

# 面向电力设备红外-可见光图像配准的自适应 监督重训算法

范澜珊, 刘云鹏, 刘一瑾, 赵 涛, 裴少通, 闫泽玉

(河北省输变电设备安全防御重点实验室(华北电力大学), 保定 071003)

**摘要:** 为实现不同光学模态信息优势互补, 以助力电力设备故障检测与定位任务, 该文采用可见光图像增强红外图像的纹理信息。针对现有红外-可见光图像配准技术难以精确对齐电力设备局部精细化结构的问题, 首次提出自适应监督重训配准算法(adaptive registration algorithm with supervision and retraining, ARSR), 主要包括双阶各向异性高斯方向导数机制(dual order anisotropic Gaussian directional derivative, Dual-AGDD)以及双视图匹配参数重训框架(double-view matching parameter retraining, DVMPR)。首先, 提出 Dual-AGDD 完成特征点筛选与定向。1 阶 AGDD 进行自适应电力设备局部细化角点检测, 2 阶 AGDD 构建高斯特征三角形确定特征点主方向, 采用局部强度不变性方法构建特征描述子。接着, 提出 DVMPR 框架对图像透视尺度与视野旋转进行制约校正。最后, 基于  $3\sigma$  原则改进支持向量回归, 对误匹配点进行剔除, 完成异源数据配准。试验结果显示, 对不同旋转和尺度差异、不同环境的电力设备异源图像进行配准时, 该文算法的平均定位误差为 2.65, 平均配准精确率为 98.57%, 具有较强的图像旋转、尺度不变性和环境鲁棒性, 显著优于现有 CAO-C2F、SuperPoint-SuperGlue 等配准算法, 可提高电力设备精细化结构异源图像配准精度。

**关键词:** 电力设备; 红外-可见光图像配准; 各向异性高斯方向导数; 自适应监督重训; 角点检测

## Adaptive Algorithm with Supervision and Retraining for Power Equipment Infrared and Visible Images Registration

FAN Lanshan, LIU Yunpeng, LIU Yijin, ZHAO Tao, PEI Shaotong, YAN Zeyu

(Hebei Provincial Key Laboratory of Power Transmission Equipment Security Defense, North China Electric Power University, Baoding 071003, China)

**Abstract:** In order to realize the complementary advantages of different optical modalities and to help power equipment fault detection and location tasks, this paper uses visible images to enhance the texture information of infrared images. The existing infrared-visible image registration technology is difficult to accurately align local fine structures of power equipment, thus, to address this issue, an adaptive registration algorithm with supervision and retraining (ARSR) is proposed for the first time. The algorithm mainly includes a dual order anisotropic Gaussian directional derivative (Dual-AGDD) mechanism and a double-view matching parameter retraining (DVMPR) framework. Firstly, Dual-AGDD is proposed to filter and orient feature points. The 1st-AGDD performs adaptive local refinement corner detection for power equipment, and the 2nd-AGDD constructs a Gaussian feature triangle to determine the main direction of the feature point. The local intensity invariance method is adopted to construct feature descriptors. Then, the DVMPR framework is proposed to correct and constrain the perspective scale and view rotation of images. Finally, based on the  $3\sigma$  principle, support vector regression (SVR) is improved to eliminate the mismatched points and complete the registration of heterogeneous data. The experimental results show that, when heterogeneous images of power equipment with different rotations and scale differences or in different environments are registered, the average RMSE of the algorithm in this paper is 2.65, and the average precision is 98.57%. The results exhibit strong rotation invariance, scale invariance, and environmental robustness, and are significantly better than those of existing registration algorithms such as CAO-C2F and SuperPoint-SuperGlue algorithms. The algorithm can improve the registration accuracy of heterogeneous images of power equipment with fine structures.

