

# 基于文化狼群算法的电力设备红外和可见光图像配准

赵洪山, 张则言\*

华北电力大学电气与电子工程学院, 河北 保定 071003

**摘要** 可见光和红外图像是电力巡检机器人检测电力设备健康状态的重要方式, 图像配准可以结合两类图像的优势, 为后续状态监测提供更好的依据。针对红外图像模糊导致的配准精度下降问题, 提出了一种基于显著性梯度的归一化互信息算法。首先, 在红外图像视觉显著性检测的基础上, 强化了显著性区域的边缘梯度信息; 然后, 将显著性梯度信息和归一化互信息相结合作为配准的测度函数; 其次, 为了提高图像配准算法的收敛性, 提出了一种文化狼群算法。该算法将文化算法的分层进化特点引入狼群算法, 建立信念空间和群体空间。在迭代过程中, 通过信念空间的知识指导群体空间的进化。最后, 选取变电站巡检图像、标准配准测试图像集和标准测试函数进行对比实验, 结果表明, 该算法在配准率和配准速度方面的性能较好。

**关键词** 图像处理; 电力巡检机器人; 图像配准; 文化狼群算法; 归一化互信息

**中图分类号** TP391; TP242

**文献标志码** A

**doi:** 10.3788/AOS202040.1610003

## Power Equipment Infrared and Visible Images Registration Based on Cultural Wolf Pack Algorithm

Zhao Hongshan, Zhang Zeyan\*

*College of Electrical and Electronic Engineering, North China Electric Power University,  
Baoding, Hebei 071003, China*

**Abstract** Visible and infrared images are important ways for power inspection robot to detect the health status of power equipment. Image registration can combine the advantages of two types of images and provide a better basis for subsequent status monitoring. To improve the registration accuracy due to the blur of infrared image, this paper proposes a normalized mutual information algorithm based on saliency gradient. First, based on the visual saliency detection of the infrared image, the edge gradient information of saliency area is enhanced. Second, the saliency gradient information and normalized mutual information are combined as a measurement function of registration. Third, to improve the convergence of the image registration algorithm, a cultural wolf pack algorithm is proposed. This algorithm introduces the hierarchical evolutionary characteristics of cultural algorithm into the wolf pack algorithm to establish the belief space and population space. In the iterative process, the evolution of population space is guided by the knowledge of belief space. Finally, the substation inspection image, standard registration test image set, and standard test functions are selected for comparative experiments. The results show that the proposed algorithm has better performance in registration rate and registration speed.

**Key words** image processing; power inspection robot; image registration; cultural wolf pack algorithm; normalized mutual information

**OCIS codes** 100.2000; 110.3080; 100.4994

## 1 引 言

红外热像仪作为反映电力设备热故障的主要组件, 被广泛装备在巡检机器人中。但红外成像受环境温度差、测量距离和大气状态的影响较大, 当被测物体和环境温度相近时, 难以有效识别电力设备的具

体信息<sup>[1]</sup>。相比红外图像, 可见光图像具有更多的细节信息。因此, 将红外和可见光图像配准后, 可以在显示设备热成像的同时, 进行精准的故障定位。高效、精准的图像配准是提高巡检机器人故障定位和识别能力的前提。图像配准的步骤包括选择相似性测度算法、确定变换模型、图像插值、优化策略<sup>[2]</sup>。

收稿日期: 2020-05-06; 修回日期: 2020-05-11; 录用日期: 2020-05-29

\* E-mail: 359888608@qq.com

目前相似性测度算法主要包括归一化互相关(NCC)<sup>[3]</sup>、互信息(MI)<sup>[4]</sup>和误差平方和(SSD)算法<sup>[5]</sup>,其中MI算法在红外和可见光图像的配准中应用最为广泛。闫利等<sup>[6]</sup>在归一化互信息算法的基础上结合梯度和灰度信息进行图像配准。Yang等<sup>[7]</sup>将高斯滤波引入局部张量,利用自适应局部结构张量提取空间信息,并通过加权函数和MI组成测度函数,充分反映了像素的邻域信息。刘小燕等<sup>[8]</sup>通过线性滤波提取图像边缘,并将边缘信息和MI相结合,弥补了MI中空间信息不足的问题。Yu等<sup>[9]</sup>提出了基于灰度窗口法的归一化互信息(GWW-NMI)算法,利用窗口法改变灰度权重,提取强边缘特征,解决了红外和可见光图像之间的特征不一致问题。上述算法都侧重于将全局边缘特征或点特征和MI结合,但实际应用中,巡检机器人的红外图像会受到振动、温度和室外灰尘等因素的影响,造成图像模糊,进而导致配准精度下降。

图像配准中的优化策略是在配准精度和速度之间达到最佳平衡,目前主要通过可行解空间中寻求全局最优解。Wang等<sup>[10]</sup>将无味卡尔曼滤波器引入粒子群中,改善其收敛过早的问题。Liu等<sup>[11]</sup>开发了一种基于条件初始化和并行协作的并行粒子群优化算法(pa-PSO),以加快收敛速度并进一步减少失配。Pradhan等<sup>[12]</sup>提出了细菌觅食-量子粒子算法,该算法兼顾收敛速度和全局最优,适用于非刚性配准。除粒子群优化算法外,Chen等<sup>[13]</sup>针对面部红外图像配准,为减小因图像晃动引起的配准误差,提出两阶段遗传算法。但这类算法自身缺乏群策能力,具有收敛性不足、全局最优解搜索能力和环境适

应性较差等问题。Wu等<sup>[14]</sup>提出了狼群算法,在算法中融入了狼群中的综合决策和逻辑推理能力。Chen等<sup>[15]</sup>通过对比其他智能种群算法,证明了狼群算法的鲁棒性和收敛速度较好,但该算法依然存在狼群搜索方式单一,搜索步长死板等问题,容易导致在图像配准这类高维函数的求解中,陷入局部最优解。

首先,为提高红外和可见光图像的配准适应性,在红外图像低清晰度的情况下保证配准效果,本文提出了一种结合显著性梯度和MI的方法。通过视觉显著性分析提取红外图像的显著性梯度特征,并用基于显著性梯度的归一化互信息(SGNMI)作为测度函数,弥补了归一化互信息的空间信息不足问题。其次,为了提高巡检过程中的图像配准效率,根据电力巡检机器人拍摄的红外和可见光图像特点,提出了一种适用于图像配准的文化狼群算法(CWPA)。借鉴文化算法的多层进化机制<sup>[16]</sup>,并结合改进的狼群算法,改善了传统狼群算法在配准中效果较差的问题。最后,通过对比实验验证了本算法的有效性。

## 2 基于显著性梯度的归一化互信息测度

电力设备出现异常高温情况,说明设备出现异常,且高温区域在红外图像中是显著的。在巡检图像中,红外和可见光图像的背景一般为自然景观(如天空),在灰度强度分布上和图像中的电力设备存在较大差异。文献[17]中基于流形排序的显著性检测算法就是利用像素块与先验背景的差异计算目标的显著性。因此,根据文献[17]中的算法提出了一种SGNMI测度算法,该算法的流程如图1所示。




图1 SGNMI测度算法的流程图

Fig. 1 Flow chart of SGNMI measurement algorithm

### 2.1 归一化互信息测度

MI是关于信息论的重要理论,常用于信息关联性的度量。在图像配准中,将两个待配准的图像视为两个随机变量,利用互信息统计图像之间的相关性进行配准。通过图像变换使两图像的互信息达到最大时,完成配准。图像A和图像B的互信息可表

示为

$$I(A, B) = H(A) + H(B) - H(A, B), \quad (1)$$

$$H(A) = - \sum_{a \in A} p_A(a) \log_2 p_A(a), \quad (2)$$

$$H(B) = - \sum_{b \in B} p_B(b) \log_2 p_B(b), \quad (3)$$

$$H(\mathbf{A}, \mathbf{B}) = - \sum_{a \in \mathbf{A}} \sum_{b \in \mathbf{B}} p_{AB}(a, b) \log_2 \frac{p_{AB}(a, b)}{p_A(a) p_B(b)}, \quad (4)$$

