

一种基于稀疏化核方法的红外强杂波背景抑制算法

朱 斌^{1,2}, 樊 祥^{1,2}, 程正东^{1,2}, 王 迪¹, 方义强¹, 陈晓斯¹

(1. 脉冲功率激光技术国家重点实验室, 安徽合肥 230037; 2. 电子工程学院光电系, 安徽合肥 230037)

摘 要: 杂波背景抑制一直是红外弱小目标检测面临的难题. 背景抑制可分为背景预测和差分滤波两步. 针对强杂波背景呈现非线性分布的特征, 提出了一种基于稀疏化核递推最小二乘(KRLS)算法的非线性背景抑制算法. 算法采用监督学习模型, 使用序列图像作为训练样本. 通过稀疏化控制学习函数的复杂度并剔除冗余信息, 不但可以提高学习机器的推广能力, 还可以降低运算量. 使用真实红外图像对算法进行了测试, 并分析了算法参数. 实验结果表明: 算法可自适应预测不同类型的强杂波背景, 并有效抑制背景杂波.

关键词: 红外背景抑制; 强杂波; 背景预测; 稀疏; 核递推最小二乘

中图分类号: TN 911.73

文献标识码: A

文章编号: 0372-2112 (2015)04-0716-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2015.04.013

An IR Strong Clutter Background Suppression Algorithm Based on Sparse Kernel Method

ZHU Bin^{1,2}, FAN Xiang^{1,2}, CHENG Zheng-dong^{1,2}, WANG Di¹, FANG Yi-qiang¹, CHEN Xiao-si¹

(1. State Key Laboratory of Pulsed Power Laser Technology, Electronic Engineering Institute, Hefei, Anhui 230037, China;

2. Department of Opto-Electronic, Electronic Engineering Institute, Hefei, Anhui 230037, China)

Abstract: Clutter background suppression is always a difficulty of infrared (IR) dim and point target detection. Background suppression is divided into background estimation and difference filtering. Aiming at the nonlinear distribution of strong clutter background, a sparse kernel recursive least squares (KRLS) based nonlinear background suppression algorithm is proposed. This method uses sequence images as training sample in supervised learning model. The complexity of learned function is controlled, and the redundant information is discarded by sparsification. In this way, the generalization of learning machine can be enhanced; moreover, the computational burden can be reduced. In the experiments, real IR images are used to test the algorithm, and the parameters are analyzed. Experimental results show that different kinds of strong clutter background can be estimated, and then be suppressed.

Key words: IR background suppression; strong clutter; background estimation; sparse; kernel recursive least squares

1 引言

弱小目标在红外图像中通常不超过 10 个像素, 身处云层、地物、建筑等强杂波背景之中使得这类目标难以检测. 因此, 抑制杂波背景是小目标检测的第一步, 也是最重要的一步, 能大大提高后续目标检测阶段算法的性能^[1]. 基于监督学习的背景预测技术是诸多背景抑制算法中的一类^[2,3]. 这类算法是用目标周围的背景像素来替代目标像素, 从而预测出一幅没有目标的图像; 然后再用原始图像减去预测出的图像得到只有目标和少量背景的残差图像; 最后在残差图像上做门限检测得到弱小目标.

杂波背景的存在使得红外图像的背景往往呈现出

非线性分布的特点. 在这种情况下, 二维最小均方 (2D Least Mean Square, TDLMS) 自适应滤波^[4]等线性回归算法的性能将变差. 相反, 核最小二乘 (Kernel Least Squares, KLS) 和指数加权核最小二乘 (Exponential Weighted Kernel Least Squares, EWKLS) 等非线性算法的性能要优于线性算法^[2,3]. 然而, 由于核矩阵的大小等于输入训练样本的个数, 离线的非线性运算将带来巨大的计算负担. 因此, 大多数情况下人们更倾向于使用在线算法, 即迭代算法来替代离线算法.

另一方面, 为了让监督学习算法获得尽可能好的推广能力, 需要研究稀疏解来控制学习算法的复杂度. 如果函数集过于复杂, 特定数据集上将可能拟合出与实际不符的模式 (过拟合); 相反, 过于简单的函数集又可能

不足以拟合出数据集中潜在的真实关系(欠拟合)^[5]. KRLS 算法是经典 RLS 算法的核版本(非线性版本),使用在线构建方式获得稀疏解^[6],满足红外图像强杂波背景抑制应用中的在线与稀疏性的要求^[7].

