

流形正则化多核模型的模糊红外目标提取

杨 煦,付冬梅[✉]

北京科技大学自动化学院,北京 100083

[✉]通信作者,E-mail: fdm2003@163.com

摘要 针对模糊边缘的红外目标提取问题,提出一种基于流形正则化多核半监督分类的提取方法。首先应用最大类间方差法计算初始分割阈值,获得确定化的目标和背景区域以及待确定化的模糊边缘区域;然后建立各区域内像素点邻域空间集,并通过多核函数特征映射获得邻域空间中灰度均值和方差信息特征值,通过流形正则化获得邻域空间中位置信息特征值;在特征值基础上建立半监督分类模型对模糊边缘区域像素点邻域空间集进行类别划分;最后计算最佳分割阈值。对比实验结果表明,该方法提取模糊边缘红外目标效果好且运算效率高。

关键词 模糊边缘; 目标提取; 核函数; 流形正则化

分类号 TP391

Extraction of blurred infrared targets based on a manifold regularized multiple-kernel model

YANG Tao , FU Dong-mei[✉]

School of Automation and Electrical Engineering , University of Science and Technology Beijing , Beijing 100083 , China

[✉] Corresponding author , E-mail: fdm2003@163.com

ABSTRACT Specific to the problem of infrared target extraction with blurred edges , this article introduces an extraction method based on a manifold regularized multiple kernel semi-supervised classification model. Firstly , the maximum variance of inter-class (OTSU) method is used to compute the initial segmentation threshold , and the certain target and background areas and the uncertain blurred edge area are determined. Then , local space sets of pixels are constructed in each area , the multiple-kernel functions are used to map the grayscale mean and variance in local space , and the location information feature in local space is obtained by manifold regularization (MR) . On the basis of features , a semi-supervised classification model is established to classify the local space sets of pixels in the blurred edge area. Finally , the optimal segmentation threshold is computed. Experiments with comparisons show that this method is efficient and less in time-consuming.

KEY WORDS blurred edge; target extraction; kernel functions; manifold regularization

红外图像是以图像形式表达的红外探测设备测量物体表面温度分布信息的成像技术,使人眼不能直接看到的表面温度分布转化为可以看到的热图像,能够作为工业生产的重要测温和诊断手段以及军事中夜视设备等重要技术。由于红外图像可观察到目标物体与周围环境温度场分布,从而图像往往是模糊的,尤其是图像中目标与周围环境接触的边缘区域,无其他外在

条件时其温度场变化随着时间增加而愈加缓慢,使得边缘区域更为模糊,这种情况在红外热痕迹图像中更加明显。红外热痕迹图像中的目标边缘带有很强的模糊性,以红外热像仪(AVIO-H2600)拍摄的手部红外图像为例,在环境温度为 27.2 ℃ 的条件下,背景物体为木板,手部在木板上平放,拍摄手部离开木板后的热痕迹图像如图 1 所示。从图中可知,随着时间增加,目标

的边缘区域的模糊性增强。

本文的研究对象就是图 1(b) 和图 1(c) ,这类具有独特特点的红外热痕迹图像。由于图像中的目标是热源经过一定时间热交换后,所接触背景物体表面的热痕迹区域,在温度分布扩散作用下,此区域出现很强

的模糊边缘。与一般实际红外图像不同,一般的红外图像中目标是热源,且图像获取的是热源在被拍摄时间点处的温度分布信息;而图 1(b) 和图 1(c) 中目标是热痕迹,且经过一定时间,温度分布已向周围区域变化。

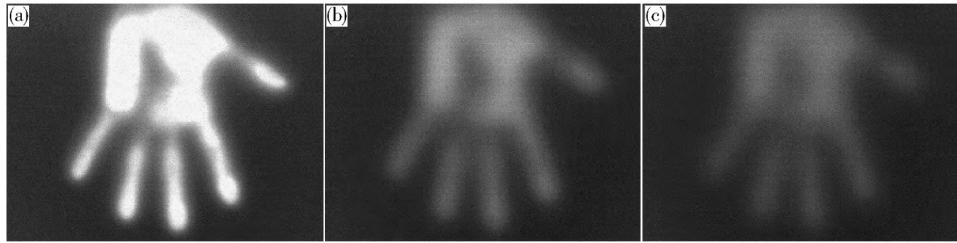


图 1 模糊边缘的手部红外热痕迹图像。(a) 手部离开木板 1 s; (b) 离开木板 60 s; (c) 离开木板 120 s

Fig. 1 Infrared hand images with blurred edges. (a) 1 s after hand leaving; (b) 60 s after hand leaving; (c) 120 s after hand leaving

研究如图 1(b) 和图 1(c) 的红外热痕迹图像的目标提取问题,目的是最大程度提取出原热源目标的轮廓,反映出图像所包含的已离开背景物体表面的原热源目标信息,由于这类热痕迹的模糊程度强,提取其真实轮廓是具有挑战性的,也比一般红外目标的提取具有针对性;而且,目前红外检测技术,在发生过重要事件现场的侦查遗留痕迹方面,发挥积极作用,多数重要遗留痕迹通常就属于红外热痕迹;通过这类热痕迹的分析可以了解原热源目标的状态。因此,研究这类红外热痕迹目标提取问题,就具有实用性和实际意义。

现有的图像目标提取的方法主要有以下几种:(1)基于阈值的分割方法。如最大类间方差法^[1],该算法是通过灰度直方图体现灰度差异性,实现方便,使用广泛,但对于图 1(b) 和图 1(c) 而言,目标的模糊边缘中灰度差异较小,导致难以得到准确的分割结果^[2]。(2)基于边缘模板的方法。即常见的微分算子^[3]如 Prewitt 模板^[4],该类模板法边缘定位准确,运算速度快,然而对于模糊边缘,其连续性和封闭性难以保证。(3)基于区域的图像分割方法。该类方法是将图像按照相似性准则分成不同的区域,其代表是分水岭法^[5],但分水岭法对噪声通常较为敏感,而一般来说图像越模糊,信噪比越低,因此对图 1(b) 和图 1(c) 而言也不适用。(4)基于能量泛函的图像分割方法。此类方法的代表是 Snake 模型^[6],该模型通过连续曲线来表达目标边缘,应用广泛且效果较好,但是在模糊边缘的提取中会出现失真问题。(5)智能图像分割方法。如基于人工免疫的图像模板法^[7~10]和其他自适应模板方法^[11],该类方法是基于人工免疫算法的图像分割技术,使图像分割的研究向人工智能化方向发展;基于启发式学习或者群优化策略,一般对初始条件敏感且时间复杂度较高。