式中,  $H(\mathbf{A})$ 、 $H(\mathbf{B})$  分别为图像  $\mathbf{A}$ 、 $\mathbf{B}$  的熵,  $H(\mathbf{A}, \mathbf{B})$  为图像  $\mathbf{A}$ 、 $\mathbf{B}$  的联合熵,  $p_A(a)$ 、 $p_B(b)$  分别为图像  $\mathbf{A}$ 、 $\mathbf{B}$  的概率密度, 其中,  $a$  和  $b$  分别为图像  $\mathbf{A}$  和  $\mathbf{B}$  的对应像素,  $p_{AB}(a, b)$  为图像  $\mathbf{A}$ 、 $\mathbf{B}$  的联合概率密度。为进一步减小图像灰度强度对互信息测度的影响, 根据联合熵与个体熵之间的关系, 将归一化互信息表示为

$$N_{MI}(\mathbf{A}, \mathbf{B}) = \frac{H(\mathbf{A}) + H(\mathbf{B})}{H(\mathbf{A}, \mathbf{B})}. \quad (5)$$




图 2 红外图像的显著性梯度。(a)原始图像;(b)显著性检测图像;(c)划分后的红外图像;  
(d)增强显著性区域的图像;(e)显著性梯度图像

Fig. 2 Saliency gradient of infrared image. (a) Original image; (b) image after saliency detection;  
(c) infrared image after division; (d) image after enhancing the saliency area; (e) image of saliency gradient

为非显著性区域的像素。红外图像的划分结果如图 2(c)所示, 其中, 显著性区域主要是电力设备的主体区域; 非显著性区域主要是背景区域。

将图像进行区域划分后, 对图像进行直方图均衡化以提高红外图像显著区域的对比度, 突出边缘信息。如图 2(d)所示。直方图均衡化后的图像可表示为

$$h(s_t) = X_{\text{round}} \left[ (L - 1) \times \frac{f(s_t) - f_{\min}}{(W \times H) - f_{\min}} \right], \quad (7)$$

$$f(s_t) = \sum_{j=0}^{s_t} p(j), \quad (8)$$

式中,  $p(j)$  为像素强度值为  $j$  的像素点在图像中出现的概率,  $f(s_t)$  为图像的像素强度值累计分布函数,  $f_{\min}$  为累计分布函数的最小值,  $W$  和  $H$  分别为图像长、宽的像素个数,  $L$  为灰度等级, 在红外图像中为 256,  $s_t$  为原始图像的像素强度值。通过增强红外图像中电气设备区域的对比度, 可提高该区域内像素强度值的梯度, 克服因红外图像边缘模糊而导致的的有效梯度信息缺失问题。提取整个红外图像的显著性梯度, 可表示为

## 2.2 基于显著性梯度的归一化互信息测度

流形排序算法是一种综合考虑前景和背景相似性的视觉显著性算法<sup>[17]</sup>, 该算法可以提取红外图像中的显著性区域, 具体步骤如图 2 所示。根据显著性检测原理将红外图像分为显著性区域和非显著性区域, 图 2(b)中的区域 1 为显著性区域, 区域 2 为非显著性区域。以图像  $\mathbf{S}$  中的单个像素  $S$  为例, 区分方法可表示为

$$\begin{aligned} X_{\text{sig}}(S_1) &> X_{\text{mean}}[\mathbf{S}], \\ X_{\text{sig}}(S_2) &\leq X_{\text{mean}}[\mathbf{S}], \end{aligned} \quad (6)$$

式中,  $X_{\text{sig}}$  为对应像素的显著性,  $X_{\text{mean}}$  为图像中所有像素显著性的均值,  $S_1$  为显著性区域的像素,  $S_2$

$$|\nabla I(x, y)| = \begin{cases} |\nabla I(x, y)|, & |\nabla I(x, y)| > T_h, \\ 0, & \text{other} \end{cases}, \quad (9)$$

$$T_h = \frac{1}{MN} \sum_x \sum_y |\nabla I(x, y)|, \quad (10)$$

式中,  $T_h$  为强梯度提取的阈值,  $\nabla I(x, y)$  为图像在  $x$  和  $y$  方向上的梯度值, 不包含梯度方向,  $N$  和  $M$  分别为在  $x$  和  $y$  方向上的梯度数量。(9)式和(10)式可以有效提取红外图像显著区域的梯度分布, 减少无关信息的影响。由于增强部分区域对比度提高了强梯度的提取阈值  $T_h$ , 但非显著性区域的部分“强梯度”依然大于阈值  $T_h$ 。因此, 通过提高梯度阈值筛选出的全局显著性梯度, 倾向于分布在出现异常温升的电力设备中。从图 2(e)中可以发现, 显著性梯度点主要分布在电力设备的周围, 且在背景中较少, 从而使基于显著性梯度的测度函数侧重反映电气设备区域的配准效果。按照(9)式提取可见光图像的显著性梯度, 结果如图 3 所示。可以发现, 提取的可见光图像梯度点不倾向于任何区域, 如图 3(b)所示。

将两组显著性梯度视为两组随机变量, 在(5)式的基础上组成新的 SGNMI 测度函数




图 3 可见光图像的显著性梯度。(a)可见光图像;(b)显著性梯度图像

Fig. 3 Saliency gradient of visible image. (a) Visible image; (b) image of saliency gradient

$$S_{\text{SGNMI}}(\mathbf{A}, \mathbf{B}) = \frac{H(\nabla \mathbf{A}_{\text{SG}}) + H(\nabla \mathbf{B})}{H(\nabla \mathbf{A}_{\text{SG}}, \nabla \mathbf{B})}, \quad (11)$$

式中,  $\nabla \mathbf{A}_{\text{SG}}$  为基于显著性区域划分的红外图像显著性梯度,  $\nabla \mathbf{B}$  为可见光图像的显著性梯度。该测度函数主要衡量两个图像之间的显著性梯度相似性, 当两幅图像完全配准时, SGNMI 测度函数达到最大值, 即将优化配准过程转化为求解 SGNMI 测度函数最大值的问题。可表示为

$$\mathbf{T}_b = \operatorname{argmax} S_{\text{SGNMI}}[\mathbf{A}, \mathbf{T}(\mathbf{B})], \quad (12)$$

$$\mathbf{T} = \begin{bmatrix} q \cos r & -q \sin r & h \\ q \sin r & q \cos r & v \\ 0 & 0 & 1 \end{bmatrix}, \quad (13)$$

式中,  $\mathbf{T}_b$  为通过优化算法求得的最佳空间变换矩阵,  $\mathbf{T}$  为空间变换矩阵,  $\mathbf{T}(\mathbf{B})$  为利用空间变换矩阵对图像  $\mathbf{B}$  进行仿射变换,  $h$ 、 $v$ 、 $q$ 、 $r$  分别为待配准图像在配准过程中的水平平移量、竖直平移量、缩放率和旋转角度。

### 3 狼群算法及分析

假设狼群算法(WPA)<sup>[14]</sup>包括3种人工狼(探狼、头狼、猛狼),3种寻优行为(探狼游走行为、头狼召唤行为、猛狼围攻行为)和2种智能规则(胜者为王的头狼角逐规则、强者生存的狼群更新规则)。WPA可表示为

$$\mathbf{X}_{\text{WPA}} = \{N, i_{\text{ter}}, \mathbf{X}, \mathbf{Y}, \mathbf{L}\}, \quad (14)$$

式中,  $N$  为三种人工狼的总数量,  $i_{\text{ter}}$  为总迭代次数,  $\mathbf{X}$  为人工狼的位置状态, 其中  $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$  为第  $i$  ( $i=1, 2, \dots, N$ ) 匹人工狼在  $D$  维空间中的位置状态。  $\mathbf{Y}$  为人工狼感知到的猎物气味浓度, 其中, 探狼为  $\mathbf{Y}_a$ 、猛狼为  $\mathbf{Y}_b$ 、头狼为  $\mathbf{Y}_c$ 。  $\mathbf{L}$  为步长因子, 包括游走步长  $\mathbf{L}_{(a)}$ 、奔袭步长  $\mathbf{L}_{(b)}$  和围攻步长  $\mathbf{L}_{(c)}$ 。算法的主要步骤如下。