本文引入 KRLS 算法,建立了一个用于红外背景抑制的监督学习模型,提出了基于 KRLS 的红外背景抑制算法.最后,使用真实的红外小目标图像检验了所提算法的性能,并分析了算法的参数.

2 核 RLS 算法

2.1 核方法

核方法广泛应用于解决分类和回归问题^[8,9],其基本思想是:使用某一非线性映射 φ 将输入空间的数据 \mathbf{x}_i 转换到高维特征空间;在该特征空间中,使用一个满足 Mercer 条件的核函数来计算内积^[8];从而可以在高维特征空间中使用线性算法解决原始数据空间中的非线性问题.核方法的典型解如式(1)所示

$$\hat{f}(\mathbf{x}) = \sum_{i=1}^l \alpha_i k(\mathbf{x}_i, \mathbf{x}) \quad (1)$$

式中, $\{\mathbf{x}_i\}_{i=1}^l$ 是训练数据点集, $\{\alpha_i\}_{i=1}^l$ 是系数, $k(\mathbf{x}_i, \mathbf{x}) = \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}) \rangle$ 是一个正定核函数.

2.2 在线稀疏

在核方法的解中,参数 α_i 的个数等于训练样本集的大小,因此有必要引入正则化.而稀疏就是一种正则化的方法.

当使用在线学习方式时,到 t 时刻,对 f 的估计如式(1)所示,其本质是一个希尔伯特空间 \mathcal{H} 中的线性估计,即

$$\hat{f}(\mathbf{x}) = \sum_{i=1}^l \alpha_i \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}) \rangle \quad (2)$$

原始方法在求解最小二乘问题时,将所有的输入向量 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_l$ 纳入计算范围.这将导致算法的复杂度随样本的增加而增大.如果数据点 $\{\mathbf{x}_i\}_{i=1}^l$ 满足 $\varphi(\mathbf{x}_i) = \sum_{i=1}^{t-1} \alpha_i \varphi(\mathbf{x}_i)$, 则 t 时刻以及所有 $i > t$ 时刻的预测函数 \hat{f} 中都可以不需要再考虑 $\varphi(\mathbf{x}_i)$ 的非零系数,因为 $\varphi(\mathbf{x}_i)$ 能被其它样本线性表示.

然而, $\varphi(\mathbf{x}_i)$ 与 $\{\varphi(\mathbf{x}_i)\}_{i=1}^l$ 之间常常无法满足严格线性相关.为此,文献[6]提出了使用近似线性相关条件(Approximate Linear Dependency, ALD)来代替严格线性相关.假设已经存在这样一个由独立样本 $\{\varphi(\tilde{\mathbf{x}}_j)\}_{j=1}^{m_i-1}$ 组成的字典(dictionary),则 ALD 条件可写为

$$\delta_t \triangleq \min_a \left\| \sum_{j=1}^{m_i-1} a_j \varphi(\tilde{\mathbf{x}}_j) - \varphi(\mathbf{x}_t) \right\|^2 \leq \nu \quad (3)$$

式中, ν 是控制逼近精度的参数,它决定了稀疏化的程度.如果满足式(3)的 ALD 条件, $\varphi(\mathbf{x}_t)$ 就能被当前字典中向量的某一线性组合以平方误差 ν 来逼近.

这时,接收到一个新样本 \mathbf{x}_t ,测试 $\varphi(\mathbf{x}_t)$ 与字典中的特征向量是否满足 ALD 条件:如果 \mathbf{x}_t 的特征值 $\varphi(\mathbf{x}_t)$ 与过去的样本近似线性相关,则只考虑这个样本对预测函数 \hat{f} 中已存在的系数产生的影响;如果 \mathbf{x}_t 的特征值 $\varphi(\mathbf{x}_t)$ 与过去的样本不近似线性相关,则将其添加进字典,而与 $\varphi(\mathbf{x}_t)$ 对应的系数 a_t 也被加入预测函数 \hat{f} 中.这样的话,直到 t 时刻的所有训练样本都能表示成字典中向量的线性组合.