针对红外图像中边缘模糊的目标提取问题,本文提出一种基于流形正则化多核半监督分类模型的

模糊边缘红外目标提取方法。本文分析边缘模糊的特征特点,充分利用灰度的统计信息。所提出的方法首先应用灰度直方图的最大类间方差来计算初始分割阈值,此阈值表征全局的灰度统计信息;在此基础上,可获得离初始分割阈值较近的不确定的边缘模糊区域,也可获得离初始分割阈值较远的确定的背景和目标区域;在各区域中建立像素点邻域空间集,每个邻域空间包含邻域灰度及其统计信息和位置信息;通过核函数对各邻域空间的灰度及其统计信息特征映射获取特征值,同时考虑到灰度及其统计信息存在差异,不同参数的核函数特征映射更加能够充分表征此差异,因此本文应用多核函数获取其特征值;再通过流形正则获取各邻域空间的位置信息的特征值;通过上述特征值信息建立半监督分类模型,利用模型对不确定的边缘模糊区域中各邻域空间进行分类,使其确定化,即归为目标或者背景区域;综合分析目标与背景区域和确定化后的模糊边缘区域的灰度值分布,计算最佳分割阈值,达到模糊边缘红外目标提取目的。

一方面,多核函数特征映射是多核学习的基础,是应用多个不同参数的核函数线性组合的特征映射方式,研究表明多核学习更为灵活和稳定^[12]。通过多核函数映射来表征红外图像不同区域的像素点邻域空间中灰度及其统计信息。另一方面,流形正则是基于流形学习的,能够表达数据的邻域结构信息^[13]。通过流形正则获取像素点邻域空间中的位置信息特征值,并以流形正则方法来增强所建立的半监督分类模型的划分能力及其连续性。笔者前期对流形正则化多核模型已有一定研究基础^[14],能够更好地应用于模糊边缘的红外目标对象上。因此,截取图 1(b) 某部分得到如图 2(b) 的模糊红外图像,对比无流形正则的多核分类和有流形正则的多核分类模型对模糊边缘红外目标提取的效果,可得出邻域空间中位置信息的重要性。

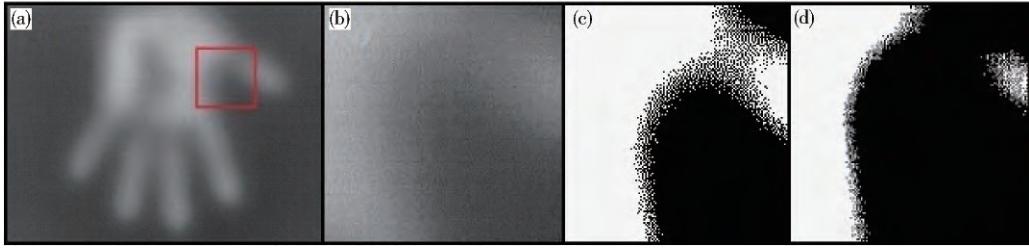


图2 多核分类模型在有流形正则和无流形正则时提取效果区别. (a) 原图; (b) 截取部分; (c) 有流形正则; (d) 无流形正则

Fig.2 Difference of multiple classifiers with and without manifold regularization: (a) original image; (b) truncated image; (c) with manifold regularization; (d) without manifold regularization

1 邻域空间集及特征值获取

1.1 邻域空间集及其元素

设分辨率为 $m \times n$ 的红外图像以灰度值矩阵 I 表示的,且总像素点有 N 个. 设任一像素点表示为 $p_{x,y}$,其中下标 x 和 y 为位置坐标, x 从 1 取到 m , y 从 1 取到 n . 对 $p_{x,y}$ 而言, 其灰度值为 $I(p_{x,y})$. 设定像素点 $p_{x,y}$ 的 3×3 邻域是其邻域空间, 用 $A(p_{x,y})$ 表示; 设 $A(p_{x,y})$ 中有 13 个元素, 并以 $[a_1 \ a_2 \ \cdots \ a_{13}]$ 表示, 其各个元素由图 3 说明.

$I(p_{x-1,y+1})$	$I(p_{x,y+1})$	$I(p_{x+1,y+1})$
$I(p_{x-1,y})$	$I(p_{x,y})$	$I(p_{x+1,y})$
$I(p_{x-1,y-1})$	$I(p_{x,y-1})$	$I(p_{x+1,y-1})$

$$\begin{aligned} a_1 &= I(p_{x-1,y+1}) \\ a_2 &= I(p_{x,y+1}) \\ &\vdots \\ a_9 &= I(p_{x+1,y+1}) \\ a_{10} &= \frac{\sum_{i=1}^9 a_i}{9} \\ a_{11} &= \frac{\sum_{i=1}^9 (a_i - a_{10})^2}{9} \\ a_{12} &= x \quad a_{13} = y \end{aligned}$$

图3 邻域空间元素含义图示

Fig.3 Illustration of elements in local space

由图可知 $a_1 \sim a_9$ 为灰度值信息, a_{10} 和 a_{11} 是灰度统计信息, a_{12} 和 a_{13} 是位置信息. 对若干像素点均建立其邻域空间并构成集合, 则为邻域空间集, 设为 Ω , 有 $\{A_1 \ A_2 \ \cdots\} \in \Omega$, 其中 A_i 表示像素点 i 的邻域空间.

为进一步讨论, 设定如下记法: 若像素点表示为 i , 则 A_i 是其邻域空间, 且 $[a_1^i \ a_2^i \ \cdots \ a_{13}^i]$ 表示空间中各元素.

1.2 流形正则的计算

流形正则的计算是获得像素点邻域空间中的位置信息特征量的过程. 首先需要根据像素点邻域空间位置信息, 建立无向图 $G(V, E)$, 其中 V 表示图中顶点集合, E 表示图中边集合. 以像素点 i 为例, 其对应一个顶点 $v_i \in V$, 通过判定像素点邻域空间的近邻关系来决定两个顶点之间是否有边相连. 令 e_{ij} 表示连接顶点 v_i 和 v_j 的边, 则 $e_{ij} \in E$, 此时 A_i 存在于 A_j 的 k 近邻集合

中, 表示像素点 i 和 j 的近邻空间中 $[a_{12}^i \ a_{13}^i]$ 和 $[a_{12}^j \ a_{13}^j]$ 的欧式距离, 在其他像素点与 j 的近邻空间中下标 12 和 13 的元素的前 k 个最小欧式距离范围之内; 否则 v_i 和 v_j 之间不连接.

在图 G 中, 为进一步刻画像素点之间的位置关系, 需要给每条边赋予权值, 来表示近邻的程度, 本文采用二值化方法求取权值. 设 v_i 和 v_j 之间的权值为 w_{ij} , 则

$$w_{ij} = \begin{cases} 1 & v_i \text{ 和 } v_j \text{ 有边连接,} \\ 0 & \text{其他.} \end{cases} \quad (1)$$

当遍历所有参与建立图 G 的邻域空间集后, 可得到权值矩阵 W , 此时定义对角矩阵 B , 其对角值为 $b_{ii} = \sum_j w_{ij}$, 则有

$$L = B - W. \quad (2)$$

式中 L 称为拉普拉斯图, 可反映出像素点之间位置关系的特征, 于是通过 L 便获得位置信息的特征值.