#### 1) 游走行为

游走行为的目的是更新探狼的信息, 第  $i$  匹探

狼始终向着最优方向进化。向  $p$  ( $p=1, 2, \dots, h$ ) 方向更新的探狼在第  $d$  维空间中的位置可表示为

$$x_{(a)id}(p) = x_{(a)id} + \sin(2\pi \times p/h) \times L_{(a)d}, \quad (15)$$

式中,  $x_{(a)id}$  和  $x_{(a)id}(p)$  为探狼  $i$  更新前后的位置,  $L_{(a)d}$  为  $d$  ( $d=1, 2, \dots, D$ ) 维空间中探狼的游走步长。在  $h$  个方向中, 取气味浓度最大且大于当前气味浓度  $Y_{ai}$  的方向作为该探狼的更新方向。重复上述游走行为, 直到游走达到最大步数  $T_{\text{max}}$ 。或按照胜者为王的机制, 出现  $Y_{ai} > Y_c$  时停止, 此时探狼  $i$  成为头狼。

#### 2) 召唤行为

通过游走行为找到气味最浓的头狼位置, 将第  $i$  匹猛狼向头狼的位置快速靠近, 该猛狼在第  $k+1$  次迭代后的位置可表示为

$$x_{(b)id}^{(k+1)} = x_{(b)id}^{(k)} + L_{(b)d} \times (g_d^{(k)} - x_{(b)id}^{(k)}) / |g_d^{(k)} - x_{(b)id}^{(k)}|, \quad (16)$$

式中,  $x_{(b)id}^{(k)}$  和  $x_{(b)id}^{(k+1)}$  为该猛狼在  $d$  维空间更新前后的位置,  $L_{(b)d} > 2L_{(a)d}$  为猛狼的奔袭步长,  $g_d^{(k)}$  为  $k$  次迭代时头狼在  $d$  维空间的位置。猛狼在奔袭中始终遵循胜者为王的更新机制, 直到猛狼和头狼的距离  $d_{bi}$  小于围攻范围  $d_{\text{near}}$  时, 结束召唤。

#### 3) 围攻行为

猛狼奔袭后将头狼的位置作为猎物目标, 在围攻范围  $d_{\text{near}}$  内的所有猛狼都发起围攻。第  $k+1$  次的围攻行为可表示为

$$x_{(b)id}^{(k+1)} = x_{(b)id}^{(k)} + \lambda \times L_{(c)d} \times |G_d^{(k)} - x_{id}^{(k)}|, \quad (17)$$

式中,  $\lambda$  为  $[-1, 1]$  的均匀随机数,  $L_{(c)d}$  为猛狼的围攻步长, 且  $L_{(a)d} > 2L_{(c)d}$ ,  $G_d^{(k)}$  为猎物第  $k$  次迭代时在  $d$  维空间的位置。

狼群算法在强者生存的更新机制下进行循环寻优, 直到达到最大迭代次数或种群最优解预定误差精度时停止。但传统狼群算法中, 存在以下

不足。

1) 游走行为反映了算法的全局最优解感知能力,但当探狼陷入局部最优解且无法成为头狼时,按(15)式的算法探狼会困在局部最优点,搜索能力下降。

2) 在算法迭代过程中,狼群向最优解区域靠近,猛狼的围攻范围应由大到小,而传统狼群算法的围攻半径是固定的。

3) 探狼应在迭代过程中,通过当前的进化状况确定游走步长,以达到最佳的搜索速度。

## 4 文化狼群优化算法

为了解决传统狼群算法中存在的问题,同时提高图像配准的速度和精度,提出了适用于图像配准的CWPA。CWPA从微观和宏观层面上模拟生物层面和文化层面的进化,种群空间和信念空间构成的双层进化机制使算法具有良好的全局搜索能力和收敛性<sup>[16]</sup>,CWPA的框架如图4所示。

### 4.1 狼群算法的改进及群体空间设计

群体空间是算法进行问题求解的主空间,实验采用改进的WPA进行演化。传统WPA中,探狼采用贪婪式游走策略,始终向着比当前更优的方向




图4 CWPA的原理图

Fig. 4 Schematic diagram of CWPA

前进,容易陷入局部最优解。且猛狼在迭代到一定次数时,应在一定范围内,进行细致的搜索,以加快收敛速度。因此,采用(14)式中的5个参数作为群体空间的主要内容,对算法进行改进。

首先,为了提高探狼对局部最优解的感知能力,防止陷入局部最优解。在探狼游走期间( $Y_{ai} < Y_c$ ),当探狼*i*周围*h*个方向的气味浓度均小于探狼当前的气味浓度时,改变搜索半径。经多次循环后,若当前探狼周围*h*个方向的气味浓度依然小于探狼*i*位置的气味浓度,表示出现极大值。此时在搜索范围外随机初始化探狼*i*的位置。探狼*i*出现局部最大值时,满足

$$\begin{cases} Y(x_{(a)id}) > Y[x_{(a)id} + \sin(2\pi \times p/h) \times 0.5^\eta \times L_{(a)d}], p = 1, 2, \dots, h, \\ Y(x_{(a)id}) < Y_c \end{cases} \quad (18)$$

式中, $Y(x_{(a)id})$ 为探狼*i*在*d*维空间的气味浓度, $\eta \in [0, 2]$ 为随机设定的搜索半径因子,通过多次取搜索半径因子的方式不断改变搜索范围,进而确定当前区域是否存在局部最大值。

其次,在迭代初期,猛狼应在较大的范围内进行围攻。随着迭代次数的增加,应逐渐缩小围攻范围,以加速算法的收敛。实验使用的动态围攻半径 $d_{near}$ 在第*k*次迭代的更新可表示为

$$d_{near}^{(k)} = \frac{i_{ter}/(\omega \times i_{ter} + k)}{D} \times \sum_{d=1}^D |X_d^{max} - X_d^{min}|, \quad (19)$$

式中, $\omega \in (0, 1)$ 为随机数, $X_d^{max}$ 和 $X_d^{min}$ 分别为*d*维变量的最大值和最小值。通过(19)式改变召唤行为中的停止条件,同时增加围攻范围的约束条件。随着迭代次数*k*的增加,围攻半径逐渐减小,从大范围的粗糙搜索转向小范围的精细搜索,提高了算法

的收敛性。

### 4.2 信念空间的设计

信念空间可以保存群体进化过程中的优秀种群,形成群体知识指导种群进化。信念空间的知识形式包括状况知识、规范知识、拓扑知识、领域知识和历史知识<sup>[18]</sup>。可以根据进化策略和应用领域选择不同的知识形式。由于传统WPA中,人工狼步长选择具有随机性,应选择规范知识作为信念空间,用于描述可行解搜索空间的变化。针对*D*维变量,其结构描述为 $\{N_1, N_2, \dots, N_D\}$ ,其中, $N_d = |(e_d, u_d), (E_d, U_d)|$ , $e_d$ 和 $u_d$ 分别为*d*维空间的上限和下限, $E_d$ 和 $U_d$ 分别为变量对应的适应值上限和下限。随着种群的进化,个体应在更有效的范围内寻找最优解。为了指导群体空间的进化,规范知识的第*k*次迭代可表示为

$$\begin{aligned}
 e_d(k+1) &= \begin{cases} x_{id}(k), & x_{id}(k) < e_d(k) \& f[x_{id}(k)] > E_{id}(k) \\ e_d(k), & \text{other} \end{cases} \\
 E_d(k+1) &= \begin{cases} f[x_{id}(k)], & x_{id}(k) < e_d(k) \& f[x_{id}(k)] > E_{id}(k) \\ E_d(k), & \text{other} \end{cases} \\
 u_d(k+1) &= \begin{cases} x_{id}(k), & x_{id}(k) > u_d(k) \& f[x_{id}(k)] > U_{id}(k) \\ u_d(k), & \text{other} \end{cases}, \\
 U_d(k+1) &= \begin{cases} f[x_{id}(k)], & x_{id}(k) > u_d(k) \& f[x_{id}(k)] > U_{id}(k) \\ U_d(k), & \text{other} \end{cases}
 \end{aligned} \tag{20}$$

式中,  $x_{id}(k)$  为第  $k$  次迭代中从群体空间挑选的人工狼  $i$  的  $d$  维参数,  $f(\cdot)$  为适应度函数, 即目标函数。

