。由于暗弱目标的能量低导致可利用的信息量有限。目前工程检测指标要求信噪比大于 6,但实际应用中遇到的信噪比通常小于 3^[2],甚至在 1 以下,传统的基于能量检测的方法对于此类问题效果不佳。

运动目标检测算法可分为三类,即基于空域、基于时域和基于机器学习的算法。基于空域的目标检测方法是最经典的处理方法,其主要思路是通过抑制背景来区分小目标与背景杂波,基于该区分规则的方法包括数学形态学方法^[3-5]、小平面法^[6-7]、图像分层法^[8]、局部对比度法^[9]、低秩恢复法^[10],以及视觉注意力法^[11]。基于时域的目标检测方法主要有帧相关法^[12]、光流法^[13]、Hough 变换法^[14]、能量积累法、动态规划法^[15]以及高阶相关法等^[16]。基于空域的目标

检测方法思路清晰,算法较为简单可靠。但事实上,由于对处理对象像素点没有区别的处理,在小目标处理方面缺乏一定保留,因此当目标的信噪比很低而背景杂波的复杂度很高时,此类算法将无法满足要求。相对地,基于时域的目标检测方法不容易受到背景变化的影响,但是容易受到目标运动速度和噪声的影响。基于机器学习的算法主要分为两类:一是基于传统统计机器学习理论的统计机器学习方法,例如随机森林和朴素贝叶斯等;二是基于深度网络的有监督学习方法,其中在目标检测中应用最为广泛的是卷积神经网络(Convolutional Neural Networks, CNN)^[17]和深度卷积神经网络(Deep Convolutional Neural Networks, DCNN)^[18],可再细分为一段式的 YOLO^[19]、YOLOv2^[20]和 SSD^[21]和两段式的 Fast-RCNN^[22]、Faster-RCNN^[23]、Mask-RCNN^[24]。利用计算机视觉,通过特征提取的方法对目标和背景进行自动分类,实现了特征、候选区域、边界框的提取以及对类别的判别,然而其不太适合检测暗弱运动小目标。由于暗弱目标所占据的像素数量很少,目标几乎没有丰富的外观信息供建模使用,在此场景下,以强大特征学习能力见长的各种深度网络模型很难被用于构建外观模型,其鲁棒性不高,对小目标检测效果不太理想。在运动目标占比很小、信噪比较低的情况下,目标可利用的空间特征很少,且在神经网络的训练中,不同维度之间的转换容易导致微小信息的丢失。

目前运动目标检测的主要方法还是基于能量在

某个变换域的检测,依靠的是在时间或者空间上目标能量与背景或噪声能量的差别,基于时域、空域等都是利用瞬时能量差别或瞬时能量差别的累积对目标进行检测的。但是当信噪比很低,目标能量被背景和噪声的能量淹没时算法无法工作。因此本文提出一种基于统计特征空间提取和 SVM 的极暗弱小天体检测方法,由于空间背景信号在时域上的分布短时间内具有相对稳定性(包括分布稳定性和变化稳定性),当运动目标穿过背景时会对稳定性产生扰动,这种扰动体现在信号的统计特征上,提取信号统计特征的异常反演目标运动产生的扰动进而判断目标的存在。此方法不直接依赖于目标能量的大小,因此在极低信噪比下仍表现出稳定的检测性能。引入核函数的方法,将有用特征进行关联形成统计特征空间,提取出更高维度的变化特性来检测目标变化,使该方法能适应更低的信噪比。同时支持向量机(SVM)的方法将暗弱小天体检测问题转化为目标与背景的二分类问题,解决了传统算法比较困难的阈值分割难题,进一步增加了方法的鲁棒性与泛化性能。

本文首先对目标和背景信号的特征进行分析,提取多种有效特征,在实验过程中发现若只使用一种特征在低信噪比情况下算法检测效果不佳,将特征关联形成特征空间后算法性能提升。随后进行了充分的半物理仿真实验,提取信号的统计特征进行关联,根据先验知识训练目标和背景的分类模型,再由各点分类预测的后验概率确定目标运动轨迹。最后利用真实的天文数据验证检测方法的有效性和泛化性能,同时与其他主流方法进行比较分析。