**Key words:** power equipment; infrared and visible images registration; anisotropic Gaussian directional derivative; adaptive supervised retraining; corner detection

## 0 引言

在我国电力行业高速发展的背景下,加强电力系统智能化运行体系建设,加速训练 AI 大模型以适应电力领域任务已成为行业共识<sup>[1-2]</sup>。其中,基于视觉大模型的智能巡检任务中,巡检机器人和无人机自动巡航技术已成为电力设备在线监测和故障诊断系统的重要组成部分<sup>[3-5]</sup>,其通过结合图像识别、深度学习等数据分析手段实现对电力设备的高效监测与评估<sup>[6]</sup>。然而,红外图像存在分辨率低、边界模糊、纹理特征缺失等缺陷,严重限制了电力设备目标识别与热故障诊断精度<sup>[7]</sup>。

通过多模态图像配准融合的预处理手段,可结合不同特征信息于一体,弥补不同传感器的感知缺陷。其中,高精度的红外-可见光图像配准融合技术,通过结合热状态信息和机械结构等纹理信息,实现多模态数据增强<sup>[8-9]</sup>,有助于同时对设备表面破损和内部发热故障精确定位<sup>[10]</sup>,被广泛应用于电力设备故障诊断中。此外,以多源数据融合为基础的电力设备数字孪生技术是推动电网数字化、智能化转型,实现设备内部状态的评估和预测的关键环节<sup>[11-14]</sup>。

基于多模态成像传感器的图像预处理技术中,变压器红外-可见光图像配准是最常见也最关键的应用场景<sup>[15-17]</sup>。变压器套管红外热成像出现亮度异常分层,常指向由密封垫老化或密封不良导致的套管漏油故障;接线端发热常指向接线接触不良问题;而套管本体发热常预指绝缘老化迹象<sup>[18]</sup>。通过红外-可见光图像精确配准,融合热红外温度信息与可见光纹理信息,可快速识别变压器具体发热位置,判断故障原因,减少不必要的大范围检修<sup>[16]</sup>。

然而,受拍摄环境、传感器差异等因素影响,巡检机器人与无人机在工作时,采集到的异源图像在光谱、分辨率、视场角度以及视野范围存在显著差异<sup>[19]</sup>。其中,光谱差异会使图像梯度相似性降低,而视场角度以及视野范围差异会造成异源图像旋转、尺度差异等问题,严重影响配准精度,从而降低数字模型还原度,甚至造成模型故障诊断与预测维护功能的丧失。针对上述问题,国内外学者近年来提出了多种图像配准方案。文献<sup>[20-23]</sup>提出尺度不变特征变换算法(scale-invariant feature transform, SIFT)依赖局部区域像素选择特征主方向,降低图像尺度差异对特征匹配的影响。文献<sup>[24]</sup>提出加速鲁棒特征算法(speeded up robust features, SURF)降低

了特征提取的计算复杂度。文献<sup>[25-26]</sup>提出局部强度不变特征描述子(partial intensity invariant feature descriptor, PIIFD),仅利用 8 个面元的方向直方图增强了特征描述符应对梯度反转的鲁棒性。但在光谱、旋转角与尺度差异的影响下,基于图像梯度的特征点提取方法,终将面临特征点提取困难、特征点主方向相关度低的问题。从算法本质上预先消除异源图像的旋转差异与视野差异,是一种更加理想的办法。姜骞等提出的 CAO-C2F 算法对异源图像进行旋转对齐,投票选择与红外图像最接近的可见光图像尺度,较好地实现了异源图像的配准<sup>[27]</sup>。但 CAO-C2F 算法采用的传统曲率角点检测器,在图像局部细节复杂时易出现角点误检、漏检。且旋转角选择未设置监督机制,一旦旋转角计算失误,将删除大量正确配准连线,算法泛化性、鲁棒性差。

近年来,随着深度学习技术的发展,基于神经网络的特征提取与匹配算法相继出现, SuperPoint 算法<sup>[28]</sup>率先提出在单个神经网络中计算特征点与描述符,实现无标注特征点提取; SuperGlue 算法<sup>[29]</sup>采用注意力神经网络和最优传输方法解决特征点匹配问题,但计算复杂度高; LoFTR 算法<sup>[30]</sup>使用自我和交叉注意力层获取图像特征描述子,全局感受野使其在低纹理区域同样能够产生密集匹配; LightGlue 算法<sup>[31]</sup>设计了一种轻量级的置信度分类器,较 SuperGlue 具有更强的可训练性和匹配效率。这些基于神经网络的特征提取与匹配算法,在可见光图像配准上已取得较好的效果,但面对异源图像过高的光谱和信息差异,仍无法准确提取共同特征点进行匹配<sup>[32]</sup>。深度学习领域最新提出的异源图像配准算法 ReDFeat<sup>[33]</sup>,使用相互加权策略将多模态特征学习的检测能力和描述能力结合,提高了跨模态图像的配准性能,对图像尺度差异具有较强鲁棒性,但对旋转与视角变化敏感。