### 4.3 接受函数

接受函数将群体空间中的最优子集提供给信念空间, 一般按照一定百分比或者一定的规则进行提取。在迭代过程中, 种群空间中的人工狼会随种群逐渐向最优解靠拢, 个体间的位置越来越接近。如果按照规定的比例系数进行更新会导致接受算法的信息传递效率低, 因此, 将种群按适应度划分为两个种群, 其中, 适应度较大的种群  $N_1$  占 20%, 适应度较小的种群  $N_2$  占 80%。选取最优子集的方法可表示为

$$\|x_{id} - x_{jd}\| > \epsilon, x_{id}, x_{jd} \in N_1, \tag{21}$$

式中,  $\epsilon$  为阈值参数,  $\|\cdot\|$  为欧氏距离。通过(21)式, 在选取最优子集的过程中, 保证传递个体间差异的同时, 种群随迭代不断聚拢。因此, 最优子集包含的个体数会随迭代次数的增加呈下降趋势, 保证了信息传递的高效性和种群的多样性。

### 4.4 影响函数

影响函数将信念空间的知识按照一定规则传递到群体空间, 以指导种群的进化。通过规范知识决定人工狼的前进步长, 优化搜索范围。种群空间中探狼的游走步长一般设为定值  $L_{(a)d}$ , 规范知识指导游走步长可表示为

$$L_{(a)d} = e_d + X_{\text{rand}}(0, 1) \times (u_d - e_d), \tag{22}$$

式中,  $X_{\text{rand}}(0, 1)$  为  $[0, 1]$  之间的随机数, 以避免在迭代后期, 人工狼陷入局部最优解。在(19)式的基础上, 将信念空间的知识传递至围攻半径函数  $d_{\text{near}}$ ,

$$d_{\text{near}}^k = \frac{i_{\text{ter}} / (\omega \times i_{\text{ter}} + k)}{D} \times \sum_{d=1}^D |u_d - e_d|. \tag{23}$$

### 4.5 本文配准算法

结合 SGNMI 算法, 将 CWPA 用于红外图像和可见光图像的配准。CWPA 的具体步骤如下。

1) 初始化设置的参数: 随机初始化人工狼  $i$  的空间位置  $\mathbf{X}_i$ , 包括  $h, v, q$  和  $r$ , 群体空间种群大小  $N$ , 最大迭代次数  $i_{\text{ter}}$ , 探狼游走行为的最大游走次数  $T_{\text{max}}$ , 阈值参数  $\epsilon$ , 更新比例因子  $\beta$ 。

2) 根据群体空间中人工狼的位置, 计算所有人工狼  $i$  的适应度  $Y_{ai}$  (两幅图像的 SGNMI 测度函数), 并选取头狼。

3) 探狼按照(15)式进行游走, 根据(18)式去除探狼中的局部极大值。如果满足  $Y_{ai} > Y_c$ , 则转至步骤 2), 若达到最大游走次数  $T_{\text{max}}$ , 则转至步骤 4)。

4) 猛狼按照(16)式进行奔袭。如果满足  $Y_{bi} > Y_c$ , 则转至步骤 2)。直到猛狼达到(23)式的围攻范围后, 根据(17)式进行围攻。并按照强者生存的更新机制, 完成群体空间人工狼的位置及适应度的更新。

5) 通过(21)式更新信念空间, 通过(20)式更新信念空间内人工狼的变量范围、位置和适应度值, 通过(22)式和(23)式指导游走步长  $L_{(a)d}$  和围攻半径  $d_{\text{near}}$ 。

6) 当误差达到最初设定值或迭代到最大次数时, 输出群体空间头狼对应的最佳空间变换矩阵和目标函数值; 否则, 返回步骤 2)。

## 5 实验分析

实验提出了新的 SGNMI 测度函数和 CWPA, 分别对测度函数和优化算法进行对比实验。算法的开发环境: 处理器为 Intel(R) Core(TM) i5-5200U, CPU 为 2.20 GHz, 内存为 8 G, 操作系统为 64 位 Windows10, 开发平台为 Matlab 2019b。

### 5.1 测度函数对比实验

测度函数的对比实验采用 3 种不同的 MI 测度函数: GWW-NMI<sup>[9]</sup>、SGNMI 和基于综合空间的互信息(SMI)算法<sup>[19]</sup>。其中, SMI 和 GWW-NMI 算法都是结合图像空间特征和 MI 的测度函数, 在红外和可见光图像配准中效果较好<sup>[9,19]</sup>。为了使测度

函数对比实验的结果更加可靠,用文献[20]中的文化粒子群优化(CPSO)算法优化三种测度函数中的4个配准参数。配准参数的解空间如表1所示。

表1 配准参数的解空间

Table 1 Solution space of registration parameters

Registration parameter	$h$	$v$	$q$	$r$
Solution space	$[-1000,1000]$	$[-1000,1000]$	$[-10,10]$	$[0,360]$

表2 优化算法参数设置

Table 2 Parameters of optimization algorithm

Algorithm	Parameter
CPSO	$N=100, i_{\text{ter}}=2000, \text{inertia weight } \omega=0.7, \text{ learning factor } c_1=c_2=1.5, \text{ individual speed limit } [-0.5, 0.5]$
WPA	$N=100, \text{ ferocious wolves:scout wolves}=1:1, i_{\text{ter}}=2000, T_{\text{max}}=10, \text{ step factor } S=0.1; \text{ judging distance } d=0.08, \text{ update scale factor } \beta=3$
CWPA	$N=100, \text{ ferocious wolves:scout wolves}=1:1, T_{\text{max}}=10, \text{ threshold parameter } \epsilon=0.5, \text{ update scale factor } \beta=3$

采用归一化测度函数、均方根误差(RMSE)和平均绝对误差(MAE)评价测度函数的图像配准效果<sup>[3]</sup>。其中,均方根误差  $X_{\text{RMSE}}$  和平均绝对误差  $X_{\text{MAE}}$  可表示为

$$X_{\text{RMSE}} = \sqrt{\frac{1}{Q} \sum_{q=1}^Q [(x_1^q - x_2^q)^2 + (y_1^q - y_2^q)^2]}, \quad (24)$$

$$X_{\text{MAE}} = \frac{1}{Q} \sum_{q=1}^Q |x_1^q - x_2^q| + |y_1^q - y_2^q|, \quad (25)$$

式中,  $(x_1^q, y_1^q)$  和  $(x_2^q, y_2^q)$  分别为红外和可见光图像中的第  $q$  对匹配点,  $Q$  为匹配点对的数目。实验中的测试图像由标准配准数据集提供,将自建数据集中的图像按标准配准数据集的标注格式进行人工标注<sup>[21]</sup>。

### 5.1.1 标准配准测试图像对比实验 1

通过分析标准配准测试图像,验证 SGNMI 算法在抗模糊和抗噪声方面的优势。为了保证实验的客观性,采用文献[21]中的 Oldbuilding 子集作为标准配准图像集,进行测度函数的对比实验。原因是该子集相比文献[21]中其他自然景观类的子集,在形态上更接近电力设备。首先,在标准配准数据集中随机选取一组图像对不同测度函数进行详细分析,如图5所示。将可见光图像作为参考图像,红外图像作为浮动图像,其中两图像已完全配准。计算浮动图像在不同位置下的归一化测度函数值,结果如图6所示,其中,HTD表示浮动图像的纵向平移距离,LTD表示浮动图像的横向平移距离。

从图6中可以发现,当横向和纵向的平移距离均为0时,两个图像完全配准,此时的相似性测度函

在表1的解空间内随机选取配准参数的初始值,CPSO算法的初始化参数按文献[20]给出的最佳参数设置,如表2所示。




图5 准配准数据集的实验样本。(a)可见光图像;  
(b)红外图像

Fig. 5 Experimental sample of standard registration data set.  
(a) Visible image; (b) infrared image

数一般达到最大(1)。图6(a1)~图6(c1)是测试图像的实验结果,可以发现,SGNMI的主峰最突出,有利于在求解最优配准参数时得到全局最优解。GWW-NMI算法的主峰也比较尖锐,但是与周围局部峰的对比如较小。而SMI算法的主峰不尖锐,这表明其对配准细节的灵敏度较低。图6(a2)~图6(c2)是在原图基础上增加系数为6的椒盐噪声的实验结果,图6(a3)~图6(c3)是在原图基础上增加系数为6的高斯噪声的实验结果。可以发现,SGNMI算法的结果基本没有明显的变化,原因是SGNMI算法增加了显著性区域的对比度,具有良好的抗噪声和抗模糊能力。GWW-NMI算法的实验结果显示其局部峰更加明显,即全局最优解和局部最优解之间的对比度较小,容易导致配准优化算法陷入局部最优解。SMI算法的实验结果与GWW-NMI算法类似,受噪声和图像模糊的影响较大。