1 方法与理论

1.1 时序窗口特征提取方法

针对暗弱小天体目标进行检测,由于目标能量极低,完全湮没于背景和噪声之中,且目标占比很低,通常只有几个甚至一个像元,故选择基于单像元时序序列进行特征提取。同时考虑到目标速度和噪声影响,如果提取整个时域上的全局特征无法适用于暗弱目标的检测,则通过划分时序窗口的方式提取局部特征信息,形成目标的特征空间,在仿真实验中对时序窗口的划分规则进行了分析。特征提取规则如下。

相似度。由于小天体的背景和噪声种类相对固

定,对于背景和噪声而言,其特征分布具有相对稳定性,当某一时刻有目标进入时,相似度特征会发生扰动,此时提取出时序窗口的相似度信息进而检测暗弱运动目标的存在,考虑到暗弱小天体目标信噪比极低的情况下,还需要进行非线性拉伸和系数增强,即

$$\Delta(X_{L1} - X_{L2}) = \sum_{i=L}^{N-L} \left[(x_{L1} - x_{L2}) \exp(x_{L1} - x_{L2})^{\frac{3}{2}} \right]. \quad (1)$$

其中, x_{L1} 和 x_{L2} 分别为滑动窗口的第 1 到 $L/2$ 帧和 $L/2$ 帧到 L 帧的部分,相似度特征反映了目标进出像元带来的分布扰动情况。

标准偏差值(std, 定义符号 S_{td} , 单位 dB)。暗弱小天体目标划过像元会引起能量变化,从而影响信号的均值方差等特征。提取时序窗口的标准差特征,能有效降低背景噪声带来的影响,标准偏差值越大,变化范围越大,有

$$S_{td} = \lg \left\{ \sqrt{\frac{\sum_{i=1}^L [(x(i) - \bar{x})^2]}{L - 1}} \right\}. \quad (2)$$

提取时序窗口峰值因子、脉冲因子与裕度因子,分别是信号峰值与有效值(RMS)、整流平均值和方根幅值的比值,代表暗弱目标经过时对背景噪声的影响程度,进而反映目标的运动,有

$$I_P(i) = \frac{\max(x_i^{i+L})}{\frac{1}{L} \sum_{j=i}^{i+L} x_j^2}, \quad (3)$$

$$I_I(i) = \frac{\max(x_i^{i+L})}{\left(\frac{1}{L} \sum_{j=i}^{i+L} |x_j| \right)^2}, \quad (4)$$

$$I_{CL}(i) = \frac{\max(x_i^{i+L})}{\left(\frac{1}{L} \sum_{j=i}^{i+L} \sqrt{|x_j|} \right)^2}. \quad (5)$$

引入峭度因子表示波形平缓程度,用于描述能量的分布。峭度越小,分布的曲线越平,峭度越大则分布的曲线越陡,能够反演出是否有目标划过像元,即

$$K(i) = \frac{\frac{1}{L} \sum_{j=i}^{i+L} (x_j - \bar{x}_i)^4}{\left[\frac{1}{L} \sum_{j=i}^{i+L} (x_j - \bar{x}_i)^2 \right]^2}. \quad (6)$$

基于奇异值的特征提取,奇异值矩阵的计算可以将一个比较复杂的矩阵用更小更简单的几个子矩阵

相乘表示,这些子矩阵代表目标特征信息。奇异值分解可以提取出更有效的特征而忽略无用信息,定义奇异值衰减速度、稳定程度和能量集中程度作为特征量。当数据受到噪声影响时,最小特征值对应的特征向量往往与噪声有关,将其舍弃能够在一定程度上起到降噪的效果。

(1) 奇异值衰减速度。定义窗口的自相关矩阵 $M_1 = (X(1), X(2), \dots, X(L))$, 则

$$R_1 = M_1^T M_1 = \begin{bmatrix} X(1)X(1) & X(1)X(2) & \cdots & X(1)X(L) \\ X(2)X(1) & X(2)X(2) & \cdots & X(2)X(L) \\ \vdots & \vdots & \ddots & \vdots \\ X(L)X(1) & X(L)X(2) & \cdots & X(L)X(L) \end{bmatrix}. \quad (7)$$