假设半监督分类模型表示为 $f(f(p_i))$ 是模型对像素点 p_i 的邻域空间的类别划分, 则流形正则可用下式表示:

$$g = \min \frac{1}{2} \sum_{i,j}^n w_{ij} (f(p_i) - f(p_j))^2 = \min \mathbf{F} \mathbf{L} \mathbf{F}^T. \quad (3)$$

其中 $\mathbf{F} = [f(p_1) \ f(p_2) \ \cdots \ f(p_n)]^T$. 上式为模型 f 提供像素点邻域空间的位置信息特征量.

1.3 多核分类模型

首先, 假设 M 个核函数为 $[K_1 \ K_2 \ \cdots \ K_M]$. 在应用中, 均使用高斯核函数, 如下式所示:

$$K_i(\mathbf{x}, \mathbf{x}') = \exp \left(-\frac{\|\mathbf{x} - \mathbf{x}'\|_2^2}{\sigma_i^2} \right). \quad (4)$$

式中 M 个核函数具有 M 个参数 $[\sigma_1 \ \sigma_2 \ \cdots \ \sigma_M]$, \mathbf{x} 和 \mathbf{x}' 均表示像素点邻域空间中前 11 个元素构成的向量.

多核可表达为 $K = \sum_{m=1}^M d_m K_m$, K_m 中元素为 $k_{ij} = K_m(\mathbf{x}_i, \mathbf{x}_j)$, 而 $K_m(\cdot, \cdot)$ 表示核函数, d_m 为核矩阵的组合系数, 并约定满足条件 $\sum_{m=1}^M d_m = 1$, $d_m \geq 0$. 实际应用中, 本

文将 \mathbf{x} 分为两类向量: (1) $[a_1 \ a_2 \ \cdots \ a_{10}]$ (2) $[a_{11}]$ 。不同类向量以不同参数的核函数进行特征映射。于是, 像素点邻域空间的灰度及其统计信息的核函数映射特征值, 即以多核矩阵 \mathbf{K} 的形式所获得。

在获取特征值之后, 为了建立半监督多核分类模型, 需要从特征值中学习得到模型 $f(f \in \mathcal{H})$, \mathcal{H} 是核函数映射后的特征空间。约定 s 是损失函数, 基于 Bach 提出的多核理论^[15], 给出如下的多核分类模型:

$$\begin{cases} \min_{\{\mathbf{f}_m\}, s} \frac{1}{2} \sum_m \frac{\|\mathbf{f}_m\|^2}{d_m} + C \sum_{i=1}^l s(\mathbf{x}_i, \mathbf{y}_i, \mathbf{f}), \\ \text{s. t. } \sum_m d_m = 1, d_m \geq 0, \forall m. \end{cases} \quad (5)$$

式中 C 是较大的常数, $\|\mathbf{f}_m\|^2/d_m$ 是一个正则项, 目的是约束函数 $f = \sum_{m=1}^M f_m$ 的复杂度, 以避免过学习出现, 每一个 f_m 是核函数 K_m 映射的特征空间中的元素。根据表示定理可知^[16], 式(5)解的形式为

$$f(\cdot) = \sum_{i=1}^n \alpha_i K(\cdot, \mathbf{x}_i) = \sum_{i=1}^n \alpha_i \sum_{m=1}^M d_m K_m(\cdot, \mathbf{x}_i). \quad (6)$$

式中 $\alpha \in \mathbb{R}^n$ 。

1.4 流形正则化多核半监督分类模型

利用式(3)作为正则化因子引入到模型式(5)中, 可得到如下的流形正则化多核半监督分类模型。

$$\begin{cases} \mathcal{M} = \min_{\mathbf{f}, b, d, \xi} \frac{\gamma_A}{2} \sum_{m=1}^M \frac{\|\mathbf{f}_m\|^2}{d_m} + \frac{\gamma_I}{2} \mathbf{F}^T \mathbf{L} \mathbf{F} + C \sum_{i=1}^l \xi_i, \\ \text{s. t. } y_i \left[\sum_m f_m(\mathbf{x}_i) + b \right] \geq 1 - \xi_i, \xi_i \geq 0, \forall i, \\ \sum_{m=1}^M d_m = 1, d_m \geq 0. \end{cases} \quad (7)$$

其中 γ_A 和 γ_I 是正则化常数。同式(6), 利用表示定理, 有如下解的形式:

$$f^*(\mathbf{x}) = \sum_{i=1}^n \alpha_i K(\mathbf{x}_i, \mathbf{x}) = \sum_{i=1}^n \alpha_i \sum_{m=1}^M d_m K_m(\mathbf{x}_i, \mathbf{x}). \quad (8)$$

并且根据希尔伯特空间理论^[17], 式(8)的解还应满足再生核性质, 即

$$f(\mathbf{x}) = \langle f, \sum_m d_m K_m(\cdot, \mathbf{x}) \rangle. \quad (9)$$

将式(8)和式(9)代入式(7)得到

$$\begin{cases} \min_{\alpha, b, d, \xi} \frac{\gamma_A}{2} \mathbf{\alpha}^T \mathbf{K} \mathbf{\alpha} + \frac{\gamma_I}{2} \mathbf{\alpha}^T \mathbf{K} \mathbf{L} \mathbf{K} \mathbf{\alpha} + C \sum_{i=1}^l \xi_i, \\ \text{s. t. } y_i \left[\sum_{j=1}^{+u} \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) + b \right] \geq 1 - \xi_i, \xi_i \geq 0, \forall i, \\ \mathbf{K} = \sum_{m=1}^M d_m \mathbf{K}_m, \\ \sum_{m=1}^M d_m = 1, d_m \geq 0. \end{cases} \quad (10)$$

式中矩阵 \mathbf{K} 的第 i 行第 j 列的元素是 $K(\mathbf{x}_i, \mathbf{x}_j)$ 。为了求解式(10), 需要先将核矩阵的组合系数 d 视为固定值, 即假设有一组 $[d_1 \ d_2 \ \cdots \ d_M]$ 满足约束条件, 则可以对其他的约束采用拉格朗日乘子方法。设拉格朗日函数为 \mathcal{L} , 有

$$\mathcal{L} = \frac{\gamma_A}{2} \mathbf{\alpha}^T \mathbf{K} \mathbf{\alpha} + \frac{\gamma_I}{2} \mathbf{\alpha}^T \mathbf{K} \mathbf{L} \mathbf{K} \mathbf{\alpha} + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \zeta_i \xi_i - \sum_{i=1}^l \beta_i \left\{ y_i \left[\sum_{j=1}^{+u} \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) + b \right] - 1 + \xi_i \right\}. \quad (11)$$

其中 ζ 和 β 是拉格朗日乘子。上式应对变量 (α, b, ξ) 求极小, 利用梯度法, 如下所示:

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial \alpha} = \gamma_A \mathbf{K} \mathbf{\alpha} + \gamma_I \mathbf{K} \mathbf{L} \mathbf{K} \mathbf{\alpha} - \mathbf{K} \mathbf{J}^T \mathbf{Y} \beta = 0, \\ \frac{\partial \mathcal{L}}{\partial b} = \sum_{i=1}^l \beta_i y_i = 0, \\ \frac{\partial \mathcal{L}}{\partial \xi_i} = C - \zeta_i - \beta_i = 0. \end{cases} \quad (12)$$

其中: \mathbf{Y} 是对角阵, 其对角元素为 y_i ; \mathbf{J} 是 $\ell \times (\ell + u)$ 的矩阵, 其组成为 $\mathbf{J} = [\mathbf{I} \ \mathbf{0}]$, \mathbf{I} 是单位阵。将式(12)等式结果代入式(11)中, 同时, 再重新将核矩阵的组合系数 d 加入到约束条件中, 并根据拉格朗日对偶理论, 可得到

$$\begin{cases} \min_{d \in \mathcal{D}} \max_{\beta \in \Theta} g(d, \beta) = \sum_{i=1}^l \beta_i - \frac{1}{2} \beta^T \mathbf{Y} \mathbf{J} \mathbf{K} \mathbf{Q} \mathbf{J}^T \mathbf{Y} \beta, \\ \mathbf{Q} = (\gamma_A \mathbf{I} + \gamma_I \mathbf{L} \mathbf{K})^{-1}, \\ \Theta = \left\{ \beta \mid \sum_{i=1}^l \beta_i y_i = 0, 0 \leq \beta_i \leq C, \forall i \right\}, \\ \mathcal{D} = \left\{ d \mid \sum_{m=1}^M d_m = 1, d_m \geq 0, \forall m \right\}. \end{cases} \quad (13)$$

上述的问题具有两个决策量, 一个是 β , 另一个是 d 。本文选择迭代法进行求解, 即先固定 d 优化 β , 再固定已优化的 β 计算当前最优的 d 循环迭代, 直到满足最终的优化条件。为描述具体优化过程, 先给定初始组合系数 d 的每一项为相同值, 即 $d_m = 1/M$; 以 t 为上标形式标记变量的当前迭代步数; 再设定两个优化问题如下:

问题 A: 在组合系数 d^t 的条件下, 应用式(13)的目标函数 $\max_{\beta \in \Theta} g(d, \beta)$ 和条件集合 Θ , 获得 β 的最优解 β^{*t} , 并更新 β 的取值, 即 $\beta^{t+1} = \beta^{*t}$;

问题 B: 在 β^t 的条件下, 应用式(13)的目标函数 $\min_{d \in \mathcal{D}} g(d, \beta)$ 和条件集合 \mathcal{D} , 获得 d 的最优解 d^{*t} , 并更新 d 的取值, 即 $d^{t+1} = d^{*t}$ 。

显然, 问题 B 的求解结果会影响问题 A 的条件, 因此重新计算问题 A 的结果, 并迭代下去。

问题 A 是经典的带等式约束的二次规划问题, 多种优化工具^[18-19]可成熟实现, 本文选择 Mosek 软件的

msklpopt 函数. 问题 B 可应用既约梯度法求解 ,即对任意 d_m^t 其一阶梯度表达如下:

$$\nabla g_{d_m^t} = -\frac{1}{2}(\beta^t)^T Y J (\mathbf{K}_m \mathbf{Q} - \gamma_1 \mathbf{K} Q L K_m \mathbf{Q}) J^T Y \beta. \quad (14)$$

假设 d^t 中最大元素为 d_v^t ,则对任意 d_m^t ,其既约梯度如下:

$$\nabla^R g_{d_m^t} = \begin{cases} \nabla g_{d_m^t} - \nabla g_{d_v^t} & m \neq v, \\ 0 & m = v. \end{cases} \quad (15)$$

之所以考虑既约梯度 是因为 d^t 的更新除了需要考虑负一阶梯度 还需要考虑条件 $d \in \mathcal{D}$. 设 d^t 的更新方向为 p^t 则 p^t 为

$$p^t: \begin{cases} p_m^t = \begin{cases} -\nabla^R g_{d_m^{t-1}} & \nabla^R g_{d_m^{t-1}} \leq 0, \\ -d_m^{t-1} \nabla^R g_{d_m^{t-1}} & \nabla^R g_{d_m^{t-1}} > 0, \end{cases} \\ p_v^t = -\sum_{m \neq v} p_m^t. \end{cases} \quad (16)$$

确定更新方向后 d 的更新取值问题便解决了. 对于既约梯度方法 ,停机条件设定为 $\|p^t - p^{t-1}\|^2 \leq \varepsilon$. 上述主要流程 如图 4 所示.

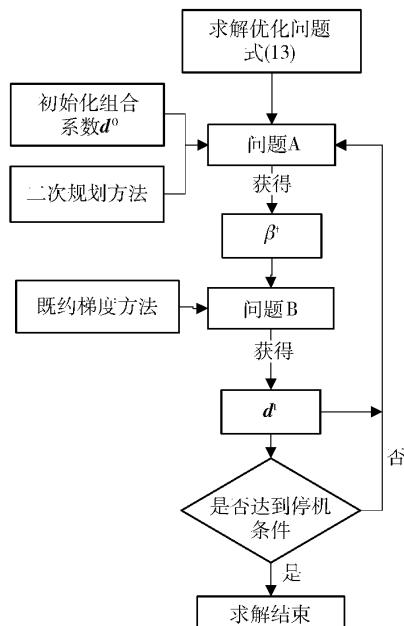


图 4 优化问题(式(13)) 的求解过程流程图

Fig.4 Flow chart of the solving process of the optimization problem (Equation (13))

假设从图像中获取的学习训练的像素点总数为 n ,多核总数为 M ; 任意像素点的邻域空间中 前 11 个元素中作为特征向量 ,由多核函数进行特征映射; 后 2 个元素是位置信息 ,用于计算流形正则项. 首先 ,计算流形正则项中 数据样本之间的距离计算需要时间复杂度为 $O(2n)$,拉普拉斯矩阵 L 的计算需要 $O(n^2)$. 计算任意核函数矩阵 \mathbf{K}_m 需要 $O(11n)$,多核组合

$\mathbf{K} = \sum_{m=1}^M d_m \mathbf{K}_m$ 计算需要 $O(11Mn)$. 式(13) 中矩阵 \mathbf{Q} 的计算需要 $O(2n^3)$. 上述优化过程中 问题 A 的二次规划方法计算 β 需要 $O(n^3)$,问题 B 的梯度计算需要 $O(Mn^3)$ d 的更新计算需要 $O(M)$. 因此 ,本文方法的整体时间复杂度可以表示为 $O(n + n^2 + Mn + n^3 + Mn^3 + M)$. 式中已忽略常数项 其中低次项可进一步忽略.