图6对单一图像进行分析,从侧面反映了SGNMI算法的抗模糊性和抗噪性较好。为了直观体现不同算法对红外图像模糊程度的适应情况,对

比了不同模糊程度下配准参数的 MAE 和 RMSE。选取标准配准数据集中除图 5 外剩余 50 组红外和

可见光图像进行配准实验<sup>[21]</sup>。所有的标准测试图像均为完全配准图像对,部分图像如图 7 所示。

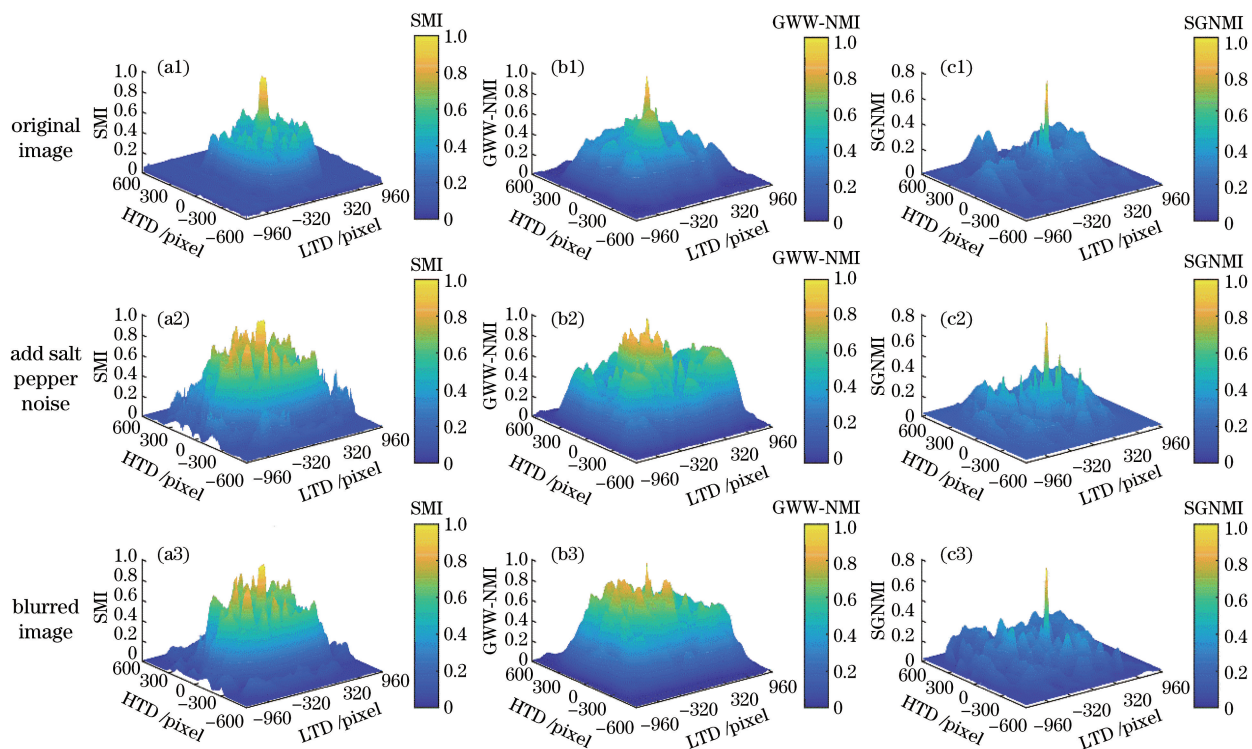


图 6 不同算法的结果对比。(a) SMI; (b) GWW-NMI; (c) SGNMI

Fig. 6 Comparison results of different algorithms. (a) SMI; (b) GWW-NMI; (c) SGNMI

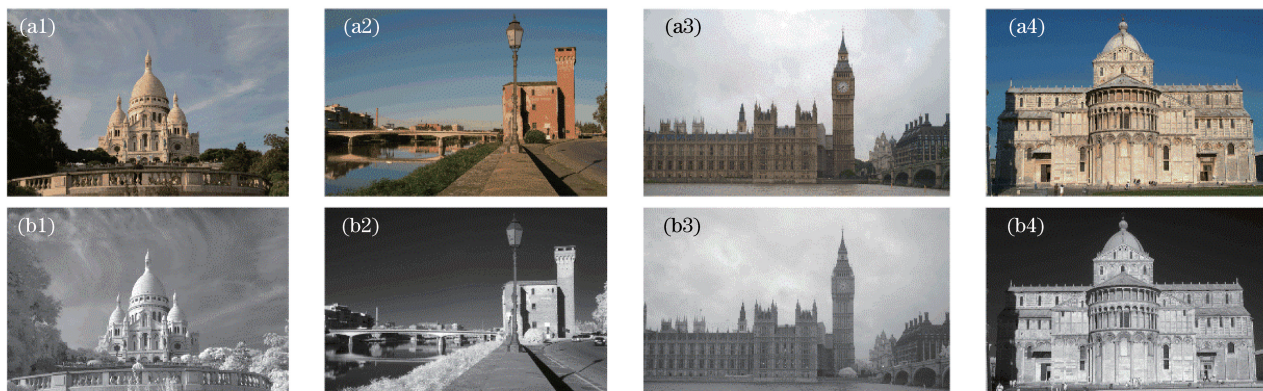


图 7 部分标准配准的测试图像。(a)可见光图像;(b)红外图像

Fig. 7 Part of the standard registration test image set. (a) Visible image; (b) infrared image

通过表 1 和表 2 中设置的配准参数,计算 50 组样本在不同模糊程度下配准参数的平均 MAE 和 RMSE,结果如图 8 所示。可以发现,随着高斯模糊中滤波器标准差  $\sigma$  的增加,红外图像的模糊程度不断增大,配准难度增加。而 SGNMI 算法因注重显著性区域边缘并提高了图像的对比度,因此,对图像模糊的适应性最好,与图 6 中的实验结果相吻合。GWW-NMI 算法更适合边缘信息较为丰富的图像,当红外图像边界较为模糊时,难以通过滑动窗口提取有效的梯度信息,配准效果较差。而 SMI 算法

为基于图像灰度强度的互信息配准,当边缘信息模糊时,图像不同区域之间的强度过渡更加缓和,容易造成误配准。

### 5.1.2 标准配准测试图像对比实验 2

为了反映 SGNMI 算法在标准配准数据集中的配准精度和配准时间,利用 5.1.1 小节中的 50 组图像进行测度函数的对比实验。通过 CPSO 算法优化三种测度函数下(13)式中的 4 个配准参数,每组图像配准 20 次,图 7 对应的实验结果如表 3 所示,其中,1~4 分别为对应的四组配准图像。标准配准



数据集中 50 组图像的平均 MAE、平均 RMSE 和平均

均配准时间如表 4 所示。

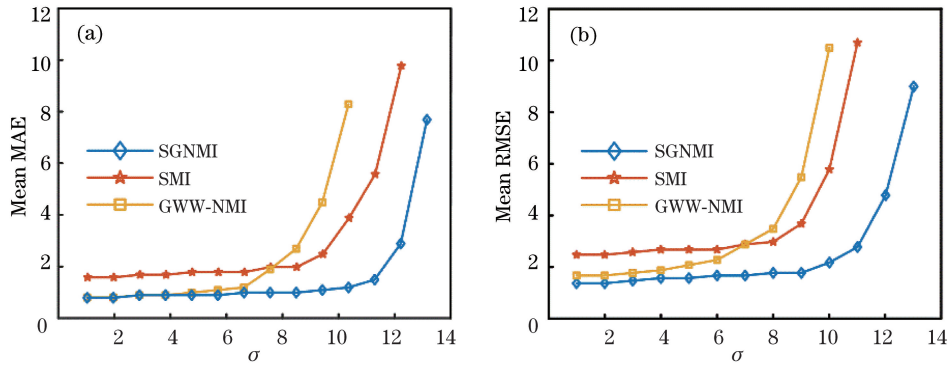


图 8 模糊图像的测试结果。(a) MAE; (b) RMSE

Fig. 8 Test results of blurred images. (a) MAE; (b) RMSE

表 3 标准测试图像集的配准结果

Table 3 Registration result of standard test image set

Sample	MAE			RMSE			Registration time /s		
	GWW-NMI	SMI	SGNMI	GWW-NMI	SMI	SGNMI	GWW-NMI	SMI	SGNMI
1	0.897	1.435	0.931	1.213	2.241	1.391	0.734	4.231	1.032
2	1.293	1.692	1.125	1.479	2.693	1.592	0.823	3.328	1.143
3	0.736	1.613	0.962	0.986	2.861	1.242	0.672	4.054	1.097
4	1.043	1.973	0.947	1.435	3.173	1.374	0.743	4.426	0.969