令 $M_2 = (X(2), X(3), \dots, X(L), 0)$, 计算 $R_1 = M_2^T M_2$ 。以此类推, $M_L = (X(L), 0, \dots, 0)$, 则

$$R_L = M_L^T M_L = \begin{bmatrix} X(L)X(L) & 0 & \cdots & 0 \\ 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{bmatrix}. \quad (8)$$

得到自相关矩阵 $R = R_1 + R_2 + \dots + R_L$ 。对自相关矩阵 R 进行奇异值分解, 并将求得的奇异值归一化得到 $W = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_N)$ 。统计大于阈值的奇异值个数 n , 则 n/L 为奇异值衰减速度。

(2) 奇异值稳定度。定义 $W_1 = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$, 对 W_1 求方差为奇异值稳定度 W_s , 有

$$W_s = \text{var}(W_1). \quad (9)$$

(3) 奇异值能量集中度。熵函数可以反映能量的集中程度, 定义奇异值的熵函数为奇异值能量集中度, 即

$$W_p = -\sum_{i=1}^L p_i \lg(\sigma_i / \sum_{j=1}^L \sigma_j). \quad (10)$$

为验证上述特征的有效性, 选取一段真实的近地小行星视频数据, 信噪比为 5 dB 以上, 从中选取 1000 个目标样本和 94 000 个背景样本, 图 1 分别给出了提取不同特征时目标和背景的分布情况。

从图 1 可以看出, 高速运动的小行星目标与背景目标相比, 其相似度特征、标准差特征、峰值、脉冲因子特征、奇异值特征和峭度因子特征均有较明显的差异, 上述特征对小行星目标和背景有良好的区分度, 验证了其对于目标检测的有效性。当信噪比降低时, 单

独使用一种特征进行分类的效果较差, 因此考虑将多特征关联映射至更高维的特征空间, 以提高算法性能。

1.2 基于多特征关联的 SVM 检测模型

支持向量机(SVM)具有泛化能力强、全局最优等优点, 且收敛速度较快。鉴于此, 这里采用支持向量机(SVM)方法对统计特征空间进行关联提取与优化。

对于一个给定的图像序列训练数据集 (x_i, y_i) , $i = 1, 2, \dots, N$, x_i 为包含目标与背景特征的训练样本, $y_i \in \{-1, 1\}$ 表示训练样本标签, 分别代表背景类与目标类, N 为样本总数, $x_{i,j}$ ($j = 1, 2, \dots, d$) 表示第 i 个样本的第 j 个特征。用非线性映射函数 $\varphi(x)$ 将样本从原空间映射到 k 维 ($k \geq d$) 特征空间 F 中, 并在此特征空间中构造如下最优线性回归函数:

$$f(x) = w^T \varphi(x) + b. \quad (11)$$

式中, w 为垂直于超平面的权向量, $w \in R$; b 为阈值, $b \in R$ 。针对该线性不可分问题, 要使得最优超平面的分类间隔最大, 即 $\|w\|$ 最小, 换言之, 使得样本中包含的目标类与样本类尽可能区分。这样非线性拟合问题即转化为高维特征空间中的线性拟合问题。根据结构风险最小化原则, 综合考虑函数复杂度和拟合误差, 最大间隔分类面通过求解如下问题获得:

$$\begin{aligned} \min_{w, b, \xi} J(w, \xi) &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i; \\ \text{s.t. } y_i [w^T \varphi(x_i) + b] &\geq 1 - \xi_i, \\ \xi_i &\geq 0, \quad i = 1, 2, \dots, N. \end{aligned} \quad (12)$$