2 红外图像模糊目标提取

2.1 目标、背景与模糊边缘区域提取

以图 1(b) 和图 1(c) 为对象 ,由于本文方法在于分类确定标号 ,因此首先设定类别. 设红外图像中背景区域为 D_1 其标号是负标号(-1); 模糊边缘区域为 D_2 其标号是正标号(+1); 目标区域为 D_3 其标号有待半监督分类模型来确定(0). 采用最大方差阈值法获取三个区域 其基本原理是: 把图像的灰度直方图在方差达到最大处时的灰度作为初始分割阈值 θ ,再取 $\theta_1 = \theta - \xi_0$ 和 $\theta_2 = \theta + \xi_1$,其中 ξ_0 和 ξ_1 是人工设定参数 ,设定原则是保证小于 θ_1 灰度的是背景 ,而大于 θ_2 的灰度是目标 ,从而将图像分割为三个区域 ,分别为 $D_1 \in [0, \theta_1]$ 、 $D_2 \in [\theta_1, \theta_2]$ 和 $D_3 \in [\theta_2, 255]$.

以归一化的图 1(b) 为例 ,初始分割阈值 $\theta = 0.4157$ 取 $\xi_0 = \xi_1 = 0.1$ 则 $\theta_1 = 0.3157$ 和 $\theta_2 = 0.5157$,图 1(b) 的三个区域是 $D_1 \in [0, 0.3157]$ 、 $D_2 \in [0.3157, 0.5157]$ 和 $D_3 \in [0.5157, 1]$ 如图 5 所示.



图 5 初始分割阈值获取确定的目标(白)、背景(黑)和模糊边缘区域

Fig.5 Target (white) ,background (black) and blurred edge areas obtained by using the initial segmentation threshold

2.2 半监督分类特征获取及方法流程

分析图 5. 从 D_1 和 D_3 中分别取 r 个像素点构造其邻域空间集 ,记为 Ω_s 此时 Ω_s 中共有 $2r$ 个邻域空间元素; 从 D_2 中取 s 个像素点构造其邻域空间集 ,记为 Ω_u 此时 Ω_u 中有 s 个邻域空间元素. 设某两个邻域空间为 A_p 和 A_q 其特征值获取如图 6 所示.

参数设定为:

(1) 前 15 个高斯核函数的参数为 $\sigma \in [0.01, 0.03, 0.05, 0.1, 0.3, 0.5, 1, 1.5, 2, 3, 5, 10, 12, 15, 20]$;

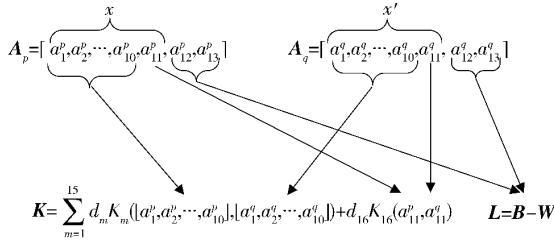


图 6 特征值获取示例

Fig. 6 Acquisition of features

(2) 第 16 个高斯核函数的参数 σ 为 a_{11}^p, a_{11}^q 的平均距离;

(3) 拉普拉斯矩阵 L 计算中 k 近邻个数 $k = 7$.

综合邻域空间集 Ω_s 和 Ω_u , 获取建立半监督分类模型需要的全体特征值, 求解式(10)并根据式(8)可获得半监督分类模型 f . 在此基础上, 令 f 对当前 Ω_u 进行确定标号的决策处理, 即确定 Ω_u 中 s 个邻域空间的标号为正或负. 因此完成一次建模决策后, 可以确定的目标和背景的样本点总共有 $(2r+s)$ 个, 同时可以分别计算当前确定的目标和背景区域中灰度的最大最小值, 目标的记为 $T^\tau = [T_{Min}^\tau, T_{Max}^\tau]$, 背景的记为 $B^\tau = [B_{Min}^\tau, B_{Max}^\tau]$, 其中 τ 表示当前建模次数. 利用 T^τ 和 B^τ 对红外图像进行划分. 此时, 若仍然存在不确定标号的模糊边缘区域, 则对剩余模糊边缘区域重新建立邻域空间集 Ω_u , 以及半监督分类模型, 作确定标号的决策处理. 此时建模次数 $\tau := \tau + 1$; 过程迭代进行直到红外图像中不存在模糊边缘区域为止. 最终最佳分割阈值 θ 设定为

$$\theta = \begin{cases} T_{Max}^\tau \text{ or } B_{Min}^\tau & \text{if } T_{Max}^\tau = B_{Min}^\tau, \\ (T_{Max}^\tau + B_{Min}^\tau) / 2 & \text{if } T_{Max}^\tau \neq B_{Min}^\tau. \end{cases} \quad (17)$$

利用最佳分割阈值 θ 达到图像目标和背景的分割效果, 其流程如图 7 所示.

3 仿真结果

应用基于流形正则化多核半监督分类的模糊边缘红外目标提取方法, 并选择基于阈值的 Otsu 法^[1], 基于边缘检测模板法的 prewitt 算子^[4], 基于区域分割的分水岭法^[5], 基于能量泛函的 Snake 模型^[6]和基于智能方法的免疫聚类模板法^[8]、免疫球面模板法^[9]和免疫网络模板法^[10]作对比; 根据文献[7–9]和文献[10]可知, 多数常用的图像目标提取方法处理此类模糊性很强的红外热痕迹难以获得理想结果. 对比方法中前四种典型方法可以表达多数提取方法的情况, 后三种方法是目前研究红外热痕迹提取的新工作. 算法中参数设定是: (1) $r = 5, s = 100$; (2) 初始分割阈值参数

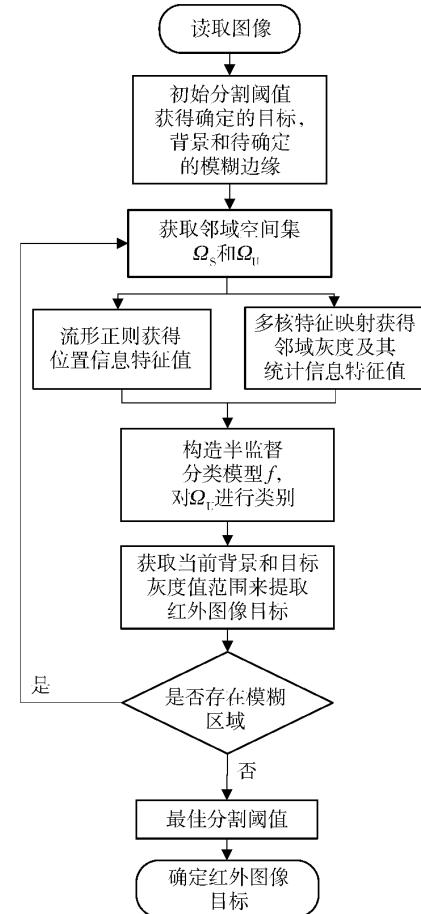


图 7 提取模糊边缘红外目标的流程

Fig. 7 Flow chart of extracting the infrared target with blurred edge

$\xi_0 = \xi_1 = 0.1$; (3) 模型中正则化参数 γ_A 和 γ_1 分别为 10^{-2} 和 10^{-4} .