表 4 50 组标准测试图像集的配准结果平均值

Table 4 Mean value of registration results of 50 sets of standard test image sets

Mean MAE			Mean RMSE			Mean registration time /s		
GWW-NMI	SMI	SGNMI	GWW-NMI	SMI	SGNMI	GWW-NMI	SMI	SGNMI
1.010	1.673	1.040	1.387	2.490	1.324	0.926	3.847	1.239

从表 3 和表 4 中可以发现, SMI 算法用时较长, 且配准效果较差。SGNMI 算法相比于 SMI 算法所用的时间较少, 效果更优。GWW-NMI 算法和 SGNMI 算法均是利用图像中的强梯度进行配准, 因此, 两种算法的配准精度相近。由于本算法使用了基于流形排序的显著性检测, 所以相比 GWW-NMI 算法配准时间较长。这表明 SGNMI 算法在牺牲一定时间的基础上, 提高了配准算法对红外图像模糊的适应性。

### 5.1.3 实际数据集对比实验 3

为了验证 SGNMI 算法在实际电力巡检中的应用效果, 建立实际数据集进行对比。样本取自于某变电站, 使用 CMOS 图像传感器 (Sony IMX214) 采集可见光图像, 采用增强型热成像相机 (ThermApp TH) 采集红外图像。红外摄像机的参数如表 5

所示。

表 5 红外相机的参数

Table 5 Parameters of infrared camera

Parameter	Value
Resolution /pixel×pixel	384×288
Scene temperature range /°C	0–200
Temperature accuracy /%	±2
Wavelength /μm	7–13
Focus range /m	>0.6
Frame rate /Hz	8.7

图像采集时间为 2019 年 11 月 19 日 15 时, 温度为 5 °C, 天气阴, PM<sub>2.5</sub> 为 193。共采集 50 组红外和可见光图像作为实验样本, 部分实验样本如图 9 所示。

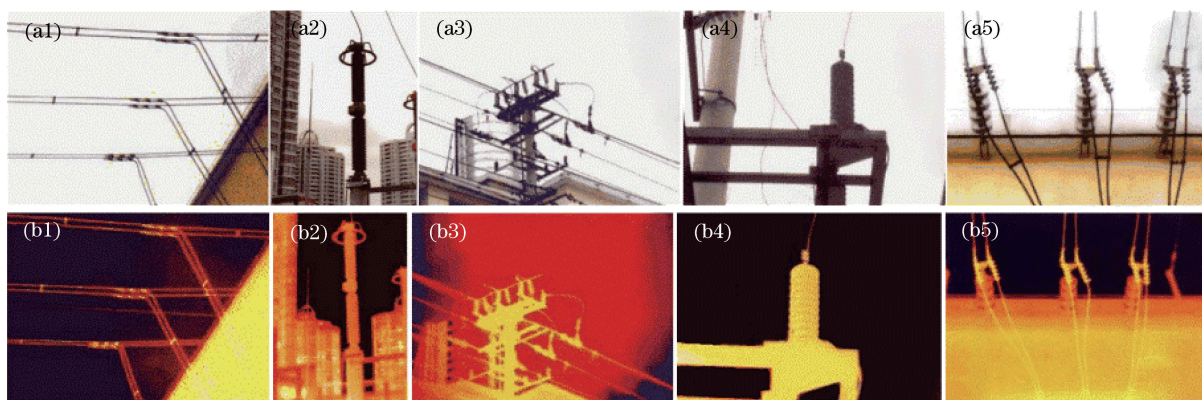


图 9 可见光图像集和红外图像集。(a)可见光图像;(b)红外图像

Fig. 9 Visible image set and infrared image set. (a) Visible image; (b) infrared image

按照标准配准数据集的标注格式进行人工标注,为每组红外和可见光图像标记 10 对匹配点<sup>[21]</sup>。用 CPSO 算法优化三种测度函数下的配准参数,每组样本图像配准 20 次,得到图 10 中三个测度函数各自的平均配准精度和平均配准时间。图 10 中的标记点“6”和“40”表示配准失败的两个样本。可以明显发现,SMI 算法的配准时间较长,SGNMI 算法的配准时间大于 GWW-NMI 算法,原因是 SGNMI 算法引入显著性检测导致配准时间稍长。而 SMI

算法的 MAE 和 RMSE 明显高于其他两种算法。实际数据集的结果与标准测试图像集的结果基本一致,这表明 GWW-NMI 算法虽然在配准效果上和 SGNMI 算法相近,且配准时间上有一定优势。但 SGNMI 算法侧重于人为增强红外图像中的显著性区域梯度,当红外图像出现模糊时,配准效果更好。

### 5.2 优化算法对比实验

为验证 CWPA 的有效性,采用 CPSO 算法<sup>[20]</sup>、CWPA 和 WPA 参数优化算法进行对比实验。其中 CPSO 算法和 WPA 均为智能种群算法,在图像配准中的效果较好<sup>[20]</sup>。

#### 5.2.1 标准测试函数对比实验

为了更好地覆盖不同类型的测试函数,选取包含单峰(U)/多峰(M)和低维(L)/高维(H)在内的 8 个测试函数,对比不同算法的寻优能力。选取的典型测试函数如表 6 所示。

由于不同文献对智能进化算法进行有效性测试时采用的测试参数有差别,采用参考文献中提供的最优参数设置算法中的其他参数<sup>[14-20]</sup>。用上述三种优化算法,按照表 2 设置的参数对标准测试函数进行 20 次独立实验,按照文献[22]中的评价指标,得到的结果如表 7 所示,其中,MEAN 为进化计算结束时的目标函数均值,STD 为目标函数标准差,SR 为寻优成功率, $\epsilon$  为单次计算得到的最佳目标函数与全局最优目标函数差的绝对值, $\epsilon < 10^{-6}$  表示寻优成功。SR 为寻优成功次数和实验总次数的比值,AEN 为平均寻优成功进化数,寻优成功进化数表示算法进化过程中首次达到寻优成功标准时的迭代次数。

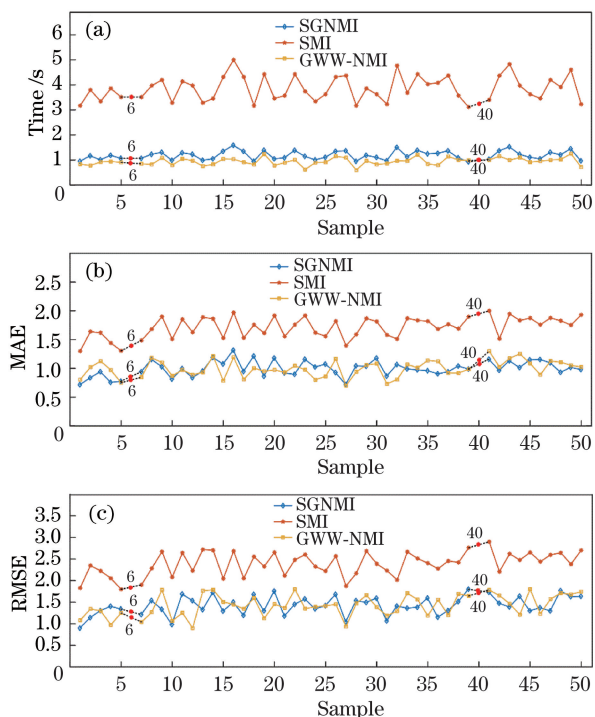


图 10 实际数据集的测试结果。(a)配准时间;(b) MAE; (c) RMSE

Fig. 10 Test results of the actual data set.