式中, C 为惩罚因子, C 值较大倾向于产生没有错样本的分界面, C 值较小则倾向于产生大间隔的分界面。对于可能存在的错分现象, 引入松弛变量 ξ_i 弱化约束条件, 允许两类不同样本与最优超平面存在一定的距离, $\varphi(x_i)$ 是将样本空间映射到高维特征空间的函数。利用拉格朗日乘子法可得到上面最优化问题的对偶问题, 即

$$\begin{aligned} \min_{\alpha} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \kappa(x_i, x_j) - \sum_{i=1}^N \alpha_i; \\ \text{s.t. } \sum_{i=1}^N \alpha_i y_i &= 0, \\ 0 \leq \alpha_i &\leq C, \quad i = 1, 2, \dots, N. \end{aligned} \quad (13)$$

根据 Karus-Kuhn-Tucher(KKT)最优条件, 求得最优解:




图 1 目标背景的不同特征分布

Fig. 1 Distribution of different characteristics of target background

$$\alpha' = (\alpha'_1, \alpha'_2, \dots, \alpha'_N)^T; \quad (14)$$

$$b' = y_i - \sum_{i=1}^N y_i \alpha'_i \kappa(x_i, x_j), \quad 0 < \alpha'_j < C. \quad (15)$$

对于线性不可分情况, w' 唯一而 b' 不唯一, 通常需要在所有符合条件的样本上计算一个 b' , 然后取平均。最终求得预测函数为

$$f(x) = \text{sign} \left\{ \sum_{i=1}^N \alpha'_i y_i [\varphi(x_i) \varphi(x)] + b' \right\}, \quad (16)$$

$$b' = \frac{1}{|\{\alpha'_k : C > \alpha'_k > 0\}|} \sum_{C > \alpha'_k > 0} \{y_k - \sum_{i=1}^N y_i \alpha'_i [\varphi(x_i) \varphi(x_k)]\}. \quad (17)$$

其中, $\kappa(x_i, x_j) = [\varphi(x_i) \varphi(x_j)]$ 为满足 Mercer 条件^[25]的核函数。通过核函数将低维空间中线性不可分问题转换为高维特征空间线性可分问题, 降低解决问题难度, 在原输入空间中计算高维特征空间中特征向量的相似性, 使得高维空间甚至无限维空间解决线性不

可分问题成为可能。常用的核函数有多项式核函数、径向基核函数和 Sigmoid 核函数, 分别为

$$\kappa_{\text{pol}}(x, y) = (x^T y + r)^p, \quad (18)$$

$$\kappa_{\text{RBF}}(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right), \quad (19)$$

$$\kappa_S(x, y) = \tanh(\beta x^T y + \theta), \quad \beta > 0, \theta < 0. \quad (20)$$

1.3 方法步骤

基于统计特征空间提取和 SVM 的极暗弱小天体检测方法步骤如下。

步骤 1 将输入的图像序列在时序上做归一化预处理, 得到 $N \times H$ 阶矩阵, 这里 N 为像素点个数, H 为图像序列的时序长度。

步骤 2 根据信号帧频和驻留时间等确定时序窗口 L 的大小, 在时序窗口上分别提取其相似度 F_s 、标准差 std 、峰值因子 I_P 、脉冲因子 I_I 、裕度因子 I_{CL} 、峭度因子 K 、奇异值衰减速度 W_n 、奇异值稳定度 W_s 和奇异值能量集中度 W_p 等特征, 训练集和测试集的数据分别为 D_{train} 和 D_{test} , D_{train} 为 $m_d \times 10$ 维数据, D_{test} 为 $m_t \times 9$ 维数据, 其中 m_d 为训练样本数, m_t 为测试样本数。

步骤 3 使用 $D_{\text{train}} = (F_s, \text{std}, I_P, I_I, I_{CL}, K, W_n, W_s, W_p, y)$ 训练集数据训练 SVM 分类器。这里采用的是径向基核函数方法。

步骤 4 将训练得到的 SVM 分类器对 $D_{\text{test}} = (F_s, \text{std}, I_P, I_I, I_{CL}, K, W_n, W_s, W_p)$ 测试集数据进行目标和背景点的分类识别。