同时, 为了数值性的评价目标提取的准确程度, 本文选择假目标提取比率(RFP)^[20]、Jaccard 相似性指数 (J)^[21]、Dice 相似性指数 (D)^[22] 和绝对误差率 (R_e)^[23] 为评价准则.

首先设定: GT 表示基准图像的手部目标区域 p_{GT} 是其像素点个数, 作为比较参考标准; ER 表示提取结果中所有被决策为手部目标区域 p_{ER} 是其像素点个数; TP 表示被正确分类为手部目标区域 p_{TP} 是其像素点个数; FP 表示将背景错误提取为手部目标区域 p_{FP} 是其像素点个数. 四个评价指标的含义如下.

(1) 假目标提取比率(FPR) 表示非真实手部目标的提取比率, 即

$$FPR = \frac{p_{FP}}{p_{TP} + p_{FP}} \times 100\%. \quad (18)$$

FPR 越接近 0 表示提取的目标准确性高.

(2) Jaccard 相似性指数 (J) 和 Dice 相似性指数 (D) 均表示提取结果和参考标准中的目标重合度, 其中 J 定义为: 提取结果中目标与参考标准中目标的交

集与并集之商,即

$$J = \frac{|\text{GT} \cap \text{ER}|}{|\text{GT} \cup \text{ER}|}. \quad (19)$$

D 定义为

$$D = 2 \frac{|\text{GT} \cap \text{ER}|}{|\text{GT}| \cup |\text{ER}|}. \quad (20)$$

J 和 D 越接近 1 表示提取的目标效果理想.

(3) 绝对误差率 (R_e) 定义为提取结果与参考标准不相同的像素点数 (n) 与图像全部像素点数 (N) 的

比值,即

$$R_e = \frac{n}{N} \times 100\%. \quad (21)$$

为计算四个评价指标需要确定基准图像. 因为红外图像中手部目标提取的结果越接近手部停留在木板上时的手部形状,就越准确,于是选择手部离开木板 1 s 时的红外图像为标准,如图 8(a) 所示. 利用最大类间方差法获得目标提取结果,如图 8(b) 所示,作为基准图像. 图 9 和图 10 是方法对比实验结果.

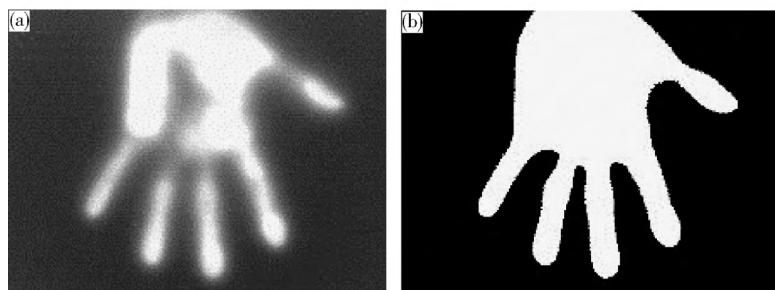


图 8 手部离开木板 1 s 时的图像(a)和基准图像(b)

Fig. 8 Image of 1 s after hand leaving (a) and ground truth image (b)

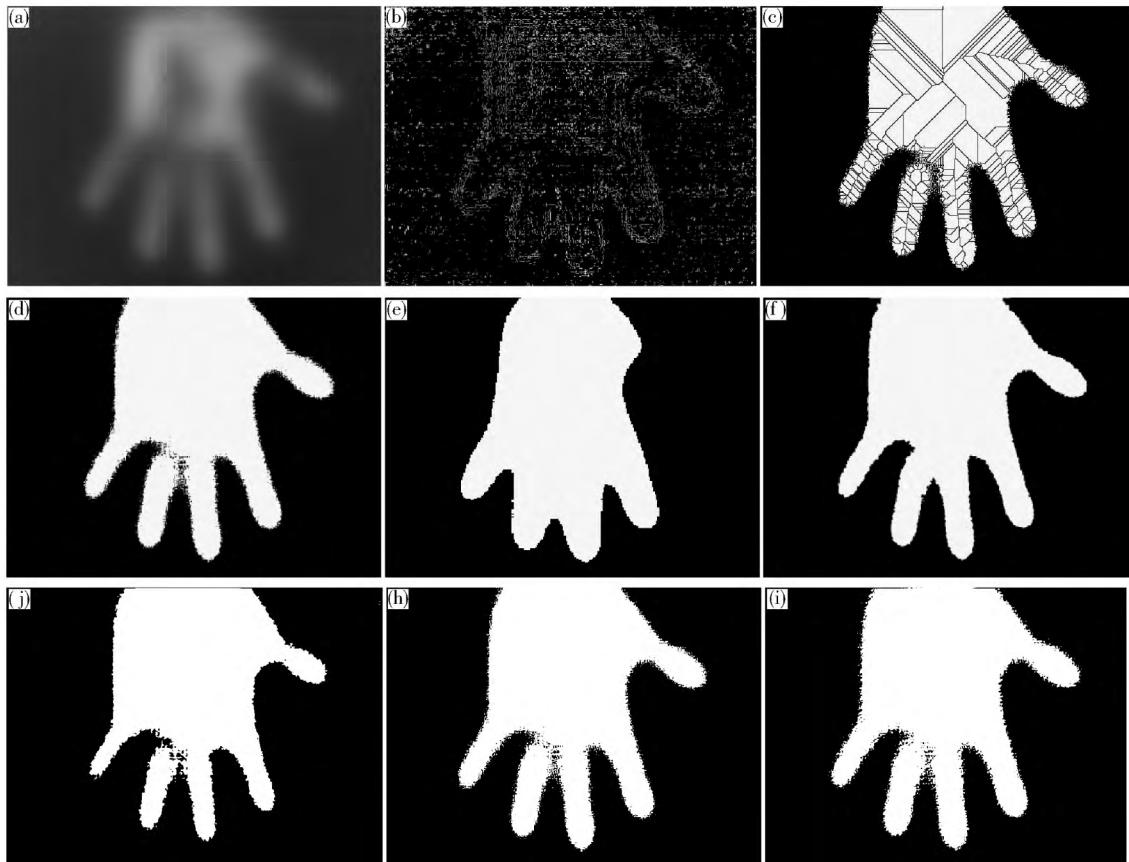


图 9 手部离开木板 60 s 时的提取结果. (a) 原红外图像; (b) prewitt 算子; (c) 分水岭法; (d) Otsu 法; (e) Snake 模型; (f) 免疫聚类模板法; (g) 免疫网络模板法; (h) 免疫球面模板法; (i) 本文算法

Fig. 9 Extraction results of the mages of 60 s after hand leaving: (a) original infrared image; (b) prewitt operator; (c) watershed method; (d) Otsu method; (e) Snake model; (f) immune template clustering method; (g) immune network template method; (h) superstring galaxy template algorithm; (i) the proposed method