最小化式(3),可以得到最优系数向量 $\mathbf{a}_t = (a_1, \dots, a_{m_t})^T$,同时能判断 $\varphi(\mathbf{x}_t)$ 是否满足 ALD 条件,求解后最优 \mathbf{a}_t 和 ALD 条件分别为

$$\mathbf{a}_t = \tilde{\mathbf{K}}_{t-1}^{-1} \tilde{\mathbf{k}}_{t-1}(\mathbf{x}_t), \delta_t = k_u - \tilde{\mathbf{k}}_{t-1}(\mathbf{x}_t)^T \mathbf{a}_t \leq \nu \quad (4)$$

式中, $\tilde{\mathbf{K}}$ 为稀疏后的核矩阵, $[\tilde{\mathbf{K}}_{t-1}]_{i,j} = k(\tilde{\mathbf{x}}_i, \tilde{\mathbf{x}}_j)$, $[\tilde{\mathbf{k}}_{t-1}(\mathbf{x}_t)]_i = k(\tilde{\mathbf{x}}_i, \mathbf{x}_t)$, $k_u = k(\mathbf{x}_t, \mathbf{x}_t)$. 如果 $\delta_t > \nu$, 则扩展现有的字典 $D_t = D_{t-1} \cup \{\mathbf{x}_t\}$, $m_t = m_{t-1} + 1$. 使用扩展后的字典, $\varphi(\mathbf{x}_t)$ 可由它自己精确表示,因此 δ_t 设置为 0. 如果 $\delta_t \leq \nu$, 则 $D_t = D_{t-1}$, $m_t = m_{t-1}$. 因此,对于每一个时刻 i 直至 t , 通过选择一个充分小的 ν , 可使 $\varphi(\mathbf{x}_i) \approx \sum_{j=1}^{m_i} a_{i,j} \varphi(\tilde{\mathbf{x}}_j)$ 的逼近误差任意小. 相应的核矩阵的逼近为 $\mathbf{K}_t \approx \mathbf{A}_t \tilde{\mathbf{K}}_t \mathbf{A}_t^T$, 式中, $[\tilde{\mathbf{K}}_t]_{i,j} = k(\tilde{\mathbf{x}}_i, \tilde{\mathbf{x}}_j)$, $i, j = 1, \dots, t$ 为完整的核矩阵, $[\mathbf{A}_t]_{i,j} = a_{i,j}$. 在实际中,当 $\nu > 0$ 时,在接受的误差范围内可以使用逼近 $\mathbf{K}_t = \mathbf{A}_t \tilde{\mathbf{K}}_t \mathbf{A}_t^T$ 来计算 \mathbf{K}_t .

2.3 核 RLS 算法

原始的 RLS 算法形式中,在每一时刻 t 都最小化误差平方和

$$L(\mathbf{w}) = \sum_{i=1}^t (f(\mathbf{x}_i) - y_i)^2 = \|\Phi_t^T \mathbf{w} - \mathbf{y}_t\|^2 \quad (5)$$

式中, $\Phi_t = [\varphi(\mathbf{x}_1), \dots, \varphi(\mathbf{x}_t)]$, $\mathbf{y}_t = (y_1, \dots, y_t)^T$. 最小化式(5)得 $\mathbf{w}_t = (\Phi_t^T)^+ \mathbf{y}_t$, $(\cdot)^+$ 表示伪逆.经典的 RLS 算法基于矩阵求逆引理,允许以在线形式最小化损失 $L(\mathbf{w})$, 这样就不需要在每一时刻都重复计算矩阵 $(\Phi_t^T)^+$. 最优权向量可写为

$$\mathbf{w}_t = \sum_{i=1}^t \alpha_i \varphi(\mathbf{x}_i) = \Phi_t \boldsymbol{\alpha} \quad (6)$$

式中, $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_t)^T$. 将式(6)代入式(5)得

$$L(\boldsymbol{\alpha}) = \|\mathbf{K}_t \boldsymbol{\alpha} - \mathbf{y}_t\|^2 \quad (7)$$

理论上,最小化式(7)的结果由 $\boldsymbol{\alpha}_t = \mathbf{K}_t^+ \mathbf{y}_t$ 给出,而它能用经典 RLS 算法迭代计算.