步骤 5 将提取出的目标信号进行空间轨迹关联, 若邻域像元内存在目标信号则判断为轨迹目标。否则, 如果没有轨迹信号输出, 则重返步骤 2 进行二次窗口划分, 改变参数进行检测。

2 实验与分析

2.1 仿真实验

为验证方法对于暗弱小天体目标检测的有效性, 与泛化能力, 开展了半物理仿真实验。首先比较不同特征提取方式与多特征关联后的性能, 分别在不同信噪比情况下对算法进行仿真实验。为进一步提高算法性能, 还研究了时序窗口与采样频率和目标区域驻留时间的关系。最后与其他经典方法进行比较。以

真实采集的图像序列为背景, 根据背景产生不同信噪比的目标信号, 分别叠加在背景上。利用文中方法进行检测, 并与最大中值滤波^[26]、最大均值滤波^[27]、小波变换^[28]、背景建模^[29]以及 Top-hat^[30]滤波 5 种经典运动目标检测方法进行对比分析。

以真实采集的 800 帧大小为 256×256 的图像序列作为背景, 目标信号的生成公式如下:

$$I(t) = A \exp \left\{ \frac{- \left\{ v \left[t - \frac{(t_2 - t_1)f}{2} \right]^2 \right\}}{2\sigma_s^2} \right\}, \quad t_1 < t < t_2. \quad (21)$$

其中, $I(t)$ 为目标信号强度, σ_s 为点扩散函数参数, v 表示目标运动速率, f 为系统采样频率, 目标在 t_1 时刻进入 t_2 时刻离开, 驻留时间为 $t_2 - t_1$ 。信噪比函数定义为

$$\frac{S}{N} = 10 \lg \left(\frac{p_s - \sigma_n}{\sigma_n} \right), \quad (22)$$

$$p_s = \frac{1}{N_s} \sum_{i=0}^{N_s-1} I(i)^2. \quad (23)$$

其中, p_s 为目标信号平均功率, σ_n 为噪声平均功率。

研究特征空间关联后对方法性能的影响, 将目标信噪比降低至 -1 dB, 分别提取不同特征验证算法性能。图 2 所示为不同特征提取规则下的受试者工作特性 (Receiver Operating Characteristic, ROC) 曲线, 通过描述检测率和虚警率的关系进行更客观准确的分析。ROC 曲线越靠近左上角, 灵敏度越高, 误判




图 2 不同特征提取规则 ROC 对比

Fig. 2 ROC comparison of different feature extraction rules

率越低, 诊断方法的性能越好。可知 ROC 曲线上最靠近左上角的 ROC 曲线上的点, 其灵敏度和特异性之和最大, 这个点或者其邻近点常被称为诊断参考值, 这些点被称为最佳临界点, 点对应的值被称为最佳临界值。

从实验结果可以看出, 若选取单一特征进行分类, 相似度特征的表现最佳, 其次为奇异值特征, 计算奇异值的过程可认为提取出更有效的特征而忽略部分无用信息。峭度因子特征在低信噪比情况下作用明显下降。将各特征空间进行关联后, 算法检测率上升, 虚警率降低, 因此本实验证明, 通过特征空间关联能够提升方法的检测性能。

图 3 为不同信噪比情况下统计特征空间关联方法的 ROC 曲线。从图 3 可看出, 随着图像信噪比的提高, 算法的检测性能随之增强。当目标信噪比低至 -1 dB 以下时, 算法仍表现出良好的性能; 目标信噪比低至 -5 dB 时, 检测性能开始明显下降; 目标信噪比达到 -7 dB 时算法失效。

研究时序窗口的划分对算法性能的影响规律。系统采样频率为 $30 \text{ frame} \cdot \text{s}^{-1}$, 仿真目标大小为 $3 \text{ pixel} \times 3 \text{ pixel}$, 速度为 $6 \text{ pixel} \cdot \text{s}^{-1}$ 。使用不同大小的时序窗口进行目标检测, 对应的检测率曲线如图 4 所示。