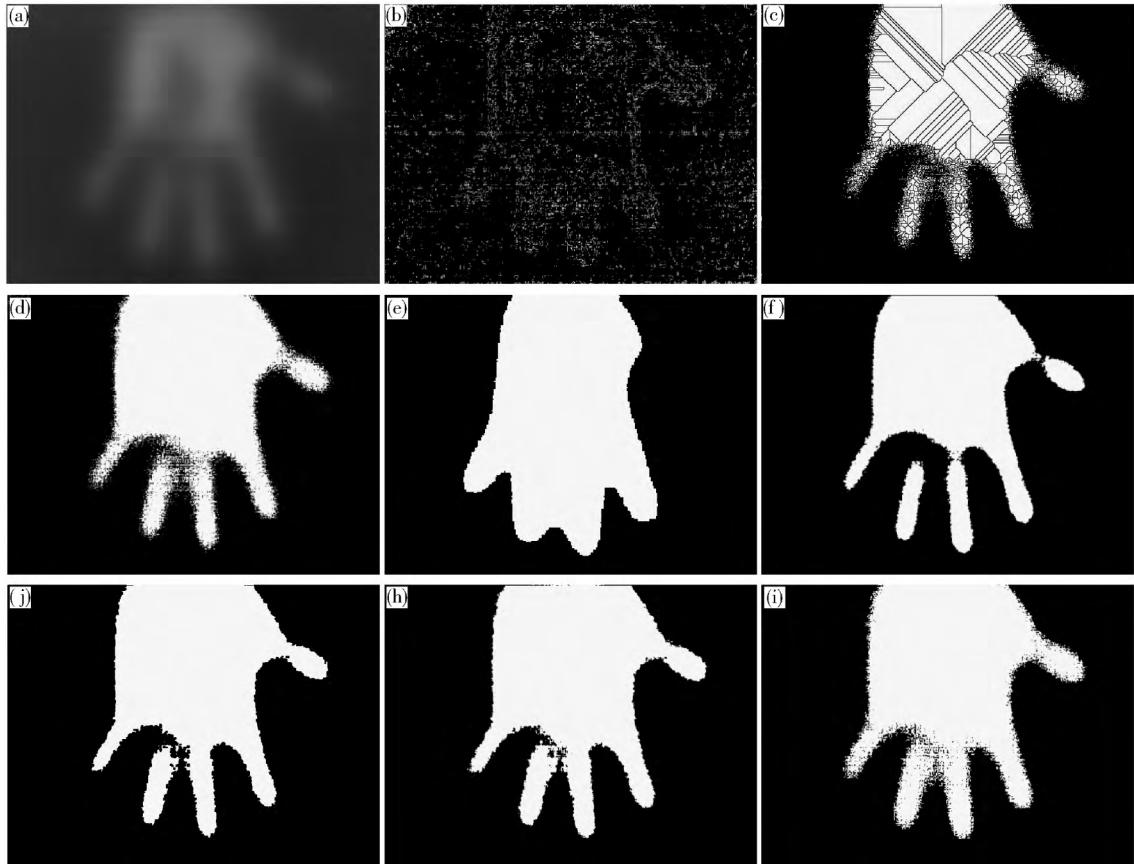


图 10 手部离开木板 120 s 时的提取结果. (a) 原红外图像; (b) prewitt 算子; (c) 分水岭法; (d) Otsu 法; (e) Snake 模型; (f) 免疫聚类模板法; (g) 免疫网络模板法; (h) 免疫球面模板法; (i) 本文算法

Fig. 10 Extraction results of the images of 120 s after hand leaving: (a) original infrared image; (b) prewitt operator; (c) watershed method; (d) Otsu method; (e) Snake model; (f) immune template clustering method; (g) immune network template method; (h) superstring galaxy template algorithm; (i) the proposed method

从四个数值评价指标分析,结果如表 1 和表 2 所示.

表 1 红外目标提取算法的定量分析结果(60 s)

Table 1 Quantitative results of infrared target extraction methods (60 s)

提取算法	FPR/%	J	D	R_e /%
Prewitt 算子		得不到连续封闭的目标区域		
分水岭法	6. 7	0. 81	0. 89	6. 1
Otsu 法	8. 0	0. 89	0. 94	3. 4
Snake 模型	67. 2	0. 16	0. 27	55. 5
免疫聚类模板	7. 5	0. 84	0. 91	5. 1
免疫网络模板	8. 2	0. 89	0. 94	3. 3
免疫球面模板	9. 2	0. 87	0. 93	4. 0
本文算法	6. 3	0. 90	0. 95	3. 1

从图 9 和图 10 以及表 1 和表 2 得出, 本文算法在提取模糊边缘红外目标上是有效的, 且整体优于其他对比方法. 表 1 中本文算法的数值情况都是最优的, 表 2 中分水岭法、Otsu 法、免疫聚类模板法和免疫球面模板法的 FPR 虽然低于本文算法, 但是 FPR 表示假目

标提取比例, 单一方面考虑 FPR 的低百分比只能说明算法所提取的目标属于真实目标, 不能说明提取目标的完整性.

表 2 红外目标提取算法的定量分析结果(120 s)

Table 2 Quantitative results of infrared target extraction methods (120 s)

提取算法	FPR/%	J	D	R_e /%
Prewitt 算子		得不到连续封闭的目标区域		
分水岭法	5. 6	0. 69	0. 82	9. 7
Otsu 法	7. 4	0. 78	0. 87	6. 9
Snake 模型	67. 6	0. 16	0. 27	55. 8
免疫聚类模板	5. 6	0. 82	0. 89	5. 6
免疫网络模板	10. 8	0. 82	0. 89	5. 9
免疫球面模板	7. 6	0. 82	0. 89	5. 8
本文算法	9. 0	0. 84	0. 91	5. 3

针对三种最新的基于人工免疫的模板方法, 分析如下: 免疫网络模板法以人工免疫为机制, 设计了一个三层网络; 以图像像素灰度的统计信息和小波信息为

特征,训练得到具有分类决策能力的网络,其不足在于训练网络所采用的超平面方法的超平面个数、初始平面位置选择重要不易确定且训练时间较长。免疫聚类模板法借鉴人工免疫机理,将图像像素灰度表达成抗原分子结构模式;从抗体识别抗原角度出发,经适应度、交叉、变异等免疫聚类计算,得到最优抗体以识别像素所属类别,达到从模糊区域获取目标边界的目的,其不足在于免疫聚类先要提取特征,其过程需要迭代大量种群个体,算法时间复杂度大。免疫球面模板法特征化图像像素邻域统计信息并将特征映射到假定的球面上,在球面上选择多个子区域对特征进行分类决策;该方法适用于红外模糊区域中的边界划分,其不足在于球面上子区域的位置和个数选择影响各子区域中分类准确程度,也影响学习效率。