(a) Registration time; (b) MAE; (c) RMSE

表 6 标准测试函数  
Table 6 Standard test functions

Function	Expression	Feature	Solution space	Global extremum
Sphere	$f_1 = \sum_{i=1}^D x_i^2$	L/U	$[-10, 10]^2$	0
Sumsquares	$f_2 = \sum_{i=1}^D ix_i^2$	L/U	$[-10, 10]^{100}$	0
Booth	$f_3 = (x_1 + 2x_2 - 7)^2 + (2x_1 + x_2 - 5)^2$	L/M	$[-10, 10]^2$	0
Quadric	$f_4 = \sum_{i=1}^D (\sum_{k=1}^i x_k)^2$	L/M	$[-30, 30]^{100}$	0
Powersum	$f_5 = \sum_{i=1}^D [(\sum_{j=1}^D x_j^i) - b_i]^2$	H/U	$[-10, 10]^2$	0
Zakharov	$f_6 = \sum_{i=1}^D x_i^2 + (\sum_{i=1}^D 0.5ix_i)^2 + (\sum_{i=1}^D 0.5ix_i)^4$	H/U	$[-10, 10]^{100}$	0
Griewank	$f_7 = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos(\frac{x_i}{\sqrt{i}}) + 1$	H/M	$[-600, 600]^{100}$	0
Ackley	$f_8 = -20 \exp(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2}) - \exp[\frac{1}{D} \sum_{i=1}^D \cos(2\pi x_i)] + 20 + e$	H/M	$[-32, 32]^{100}$	0

表 7 优化算法的性能对比  
Table 7 Performance comparison of optimization algorithms

Function	Algorithm	MEAN	STD	SR / %	AEN
Sphere	WPA	$6.31 \times 10^{-91}$	$8.13 \times 10^{-87}$	100	111.30
	CPSO	<b><math>7.8 \times 10^{-188}</math></b>	<b><math>2.1 \times 10^{-185}</math></b>	100	<b>34.70</b>
	CWPA	$2.45 \times 10^{-91}$	$8.97 \times 10^{-88}$	100	102.10
Sumsquares	WPA	<b><math>2.16 \times 10^{-96}</math></b>	<b><math>8.57 \times 10^{-96}</math></b>	100	88.46
	CPSO	$1.03 \times 10^{-8}$	$1.05 \times 10^{-8}$	100	<b>33.64</b>
	CWPA	$4.84 \times 10^{-96}$	$2.17 \times 10^{-95}$	100	77.56
Booth	WPA	$1.32 \times 10^{-6}$	$1.7 \times 10^{-6}$	100	145.50
	CPSO	<b>0</b>	<b>0</b>	100	<b>31.24</b>
	CWPA	$1.07 \times 10^{-9}$	$1.25 \times 10^{-9}$	100	87.42
Quadric	WPA	$7.60 \times 10^{-84}$	$2.21 \times 10^{-89}$	100	326.52
	CPSO	$6.88 \times 10^{+2}$	$1.46 \times 10^{+2}$	0	2000.00
	CWPA	<b><math>6.82 \times 10^{-90}</math></b>	<b><math>3.12 \times 10^{-90}</math></b>	100	<b>226.60</b>
Powersum	WPA	$6.63 \times 10^{-95}$	$2.30 \times 10^{-95}$	100	113.30
	CPSO	$1.09 \times 10^{-6}$	$1.01 \times 10^{-6}$	100	1172.00
	CWPA	<b><math>4.84 \times 10^{-183}</math></b>	<b><math>1.27 \times 10^{-183}</math></b>	100	<b>38.42</b>
Zakharov	WPA	$3.18 \times 10^{-2}$	$2.98 \times 10^{-1}$	100	391.80
	CPSO	1.20	2.20	0	2000.00
	CWPA	<b><math>4.15 \times 10^{-16}</math></b>	<b><math>2.06 \times 10^{-16}</math></b>	100	<b>237.98</b>
Griewank	WPA	$1.44 \times 10^{-89}$	$5.56 \times 10^{-89}$	100	243.52
	CPSO	$1.03 \times 10^{+3}$	$2.97 \times 10^{+2}$	0	2000.00
	CWPA	<b><math>6.63 \times 10^{-90}</math></b>	<b><math>1.88 \times 10^{-89}</math></b>	100	<b>221.94</b>
Ackley	WPA	$9.33 \times 10^{-1}$	1.19	60	991.04
	CPSO	$9.37 \times 10^{+1}$	1.37	0	2000.00
	CWPA	<b><math>4.62 \times 10^{-10}</math></b>	<b><math>3.29 \times 10^{-12}</math></b>	<b>100</b>	<b>193.51</b>

从表 7 中可以发现,在 Sphere 和 Booth 函数的计算中,CPSO 算法表现最好;但 CPSO 算法在多峰函数 Quadric、Griewank 和 Ackley 中都无法进行有效收敛。CWPA 在多峰函数中的收敛性优于 CPSO 算法,WPA 仅在 Sumsquares 函数中 MEAN 和 STD 两个指标上优于 CWPA,在其他函数中均劣于 CWPA。这表明 CWPA 优于 WPA,原因是 CWPA 通过(22)式、(23)式的影响函数,引导群体空间中的狼群算法的进化,加速了算法的收敛。在各类标准测试函数中,CWPA 的 AEN 均小于 WPA 的 AEN,这表明 CWPA 的寻优效率更高。且 CWPA 在多峰函数中的收敛性优于 CPSO 算法和 WPA,原因是(18)式提高了群体空间中探狼局部最优解的感知能力,使狼群在每次迭代初期的探狼游走期间就避免了陷入局部最优。

### 5.2.2 实际数据集对比实验

为验证 CWPA 在实际电力巡检环境中的应用,利用 5.1.3 小节中的 50 组实际图像进行对比实验,用 SGNMI 作为统一的测度函数。CPSO 算法、CWPA 和 WPA 都是针对(13)式中的配准参数进行优化。首先,利用标注匹配点求出标准配准参数  $\{H_i, V_i, Q_i, R_i\} (i=1, 2, \dots, 50)$ ,  $H_i, V_i, Q_i, R_i$  分别为标准水平方向位移  $H$ 、标准垂直方向位移  $V$ 、标准图像旋转角度  $Q$ 、标准缩小率  $R$ 。其次,用目标配准误差(TRE)作为评价指标<sup>[23]</sup>,可表示为

$$\sigma_{TRE} = \sqrt{\left(\frac{H-h}{H}\right)^2 + \left(\frac{V-v}{V}\right)^2 + \left(\frac{Q-q}{Q}\right)^2 + \left(\frac{R-r}{R}\right)^2} \quad (26)$$

(26)式综合反映了配准参数  $h$ (水平平移量)、 $v$ (竖直平移量)、 $q$ (放缩率)和  $r$ (旋转角度)在优化过程中与理想值的差值,进而反映优化算法的配准精度。对每组图像配准 20 次,得到平均配准时间和平均  $\sigma_{TRE}$ ,如图 11 所示。其中,配准时间为满足  $\Delta\sigma_{TRE} \leq 10^{-3}$  时的计算时间。可以发现,WPA 在样本 6、33 和 40 上的  $\sigma_{TRE}$  异常高,CPSO 算法在样本 6 和样本 40 上的  $\sigma_{TRE}$  异常高。这表明配准优化算法在这几个样本上无法实现配准优化。但在其他样本中,WPA、CWPA 和 CPSO 算法的最终配准精度相近。在图 11(b)中,WPA 的计算时间较长,但在样本 6、33 和 40 上的配准时间异常少,这表明 WPA 在这三组样本的配准过程中陷入了局部最优解,过早地停止收敛。同样 CPSO 算法在样本 6 上,也过早地停止收敛。但在样本 40 中,CPSO 算法直到达

到最大收敛步数,即  $i_{ter} = 2000$  时,也未完全收敛。原因是图 11 中的样本 6 和样本 40 分别为图 9(a2)、图 9(b2)和图 9(a3)、图 9(b3),其中图 9(b2)和图 9(b3)的背景较为复杂,由 SGNMI 提取的梯度信息较多,导致在配准优化中的局部极值增加,不利于配准优化算法。

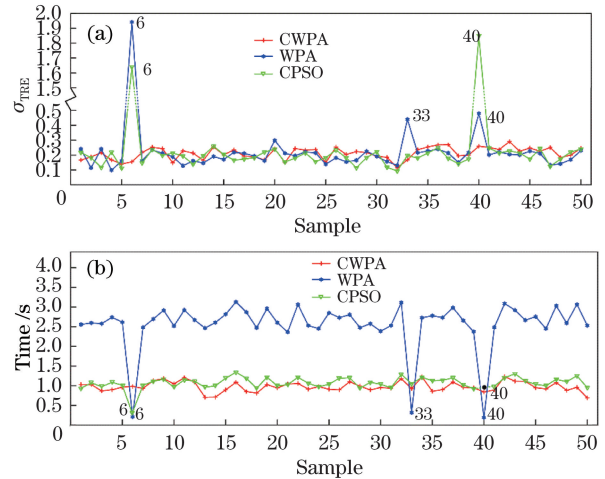


图 11 实际数据集的实验结果。(a)  $\sigma_{TRE}$ ; (b) 配准时间

Fig. 11 Experimental results of actual data set.