通过实验分析可以得到, 时序窗口的划分规则为采样频率与目标区域驻留时间 $2 \sim 3$ 倍的乘积。该实验中目标区域驻留时间为 0.5 s 。计算得到最佳的时序窗口为 $30 \sim 45$, 与实验结果一致。此外还可以得出, 时间窗口越小则关联特征的变化越明显, 但是对

应的稳定性会降低, 而当窗口选取得过大时, 关联特征的灵敏度降低, 不易检测出暗弱运动目标。处理窗口 W 固定时, 目标驻留时间为 W 与采样频率比值的 $1/10$ 左右时达到检测极限。

为进一步验证算法的性能, 在目标信噪比为 -2 dB 时, 将文中方法与最大中值滤波 (Max-median)、最大均值滤波 (Max-mean)、小波变换 (Wavelet transform)、背景建模 (Background modeling) 以及 Top-hat 滤波 5 种经典运动目标检测方法的结果进行对比分析, 如图 5 所示。

表 1 列出了上述 5 种方法的检测率、虚警率和 AUC (Area Under the ROC Curve) 等指标。其中 AUC 是指 ROC 曲线与 $(1, 0)$ 和 $(1, 1)$ 点围绕的面积, 只要 ROC 曲线下的面积大于 0.5 , 即证明该检测实验




图 4 不同时序窗口

Fig. 4 Comparison of different windows




图 3 不同信噪比 ROC 对比

Fig. 3 ROC comparison diagram of different signal-to-noise ratios




图 5 不同方法 ROC 对比

Fig. 5 ROC comparison diagram of different methods

具有一定的检测价值。同时, AUC 越接近 1, 说明算法检测性能越好。

从实验结果可以看出, 本文方法的检测性能无论检测率、虚警率还是 AUC 指数都是最佳的。其他算法的检测率最高为 92.80%, AUC 指数最高为 0.9771, 虚警率最低为 8.54%。本文方法的检测率为 96.82%, 高出其他算法 4.02%; AUC 指数为 0.9915, 高出 0.0144; 虚警率为 3.23%, 减少了 5.31%。这充分验证了本文方法在暗弱小天体目标检测中的可靠性。

2.2 暗弱小天体检测实验

为分析算法对于真实暗弱小天体运动目标的检测性能, 进行暗弱小天体检测实验。利用中国科学院国家天文台 50 cm 口径天文望远镜拍摄的一段近地小行星图像序列进行检测, 原始单帧图像如图 6 所示, 单像元规格为 6.5 mm, 望远镜焦比 $f/9.5$, 使用凝视模式, 让目标划过视场, 采取短积分拍摄图像进行处理。获取到大小为 2048×2048 、图像帧数为 100、

信噪比为 -3 dB 的图像序列, 小行星目标完全湮没在背景和噪声之中, 属于极暗弱目标。处理系统为移动工作站, CPU 具体型号为 Intel(R) Xeon(R) W-10855 M CPU @ 2.80 GHz, 处理时间约 2 h。

经过本文方法检测后的结果如图 7(a)所示, 背景建模、最大均值滤波和 Top-hat 滤波的检测结果分别如图 7(b)~(d)所示。表 2 列出了上述 4 种检测方法的虚警率和检测率。信噪比计算公式为 $SNR = (\mu_t - \mu_b)/\sigma$, 其中 μ_t 和 μ_b 分别为目标和背景均值, σ 为背景标准差。正样本分类准确率 D 表示正类样本被正确分类的数目占有所有正类样本的比例, 这里正类样本即为目标轨迹; 负样本分类准确率 F 表示负类样本中被正确分类的数目占有所有负类样本的比例(负类样本即除去目标轨迹的所有像元数目)。本文检测方法结果清晰, 在信噪比、正负样本检测率方面均有显著提升, 相比检测率最高的背景建模方法(63.16%)提高了 11.12%, 达到 74.28%。同时将负样本分类错误率降至 0.16%, 验证了该算法在暗弱小天体运动目标检测中的有效性和泛化性。