KRLS 算法的基本思路是使用上文已定义的通过在线稀疏获得的更小的矩阵 $\tilde{\mathbf{K}}_t$ 替代 \mathbf{K}_t . 使用 $\mathbf{w}_t = \Phi_t \boldsymbol{\alpha}_t \approx \tilde{\Phi}_t \tilde{\mathbf{A}}_t^T \boldsymbol{\alpha}_t = \tilde{\Phi}_t \tilde{\boldsymbol{\alpha}}_t$, 式中, $\tilde{\mathbf{A}}_t = \mathbf{A}_t^T \mathbf{A}_t$, 则损失变为

$$L(\tilde{\boldsymbol{\alpha}}) = \|\Phi_t^T \tilde{\Phi}_t \tilde{\boldsymbol{\alpha}} - \mathbf{y}_t\|^2 = \|\mathbf{A}_t \tilde{\mathbf{K}}_t \tilde{\boldsymbol{\alpha}} - \mathbf{y}_t\|^2 \quad (8)$$

它的最小化结果为

$$\tilde{\boldsymbol{\alpha}}_t = (\mathbf{A}_t \tilde{\mathbf{K}}_t)^+ \mathbf{y}_t = \tilde{\mathbf{K}}_t^{-1} (\mathbf{A}_t^T \mathbf{A}_t)^{-1} \mathbf{A}_t^T \mathbf{y}_t \quad (9)$$

因此,在在线情况下,KRLS算法的更新方程如下:

(1)如果 $\varphi(\mathbf{x}_t)$ 在 D_{t-1} 上满足 ALD 条件,即 $\delta_t \leq \nu$, 则 $\tilde{\mathbf{a}}_t$ 由式(9)给出, $D_t = D_{t-1}$, $m_t = m_{t-1}$ 且 $\tilde{\mathbf{K}}_t = \tilde{\mathbf{K}}_{t-1}$, 只有 \mathbf{A} 发生改变 $\mathbf{A}_t = [\mathbf{A}_{t-1}^T, \mathbf{a}_t]^T$. 在这种情况下,KRLS 算法中 $\tilde{\mathbf{a}}_t$ 的更新规则为

$$\tilde{\mathbf{a}}_t = \tilde{\mathbf{a}}_{t-1} + \tilde{\mathbf{K}}_t^{-1} \mathbf{q}_t - \tilde{\mathbf{k}}_{t-1}(\mathbf{x}_t)^T \tilde{\mathbf{a}}_{t-1} \quad (10)$$

式中,

$$\mathbf{q}_t = \mathbf{P}_{t-1} \mathbf{a}_t / (1 + \mathbf{a}_t^T \mathbf{P}_{t-1} \mathbf{a}_t)$$

$$\mathbf{P}_t = \mathbf{P}_{t-1} - \mathbf{P}_{t-1} \mathbf{a}_t \mathbf{a}_t^T \mathbf{P}_{t-1} / (1 + \mathbf{a}_t^T \mathbf{P}_{t-1} \mathbf{a}_t)$$

(2)如果 $\varphi(\mathbf{x}_t)$ 在 D_{t-1} 上不满足 ALD 条件,即 $\delta_t > \nu$, \mathbf{x}_t 被加入字典 $D_t = D_{t-1} \cup \{\mathbf{x}_t\}$, $m_t = m_{t-1} + 1$ 且 $\tilde{\mathbf{K}}_t$ 也相应增加. $\tilde{\mathbf{K}}_t^{-1}$ 的递推方程为

$$\tilde{\mathbf{K}}_t^{-1} = \frac{1}{\delta_t} \begin{bmatrix} \delta \tilde{\mathbf{K}}_{t-1}^{-1} + \mathbf{a}_t \mathbf{a}_t^T & -\mathbf{a}_t \\ -\mathbf{a}_t^T & 1 \end{bmatrix} \quad (11)$$

式中, \mathbf{a}_t 和 δ_t 是用式(4)进行 ALD 测试后得到的变量. 随着字典更新, \mathbf{x}_t 加入了字典 D_t , $\varphi(\mathbf{x}_t)$ 可以由其自己精确表示.