表3 时间效率对比
Table 3 Comparisons of time efficiency

归一化的时间单位	本文算法	Otsu 法	免疫聚类模板	免疫网络模板	免疫球面模板
60 s 红外目标提取	1	0.8	361.3	334.3	276.2
120 s 红外目标提取	0.6	0.8	51.2	32.1	31.5

从表3可以得出:本文算法在时间效率上优于基于人工免疫的模板方法;在120 s的实验中,也优于Otsu方法。此外,当以120 s红外图像为对象时,本文算法与三种基于人工免疫的模板方法的时间消耗均减小,其原因在于这四类算法在提取目标时采用迭代的方式,对于120 s的红外图像而言,其边缘模糊区域灰度变化比60 s的红外图像要慢得多,这也是其模糊性更强的原因所在,因此灰度变化平缓使得灰度值分布较为平均,迭代的求解方式易于得出结果,其迭代步数就会明显下降。

仿真结果表明:基于流形正则化多核半监督分类模型的模糊边缘红外目标提取效果优于其他方法,可以克服模糊边缘的影响并给出相对完整和准确的目标;所应用的半监督分类模型是基于多核函数和流形正则的,多核函数和流形正则分别对红外图像不同区域邻域空间集中的不同元素获取特征,可有针对性地处理不同特征,并获得像素点之间邻域结构信息,最终获取模糊边缘红外目标提取的最佳分割阈值。在算法时间效率方面本文算法优于提取效果比较好的基于人工免疫的新型模板方法。

4 结论

(1) 红外图像中边缘模糊的目标提取是此类特殊图像处理中的难点。依据构造红外图像不同区域的邻域空间集来分析,提出基于流形正则化多核半监督分类的边缘模糊红外目标提取方法。

(2) 灰度及其统计信息特征,以及位置信息特征

在稳定性和时间效率方面,与上述三种基于人工免疫的模板方法比较,本文算法较优。因为在模糊边缘红外热痕迹的提取问题上,充分应用图像像素邻域中的灰度及其统计特征和邻域位置特征,学习得到可对模糊区域的像素进行分类的模型;尤其是,学习该模型仅需要少量像素的特征,便能够达到较为理想的效果,且算法对这些被选择的少量像素的位置和数量较为鲁棒。

为了比较时间效率的不同,以准确性较好的Otsu法和上述分析的免疫聚类模板法、免疫网络模板法和免疫球面模板法为对比。在仿真结果中,将本文的算法在学习和决策阶段的时间归一化为单位时间1,其他方法按照相同的比率作归一化处理,仿真结果如表3所示。

是能够表征模糊边缘红外目标有效特征量;通过多核函数对邻域空间的灰度及其统计信息的特征映射,流形正则对邻域空间的位置信息特征提取。

(3) 在获取的特征基础上,建立半监督分类模型来决策像素的类别,以类别划分的方式达到模糊边缘区域确定的目的。仿真对比结果表明,本文算法能够提取相对完整和准确的红外目标,且算法时间效率高。

参 考 文 献

- [1] Otsu N. A threshold selection method from gray-level histograms. *IEEE Trans Syst Man Cybern*, 1979, 9(1): 62
- [2] Chen Q, Zhao L, Lu J, et al. Modified two dimensional Otsu image segmentation algorithm and fast realization. *IET Image Process*, 2012, 6(4): 426
- [3] Belongie S, Malik J, Puzicha J. Shape matching and object recognition using shape contexts. *IEEE Trans Pattern Anal Mach Intell*, 2002, 24(4): 509
- [4] Yang L, Zhao D, Wu X, et al. An improved Prewitt algorithm for edge detection based on noised image // *The 4th International Congress on Image and Signal Processing, shanghai*, 2011: 1197
- [5] Meyer F, Bacher S. Morphology segmentation. *J Visual Commun Image Represent*, 1990, 1(1): 21
- [6] Xu C, Prince J L. Snakes, shapes, and gradient vector flow. *IEEE Trans Image Process*, 1998, 7(3): 359
- [7] Fu D M, Yu X, Tong H J, et al. An ensemble template algorithm for extracting targets from blurred infrared images. *Optik*, 2014, 125(3): 954
- [8] Fu D M, Yu X, Tong H J, et al. Extracting target from blurred

- midwave infrared image based on immune template clustering. *Spectrosc Spectral Anal*, 2014, 34(3): 673
(付冬梅,于晓,童何俊,等. 基于免疫聚类模板的模糊中波红外图像目标提取. 光谱学与光谱分析 2014, 34(3): 673)
- [9] Yu X, Fu D M. Target Extraction from Blurred Trace Infrared Images with a Superstring Galaxy Template Algorithm. *Infrared Phys Technol*, 2014, 64(3): 9
- [10] Fu D M, Yu X, Tong H J. Target extraction of blurred infrared image with an immune network template algorithm. *Opt Laser Technol*, 2014, 56(1): 102
- [11] Han W Y, Lee J C. Palm vein recognition using adaptive Gabor filter. *Expert Syst Appl*, 2012, 39(18): 13225
- [12] Gönen M, Alpaydin E. Multiple kernel learning algorithms. *J Mach Learn Res*, 2011, 12: 2211
- [13] Belkin M, Niyogi P, Sindhwani V. Manifold regularization: a geometric framework for learning from labeled and unlabeled examples. *J Mach Learn Res*, 2006, 7: 2399
- [14] Yang T, Fu D M. Semi-supervised classification with Laplacian multiple kernel learning. *Neurocomputing*, 2014, 140: 19
- [15] Rakotomamonjy A, Bach F, Canu S, et al. SimpleMKL. *J Mach Learn Res*, 2008, 9: 2491
- [16] Schölkopf B, Herbrich R, Smola A J, et al. A generalized repre-
senter theorem. *Proc Annu Conf Comput Learn Theory*, 2000, 42(3): 416
- [17] Schölkopf B, Smola A J. Learning with kernels: support vector machines, regularization, optimization, and beyond. *J Am Stat Assoc*, 2011, 98(3): 781
- [18] Grant M C, Boyd S P. Graph implementations for nonsmooth convex programs // *Recent Advances in Learning and Control*. Springer London, 2008: 95
- [19] Andersen B E D, Andersen K D. *The MOSEK Optimization Tools Manual*, 2007
- [20] Jadin M S, Taib S. Infrared image enhancement and segmentation for extracting the thermal anomalies in electrical equipment. *Electron Electr Eng*, 2012, 4: 107
- [21] Cardenes R, Bach M, Chi Y, et al. Multimodal evaluation for medical image segmentation // *Lecture Notes in Computer Science*, 4673 LNCS, 2007: 229
- [22] Babalola K O, Patenaude B, Aljabar P. An evaluation of four automatic methods of segmenting the subcortical structures in the brain. *Neuroimage*, 2009, 47(4): 1435
- [23] Tao W B, Jin H, Liu L M. Object segmentation using ant colony optimization algorithm and fuzzy entropy. *Pattern Recognit Lett*, 2007, 28(7): 788