3 结论

针对信噪比低的小天体目标检测问题, 提出一种基于统计特征空间提取和 SVM 的极暗弱小天体检测方法, 不直接依赖于目标能量的大小, 在极低信噪比下仍表现出稳定的检测性能。引入核函数的方法, 关联形成统计特征空间, 使该方法能够适应更低的信噪比。同时支持向量机(SVM)的方法将暗弱小天体检测问题转化为目标与背景的二分类问题, 解决了令传统算法棘手的阈值分割难题, 进一步增加了方法的鲁棒性与泛化性能。

本文方法比其他经典方法能够检测出更低信噪比的目标信号, 半物理仿真实验中, 在 -1 dB 以下时表现出良好的性能, 对 -7 dB 的目标信号仍有一定的检测能力。同时算法对较广的速度范围都具有有效性。为进一步发挥算法的性能, 还进行了不同时序窗口对检测率影响的实验。与其他经典的运动目标检测方法相比, 本文方法在信噪比极低的情况下更具优势。本文方法的检测率为 96.82%, AUC 指数为 0.9915, 比其他方法分别高出 4.02% 和 0.0144。虚警率为 3.23%, 比其他方法减少 5.31%。这充分验证了

表 1 不同方法实验结果对比

Table 1 Comparison of experimental results of different methods

方法	虚警率/(%)	检测率/(%)	AUC
背景建模	16.30	84.61	0.9193
Top-hat滤波	8.54	92.80	0.9771
最大中值滤波	22.50	86.10	0.9357
最大均值滤波	16.45	88.71	0.9431
小波变换	9.68	91.17	0.9677
文中方法	3.23	96.82	0.9915

注 AUC指ROC曲线与(1, 0)和(1, 1)点围绕的面积。




图 6 原始单帧图像

Fig. 6 Original single frame image




图 7 不同方法实验结果
Fig. 7 Experimental results of different methods

表 2 不同方法实验结果对比
Table 2 Comparison of experimental results of different methods

方法	信噪比	正样本分类 准确率/(%)	负样本分类 准确率/(%)
背景建模	37.14	63.16	96.97
Top-hat滤波	29.28	42.08	97.46
最大均值滤波	61.95	53.77	99.47
本文方法	98.44	74.28	99.84

本文方法在暗弱小天体运动目标检测中的可靠性。在真实采集的暗弱小天体目标检测实验中,也表现出比其他经典方法更优越的性能,正样本分类准确率增加至 74.28%,负样本分类错误率降低至 0.16%,充分验证了本文基于统计特征空间提取和 SVM 的极暗弱小天体检测方法的有效性和泛化性。

参考文献

[1] XUE D N, SUN J Q, HU Y Q, *et al.* Dim small target detection based on convolutinal neural network in star image[J]. *Multimedia Tools and Applications*, 2020, **79**(7): 4681-4698

[2] LI Y S, LI Z Z, ZHANG C, *et al.* Infrared maritime dim small target detection based on spatiotemporal cues and directional morphological filtering[J]. *Infrared Physics & Technology*, 2021, **115**: 103657

[3] BAI X Z, ZHOU F G. Analysis of new top-hat transformation and the application for infrared dim small target detection[J]. *Pattern Recognition*, 2010, **43**(6): 2145-2156

[4] MENG W, JIN T, ZHAO X W. Adaptive method of dim small object detection with heavy clutter[J]. *Applied Optics*, 2013, **52**(10): D64-D74

[5] XU Y L, WANG W H. A method for single frame detection of infrared dim small target in complex background [J]. *Journal of Physics: Conference Series*, 2020, **1634**(1):