因此

$$\mathbf{A}_t = \begin{bmatrix} \mathbf{A}_{t-1} & \mathbf{0} \\ \mathbf{0}^T & 1 \end{bmatrix}, \mathbf{A}_t^T \mathbf{A}_t = \begin{bmatrix} \mathbf{A}_{t-1}^T \mathbf{A}_{t-1} & \mathbf{0} \\ \mathbf{0}^T & 1 \end{bmatrix}$$

$$\mathbf{P}_t = (\mathbf{A}_t^T \mathbf{A}_t)^{-1} = \begin{bmatrix} \mathbf{P}_{t-1} & \mathbf{0} \\ \mathbf{0}^T & 1 \end{bmatrix}$$

KRLS 算法中 $\tilde{\mathbf{a}}_t$ 的更新规则为

$$\tilde{\mathbf{a}}_t = \begin{bmatrix} \tilde{\mathbf{a}}_{t-1} - \mathbf{a}_t (\mathbf{y}_t - \tilde{\mathbf{k}}_{t-1}(\mathbf{x}_t)^T \tilde{\mathbf{a}}_{t-1}) / \delta_t \\ (\mathbf{y}_t - \tilde{\mathbf{k}}_{t-1}(\mathbf{x}_t)^T \tilde{\mathbf{a}}_{t-1}) / \delta_t \end{bmatrix} \quad (12)$$

因为 $\tilde{\mathbf{a}}_t = (\tilde{\alpha}_1, \dots, \tilde{\alpha}_{m_t})^T$, 对样本 \mathbf{x}_{t+1} 的估计可以由式(13)计算

$$\hat{f}(\mathbf{x}_{t+1}) = \sum_{i=1}^t \alpha_i k(\mathbf{x}_i, \mathbf{x}_{t+1}) \approx \sum_{i=1}^{m_t} \tilde{\alpha}_i k(\tilde{\mathbf{x}}_i, \mathbf{x}_{t+1}) \quad (13)$$

式中, $\tilde{\alpha}_i$ 通过式(10)、(12)更新, 字典向量 $\tilde{\mathbf{x}}_i$, ($i = 1, \dots, m_t$) 通过在线稀疏获得, $k(\cdot, \cdot)$ 是核函数.

3 基于核 RLS 的红外背景抑制算法

3.1 背景预测模型

本节建立了一个用于红外背景抑制的在线监督学习算法模型. 模型中, 训练样本是从第 1 帧到第 t 帧的数据, 测试样本是第 $t+1$ 帧的数据. 因为弱小目标的像素数目远小于背景, 而其移动速度却比背景要快得多, 所以预测出的灰度值更接近于背景的灰度.

设 (m, n) 是图像中的坐标, $y_i(m, n)$ 和 $\hat{y}_i(m, n)$ 分别是第 i 帧, 像素点 (m, n) 处的原始和预测出来的背景灰度值. 以预测 $\hat{y}_{t+1}(m, n)$ 为例, 如果有 t 个连续帧用于训练, 则有 t 个训练样本, 记为 $\{\mathbf{x}_i\}_{i=1}^t$, 其中 \mathbf{x}_i 是由像素 (m, n) 周围特定区域(如矩形窗口)内的灰度值 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{i24})^T$ 构成的向量, 图 1 所示为一个 5×5

预测窗口内样本向量 \mathbf{x}_i 的结构形式.

每个样本 $\{\mathbf{x}_i\}_{i=1}^t$ 都要用式(4)进行 ALD 测试. 只有不满足 ALD 条件的样本向量被保留到字典中, 并称之为字典向量 $\{\tilde{\mathbf{x}}_i\}_{i=1}^{m_t}$, ($m_t < t$). 使用字典向量 $\{\tilde{\mathbf{x}}_i\}_{i=1}^{m_t}$ 和选定的核函数 $k(\cdot, \cdot)$, 通过式(13)就可以预测得到 $\hat{y}_i(m, n)$. 接下来, 预测窗将逐个像素滑过整幅图像, 直至预测出 1 帧完整的背景图像.