(a)  $\sigma_{TRE}$ ; (b) registration time

综上所述,实际图像数据集的实验结果(图 11)与标准测试数据集的实验结果(表 7)相吻合。且表 7 中 WPA 的 AEN 在各类函数中均高于 CWPA,因此 WPA 的配准时间远高于 CWPA。由于 CWPA 中用(18)式对局部最优解进行检测,使 CWPA 在自建图像集和标准测试函数中的寻优成功率均高于 WPA。CPSO 算法在表 7 中高维多峰函数上的表现明显比 CWPA 差,且在图 11 中 CPSO 算法的配准成功率低于 CWPA。但当三种算法都实现配准时,配准精度相差不大。这表明 CWPA 在图像配准这类高维多峰函数时的配准成功率和配准效率更高,更适合红外和可见光图像配准。

## 6 结 论

为了提高巡检机器人在电力巡检过程中对红外和可见光图像的配准效果,将红外图像中显著梯度信息和可见光图像的梯度信息进行对比,并结合传统归一化互信息,建立了新的 SGNMI 测度函数。实验结果表明,SGNMI 算法在牺牲一定配准时间的情况下,可提高对红外图像模糊程度的适应性。同时,结合了文化算法的双层进化机制和狼群算法,解决了狼群算法中探狼搜索方式单一和猛狼围攻半

径固化等问题。在标准测试函数的对比实验中, CWPA 相比于 WPA 有更好的收敛速度和收敛性; 相比于 CPSO 算法, CWPA 虽然在单峰函数中寻优能力较弱, 但在多峰函数中具有更好的全局寻优能力。在实际红外和可见光图像配准中, CWPA 表现出更高的收敛性和配准率。本算法为电力巡检机器人的红外与可见光图像配准提供了精度保证, 有利于后续电力设备的故障定位和故障识别。鉴于图像配准的最终目的是提升红外和可见光图像的融合质量, 后续研究还需结合图像融合算法, 对本算法进行更全面的评价。

## 参 考 文 献

- [1] Li Y, Yu F Y, Cai Q, et al. Image fusion of fault detection in power system based on deep learning[J]. *Cluster Computing*, 2019, 22(4): 9435-9443.
- [2] Li W, Dong M L, Lü N G, et al. Multispectral face image registration based on T-distribution mixture model[J]. *Acta Optica Sinica*, 2019, 39(7): 0710001. 李巍, 董明利, 吕乃光, 等. 基于 T 分布混合模型的多光谱人脸图像配准[J]. *光学学报*, 2019, 39(7): 0710001.
- [3] Zhu M, Yao Q, Tang J, et al. Image registration algorithm with hypergraph constraint and improved normalized cross correlation method[J]. *Journal of National University of Defense Technology*, 2019, 41(3): 50-55. 朱明, 姚强, 唐俊, 等. 超图约束和改进归一化互相关方法相结合的图像配准算法[J]. *国防科技大学学报*, 2019, 41(3): 50-55.
- [4] Chen L, Zhang F F, Yu L T, et al. A 2D-3D registration method based on normalized mutual information and multi-resolution fusion[J]. *Journal of Harbin Engineering University*, 2020, 41(2): 243-249. 陈龙, 张峰峰, 于凌涛, 等. 归一化互信息与多分辨率融合的 2D-3D 配准方法[J]. *哈尔滨工程大学学报*, 2020, 41(2): 243-249.
- [5] Abdel-Basset M, Fakhry A E, El-Henawy I, et al. Feature and intensity based medical image registration using particle swarm optimization [J]. *Journal of Medical Systems*, 2017, 41(12): 197.
- [6] Yan L, Wang Z Q, Ye Z Y. Multimodal image registration algorithm considering grayscale and gradient information[J]. *Acta Geodaetica et Cartographica Sinica*, 2018, 47(1): 71-81. 闫利, 王紫琦, 叶志云. 顾及灰度和梯度信息的多模态影像配准算法[J]. *测绘学报*, 2018, 47(1): 71-81.
- [7] Yang T J, Tang Q, Li L, et al. Nonrigid registration of medical image based on adaptive local structure tensor and normalized mutual information[J]. *Journal of Applied Clinical Medical Physics*, 2019, 20(6): 99-110.
- [8] Liu X Y, Wang H H, Sun G, et al. A novel automatic registration method for fluorescein fundus angiography sequences based on mutual information [J]. *Journal of Electronics & Information Technology*, 2018(8): 1919-1926. 刘小燕, 王浩浩, 孙刚, 等. 基于互信息的荧光素眼底血管造影图像序列的自动配准方法[J]. *电子与信息学报*, 2018(8): 1919-1926.
- [9] Yu K, Ma J, Hu F Y, et al. A grayscale weight with window algorithm for infrared and visible image registration[J]. *Infrared Physics & Technology*, 2019, 99: 178-186.
- [10] Wang C J, Goatman K, Boardman J P, et al. Distance oriented particle swarm optimizer for brain image registration[J]. *IEEE Access*, 2019, 7: 56016-56027.
- [11] Liu J, Li Y, Wang W B, et al. Automatic, high-accuracy image registration in confocal microscopy [J]. *Applied Optics*, 2017, 56(32): 8924-8930.
- [12] Pradhan S, Patra D. RMI based non-rigid image registration using BF-QPSO optimization and P-spline[J]. *AEU-International Journal of Electronics and Communications*, 2015, 69(3): 609-621.
- [13] Chen C L, Jian B L. Infrared thermal facial image sequence registration analysis and verification [J]. *Infrared Physics & Technology*, 2015, 69: 1-6.
- [14] Wu H S, Zhang F M. Wolf pack algorithm for unconstrained global optimization [J]. *Mathematical Problems in Engineering*, 2014, 2014: 1-17.
- [15] Chen X Y, Tang C J, Wang J, et al. Improved wolf pack algorithm based on differential evolution elite set[J]. *IEICE Transactions on Information and Systems*, 2018, E101.D(7): 1946-1949.
- [16] Yan X S, Song T, Wu Q H. An improved cultural algorithm and its application in image matching [J]. *Multimedia Tools and Applications*, 2017, 76(13): 14951-14968.
- [17] Zhu X Z, Tang C, Wang P C, et al. Saliency detection via affinity graph learning and weighted manifold ranking [J]. *Neurocomputing*, 2018, 312: 239-250.
- [18] Xue H, Shao Z P, Pan J C, et al. Cultural firefly algorithm for dynamic path planning of soccer robot [J]. *Control and Decision*, 2018, 33(11): 2015-2020. 薛晗, 邵哲平, 潘家财, 等. 基于文化萤火虫算法的足球机器人动态路径规划 [J]. *控制与决策*, 2018, 33(11): 2015-2020.

- [19] Liang J Y, Liu X P, Huang K N, et al. Automatic registration of multisensor images using an integrated spatial and mutual information (SMI) metric[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1): 603-615.
- [20] Guo Y N, Yang Z, Wang C, et al. Cultural particle swarm optimization algorithms for uncertain multi-objective problems with interval parameters[J]. Natural Computing, 2017, 16(4): 527-548.
- [21] Matthew B, Sabine S. Multi-spectral SIFT for scene category recognition[C]//International Conference on Computer Vision and Pattern Recognition (CVPR11), June 20-25, 2011, Colorado Springs, CO, USA. New York: IEEE, 2011: 177-184.
- [22] Xue J J, Wang Y, Li H, et al. A smart wolf pack algorithm and its convergence analysis [J]. Control and Decision, 2016, 31(12): 2131-2139.  
薛俊杰, 王瑛, 李浩, 等. 一种狼群智能算法及收敛性分析[J]. 控制与决策, 2016, 31(12): 2131-2139.
- [23] Öfverstedt J, Lindblad J, Sladoje N. Fast and robust symmetric image registration based on distances combining intensity and spatial information[J]. IEEE Transactions on Image Processing, 2019, 28(7): 3584-3597.