- 012063
- [6] QI S X, MA J, TAO C, *et al.* A robust directional saliency-based method for infrared small-target detection under various complex backgrounds[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, **10**(3): 495-499
 - [7] YANG C C, MA J Y, ZHANG M F, *et al.* Multiscale facet model for infrared small target detection[J]. *Infrared Physics & Technology*, 2014, **67**: 202-209
 - [8] LI H, TAN Y H, LI Y S, *et al.* Image layering based small infrared target detection method[J]. *Electronics Letters*, 2014, **50**(1): 42-44
 - [9] CHEN C L P, LI H, WEI Y T, *et al.* A local contrast method for small infrared target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(1): 574-581
 - [10] GAO C Q, MENG D Y, YANG Y, *et al.* Infrared patch-image model for small target detection in a single image[J]. *IEEE Transactions on Image Processing*, 2013, **22**(12): 4996-5009
 - [11] HAN J H, MA Y, ZHOU B, *et al.* A robust infrared small target detection algorithm based on human visual system[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, **11**(12): 2168-2172
 - [12] HE L H, GE L. CamShift target tracking based on the combination of inter-frame difference and background difference[C]//2018 37 th Chinese Control Conference (CCC). Wuhan, China: IEEE, 2018: 889-893
 - [13] CHEN H, BOHUSH R P, CHEN C, *et al.* Estimation of people movement in video based on optical flow block method and motion maps[J]. *Pattern Recognition and Image Analysis*, 2021, **31**(2): 261-270
 - [14] ZHANG T, SONG C F. Object detection based on minimum convex hull and generalized Hough transform[J]. *IOP Conference Series: Materials Science and Engineering*, 2020, **768**(7): 072058
 - [15] TESTOLIN A, DIAMANT R. Combining denoising autoencoders and dynamic programming for acoustic detection and tracking of underwater moving targets[J]. *Sensors*, 2020, **20**(10): 2945
 - [16] BOSQUET B, MUCIENTES M, BREA V M. STDnet-ST: Spatio-temporal ConvNet for small object detection[J]. *Pattern Recognition*, 2021, **116**: 107929
 - [17] DU J M, LI D Y, DENG Y J, *et al.* Multiple frames based infrared small target detection method using CNN[C]//2021 4 th International Conference on Algorithms, Computing and Artificial Intelligence (ACAI 2021). Sanya, China: Association for Computing Machinery, 2021: 397-402
 - [18] KUMAR S S, ABRAHAM D M, JAHANSHAH M R, *et al.* Automated defect classification in sewer closed circuit television inspections using deep convolutional neural networks[J]. *Automation in Construction*, 2018, **91**: 273-283
 - [19] REDMON J, DIVVALA S, GIRSHICK R, *et al.* You only look once: Unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2015: 779-788
 - [20] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2016: 6517-6525
 - [21] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: Single shot MultiBox detector[C]//14 th European Conference on Computer Vision. Amsterdam, The Netherlands: Springer, 2016: 21-37
 - [22] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision. Santiago, Chile: IEEE, 2015: 1440-1448
 - [23] REN S Q, HE K M, GIRSHICK R, *et al.* Faster R-CNN: Towards real-time object detection with region proposal networks[C]//International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2015: 91-99
 - [24] HE K M, GEORGIA G, DOLLÁR P, *et al.* Mask R-CNN[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, **42**(2): 386-397
 - [25] PATAN G, BARSKY B A. An Introduction to Laplacian Spectral Distances and Kernels: Theory, Computation, and Applications[M]. San Rafael: Morgan & Claypool Publishers, 2017
 - [26] DESHPANDE S D, ER M H, VENKATESWARLU R, *et al.* Max-mean and max-median filters for detection of small targets[J]. *Proceedings of the SPIE*, 1999, **3809**: 74-83
 - [27] XU Y, LUO M Z, LI T, *et al.* ECG signal De-noising and baseline wander correction based on CEEMDAN and Wavelet Threshold[J]. *Sensors (Basel, Switzerland)*, 2017, **17**(12): 2754
 - [28] BOUWMANS T, EL BAF F, VACHON B. Background modeling using mixture of Gaussians for foreground detection-a survey[J]. *Recent Patents on Computer Science*, 2008, **1**(3): 219-237
 - [29] HADHOUD M M, THOMAS D W. The two-dimensional adaptive LMS (TDLMS) algorithm[J]. *IEEE Transactions on Circuits and Systems*, 1988, **35**(5): 485-494
 - [30] SONI T, ZEIDLER J R, KU W H. Performance evaluation of 2-D adaptive prediction filters for detection of small objects in image data[J]. *IEEE Transactions on Image Processing*, 1993, **2**(3): 327-340