图1 预测窗口与样本向量 \mathbf{x}_i 的构造

3.2 背景抑制算法

基于稀疏化 KRLS 的背景抑制算法的流程图如图 2 所示, 具体步骤如下:

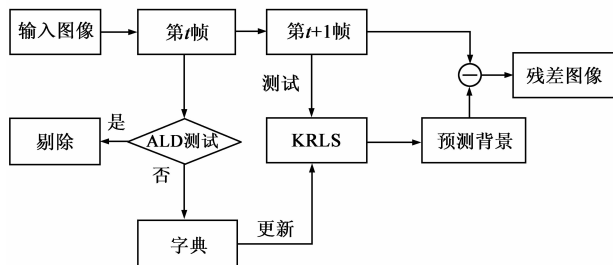


图2 基于稀疏化 KRLS 的背景抑制算法流程

步骤 1: 假设 t 时刻, 在测试了 $t-1$ 个训练样本后, 得到一个由近似线性独立的样本向量构成的字典 $D_{t-1} = \{\mathbf{x}_i\}_{i=1}^{m_{t-1}}$.

步骤 2: 当新样本 \mathbf{x}_t 到来后, 首先对其进行 ALD 测试: 如果 \mathbf{x}_t 满足式(4), 则将其剔除, 且 $D_t = D_{t-1}$; 反之, 则将其添加进当前字典 $D_t = D_{t-1} \cup \{\mathbf{x}_t\}$.

步骤 3: 用新字典 D_t , 结合式(10)或(12)更新 KRLS 学习机器.

步骤 4: 用第 $t+1$ 帧作为测试样本, 结合式(13)预测背景灰度值.

步骤 5: 用第 $t+1$ 帧原始图像减去预测出来的背景图像得到没有背景分量的残差图像. 再对残差图像进行门限分割获得候选目标.

步骤 6: 下一轮预测, 新样本 \mathbf{x}_{t+1} 到来后, 回到步骤 2, 使用字典 D_{t+1} 来预测第 $t+2$ 帧的背景.

4 实验与参数分析

为验证所提算法的性能, 使用包含不同类型背景

的真实红外点目标图像进行了测试. 图像尺寸为 178×256 像素, 图像中的点目标为远距离的飞机. 因为 KEWLS 与 KLS 算法的性能非常接近, 所以仅选择 KLS 算法和 TDLMS 算法用于对比参考. 所有测试均在 3GHz Pentium 4 处理器, 1G 内存的计算机上完成, 仿真软件为 Matlab 2009a.

信噪比增益 $G_{\text{SNR}} = \text{SNR}_{\text{out}} / \text{SNR}_{\text{in}}$, 背景抑制系数 $\text{BSF} = \sigma_{\text{in}} / \sigma_{\text{out}}$ 和单帧处理时间 T_{PF} 三个指标被用来评价算法的性能^[7]. 信噪比定义为 $\text{SNR} = f_{\text{max}} / (\mu + \sigma)$, f_{max} 是目标的最大灰度值, μ 、 σ 分别为图像的灰度均值和均方差. G_{SNR} 是衡量算法性能的重要指标, 背景预测越准确 G_{SNR} 就越高; BSF 中 σ_{in} 和 σ_{out} 分别为原始图像和滤波残差图像的背景灰度均方差, BSF 反映了算法抑制背景的能力; 而单帧运算时间 T_{PF} 用于评价算法的运算量.

(1) KRLS 与 KLS、TDLMS 算法的比较

图 3 所示为 4 组强杂波背景(云层、地物、建筑和树

木, 在图 3 中分别用 (a), (b), (c), (d) 四行表示. 第 1 列为原始图像)红外图像的背景抑制实验结果. 实验使用连续 30 帧图像用于训练, 第 31 帧用于测试. 其中, DVs(Dictionary Vectors)为经 KRLS 算法稀疏后的字典向量的总数, DVs 分布图(第 2 列)指的是图像不同位置的字典向量数目: 亮的位置字典向量多, 暗的位置字典向量少. 从 DVs 分布可以看出: 目标及背景较复杂的区域字典向量较多, 而平稳背景区域字典向量较少, 甚至只有 1 个. 也就是说, 通过稀疏, 有用信息被保留下来, 而无用和冗余信息则被剔除了. DVs 的这种分布特性, 保证了预测复杂区域背景时有足够的信息量, 同时, 极大地精简了平稳区域的冗余信息. 第 3 列图是 KRLS 算法预测出的背景, 从图中可以看出, 目标区的高灰度值被分散到了其周围区域. 因此, KRLS 算法的残差图像(第 4 列)中目标得以从背景中突显出来. 第 5 列和第 6 列图分别为 KLS 和 TDLMS 算法的残差图像.




图3 不同类型的强杂波背景实验结果

表 1 为 KLS 和 KRLS($t = 5, c = 0.2, \nu = 0.6, \sigma = 25$, 使用高斯核函数)算法的性能, 实验中未刻意选择参数. KRLS 算法的 G_{SNR} 和 T_{PF} 要优于 KLS 算法; 而 BSF 指标比较接近. 实验结果说明, 冗余信息将影响算法性能, 这也是 KRLS 算法用更少的样本, 性能却更高的原

因. 图 4 为 KLS 和 KRLS 算法的 T_{PF} 指标. 由图可知, KLS 的运算时间随样本数增加而迅速增长; KRLS 算法因采用在线运算和稀疏化, 运算时间随样本数增加而增长并不明显.




图4 样本数目与KLS和KRLS算法 T_{PF} 的关系

表 1 TDLMS, KLS 和 KRLS 算法的性能

| 性 能 \ 图 像 | | 图 3 (a) | 图 3 (b) | 图 3 (c) | 图 3 (d) |
|-----------|---------------|---------|---------|---------|---------|
| | | | | | |
| TDLMS | SNR_{in} | 1.143 | 1.522 | 3.187 | 5.164 |
| | σ_{in} | 5.878 | 23.347 | 46.397 | 42.584 |
| | G_{SNR} | 2.2492 | 4.2888 | 3.9165 | 3.1099 |
| | BSF | 3.0984 | 2.3727 | 3.2841 | 2.6764 |
| | $T_{PF}(s)$ | 7.2969 | 7.9531 | 8.4375 | 8.4531 |
| KLS | G_{SNR} | 1.907 | 11.959 | 4.729 | 3.697 |
| | BSF | 8.476 | 10.627 | 6.549 | 8.060 |
| | $T_{PF}(s)$ | 39.357 | 39.347 | 39.196 | 40.128 |
| KRIS | G_{SNR} | 3.033 | 17.430 | 5.478 | 3.899 |
| | BSF | 8.794 | 10.536 | 6.320 | 7.712 |
| | $T_{PF}(s)$ | 13.059 | 13.149 | 12.858 | 12.939 |

(2)参数分析

本组实验使用 20 组真实红外图像,测试了稀疏化 KRLS 算法的参数 σ 和 ν . 这两个参数都会影响 ALD 测试. 实验结果为 20 组实验结果的平均值. DVP 为字典向量数占样本向量总数的比例,用以衡量稀疏化的程度.

固定 $\nu = 0.6$, $t = 30$, 使用 6 组图像测试了高斯核函数的参数 σ , 结果如表 2 所示. G_{SNR} 和 BSF 没有随 σ 的增加而单调增长,而是在 $\sigma = 200$ 时出现最大值. DVP 随着 σ 的增加而减少,而处理时间 T_{PF} 随着稀疏程度的提高而减少.

表 2 σ 与 KRLS 算法性能的关系

| σ | 4.4 | 25 | 50 | 100 | 200 | 400 |
|-----------|--------|--------|--------|--------|--------|--------|
| G_{SNR} | 2.467 | 4.266 | 6.357 | 6.987 | 7.298 | 7.175 |
| BSF | 1.427 | 6.294 | 9.57 | 13.33 | 14.709 | 13.86 |
| T_{PF} | 64.766 | 16.512 | 15.832 | 15.823 | 15.786 | 15.727 |
| DVP | 58.429 | 3.644 | 3.39 | 3.362 | 3.343 | 3.331 |

固定 $\sigma = 200$, $t = 30$, 测试不同 ν 对算法性能的影响. 实验结果如表 3 所示. 由式(3)可知, ν 控制了稀疏程度,字典向量数目会随着 ν 的增大而降低. 当 $0.1 < \nu < 1$ 时, G_{SNR} 和 T_{PF} 的变化不大,因为字典几乎不变;当 $0.001 < \nu < 0.1$ 时,随着更多向量加入字典, G_{SNR} , BSF 和 T_{PF} 都有较大变化. 对 G_{SNR} 而言,没有单调变化的规

律,但考虑到运算时间,建议选择 $0.1 < \nu < 1$.

表 3 ν 与 KRLS 算法性能的关系

| ν | 0.001 | 0.01 | 0.1 | 0.6 | 0.8 | 1 |
|-----------|--------|--------|--------|--------|--------|--------|
| G_{SNR} | 9.274 | 7.515 | 7.141 | 7.298 | 7.221 | 7.172 |
| BSF | 21.331 | 17.681 | 16.094 | 14.709 | 13.434 | 12.141 |
| T_{PF} | 31.742 | 17.611 | 15.894 | 15.786 | 15.743 | 15.729 |
| DVP | 18.39 | 3.891 | 3.369 | 3.343 | 3.338 | 3.33 |

5 结论

本文提出了一种基于稀疏化 KRLS 的红外背景抑制算法,并分析了算法的性能. 对背景预测而言,不是每个样本都是必需的. 冗余信息可能会导致拟合出错误的结果. 因此,通过稀疏化剔除冗余样本,可以达到提高预测准确性和降低运算负担的目的. 实验结果说明稀疏化 KRLS 算法的性能优于 KLS 和 TDLMS 算法,然而还有很多工作有待进一步深入,例如核函数的优化与选择问题等.

参考文献

[1] Stephen J Searle. Background modeling and target segmentation via modified Kalman filtering[A]. Proc SPIE 5428, Signal and Data Processing of Small Target 2004[C]. SPIE, 2004, 13 - 24.

[2] 朱斌,樊祥,马东辉,等. 核最小二乘算法检测红外点目标[J]. 光电工程, 2009, 36(9): 29 - 34.

Bin Zhu, Xiang Fan, Donghui Ma, et al. Infrared point target detection based on kernel least squares algorithm[J]. Opto-Electronic Engineering, 2009, 36(9): 29 - 34. (in Chinese)

[3] Bin Zhu, Xiang Fan, Donghui Ma, et al. Sequence IR images background estimation algorithm based on kernel exponential weighted least squares[A]. Proc SPIE 7495, MIPPR 2009: Automatic Target Recognition and Image Analysis[C]. SPIE, 2009, doi:10.1117/12.832993.

[4] Soni T, Zeidler J R, Ku H. Performance evaluation of 2-D adaptive prediction filters for detection of small objects in image data[J]. IEEE Trans on Image Processing, 1993, 2(3): 327 - 340.

[5] V N Vapnik. Statistical Learning Theory[M]. New York: John Wiley & Sons, Inc. 1998.

[6] Yaakov Engel, Shie Mannor, Ron Meir. The kernel recursive least-squares algorithm[J]. IEEE Trans on Signal Processing, 2004, 52(8): 2275 - 2285.

[7] Bin Zhu, Zhengdong Cheng, Xiang Fan, et al. Online sparse IR background estimation via KRLS[A]. 2010 IEEE International Conference on Information and Automation(ICIA)[C]. IEEE, 2010. 1123 - 1127.

[8] John Shawe-Taylor, Nello Cristianini. Kernel Methods for Pat-

tern Analysis[M]. Cambridge University Press, 2004.

[9] Marcelo R P Ferreira, Francisco de A T de Carvalho. Kernel-based hard clustering methods in the feature space with auto-matic variable weighting [J]. Pattern Recognition, 2014, 47: 3082 – 3095.

作者简介



朱斌 男, 1982 年生于湖南湘潭. 电子工程学院讲师, 博士. 研究方向为红外图像处理、机器学习、探测与成像系统.
E-mail: zhubineei@163.com



樊祥 男, 1963 年生于安徽滁州. 电子工程学院教授, 博士生导师. 研究方向为光电对抗系统、信号与信息处理.