综上,在电力设备精细化结构的红外-可见光图像配准任务中,现有配准方法主要存在以下问题:1)特征点提取精度低。电力设备局部细节处结构相似性过高且结构精细复杂,需采用精度与稳定性更高的特征点提取方案。2)特征主方向选取模糊。由于红外图像与可见光图像存在光谱和分辨率差异<sup>[34]</sup>,需运用更具一致性的信息分配特征点主方向。3)受视野旋转、尺度差异影响大。在图像细节复杂且存在旋转视角与尺度差异时,现有局部不变性特征描述子不具备良好的鲁棒性<sup>[32,35]</sup>。

为解决上述问题, 本文首次提出自适应监督重训配准算法(adaptive registration with supervision and retraining, ARSR), 其主要创新性机制包括双阶各向异性高斯方向导数特征点自适应监督筛选与定向机制(dual order anisotropic Gaussian directional derivative, Dual-AGDD)和双视图匹配参数重训框架(double-view matching parameter retraining, DVMPR)。首先, 在特征提取与描述阶段, 提出了 Dual-AGDD 机制, 基于各向异性高斯响应, 结合电力设备红外与可见光图像突出的轮廓特征, 设计自适应门限阈值, 提高了特征点筛选的准确率, 再根据测度值计算相似性更高的特征主方向; 然后, 提出 DVMPR 算法, 基于斜率一致性理论提高旋转角度与尺度偏差计算准确度, 最大限度消除了因旋转与尺度差异造成的特征描述子匹配困难; 最后, 利用配准点主方向角差的标准差  $\sigma$ , 采用  $3\sigma$  原则改进支持向量回归(support vector regression, SVR), 提出  $3\sigma$ -SVR 算法, 以优化误匹配剔除性能, 完成图像匹配工作。

本文首先阐释了 ARSR 方法的逻辑框架及创新原理。然后, 以某变电站 110 kV 在运主变压器为例, 将 ARSR 算法与 CAO-C2F 等算法在不同条件的异源图像集下进行性能对比。实验结果表明, 本文 ARSR 算法通过在特征点提取、匹配参数计算等方面进行优化, 能够显著提升电力设备精细结构的红外-可见光图像配准精度, 最终配准效果优于现有算法, 且具有较好的环境鲁棒性。

## 1 ARSR 算法图像配准流程

本文提出一种面向电力设备红外-可见光图像配准的自适应监督重训算法, 具体流程如下所述。

1) 检测特征点。提出 Dual-AGDD 特征角点监督筛选与定向机制, 将电力设备红外和可见光图像集合输入各向异性高斯核函数角点检测网络。1 阶 AGDD 自适应阈值角点监督筛选首先采用 Canny 检测器分别提取异源图像边缘轮廓, 再使用各向异性高斯核函数对边缘轮廓进行遍历平滑, 依次计算出图像边缘轮廓上每个像素点的 AGDD 响应并进行标准化处理。设置自适应门限阈值, 通过 ReLU 激活函数对像素点进行流通控制, 提取候选角点集。对候选角点进行非极大值抑制处理, 确定正确角点集。

2) 指定特征点主方向、构建描述子。2 阶 AGDD

轮廓像素特征点定向, 采用边缘轮廓像素的 AGDD 测度值的极大值与双边极小值构建高斯特征三角形, 选取角点集特征方向, 构建 PIIFD 特征描述子并进行特征初匹配。

3) 图像旋转、尺度差异校正。基于主方向回归和斜率一致性, 提出 DVMPR 双视图匹配参数重训算法。对异源图像尺度、旋转角度进行相互制约的迭代矫正, 选取校正后的图像进行特征精匹配。

4) 剔除误匹配、构建图像变换矩阵。因系统误差产生的连接线斜率波动, 使匹配连线组的斜率统计满足近似正态分布, 所以先采用斜率  $3\sigma$  原则剔除明显假匹配连接线, 再采用 SVR 对误匹配连线进行进一步剔除。根据上述剔除结果, 计算热红外成像与可见光图像的投影变换矩阵<sup>[36]</sup>, 进行红外-可见光图像拼接融合。

总流程图如图 1 所示, 其中  $\zeta$  表示像素点 AGDD 响应标准化测度值;  $F$  表示角点筛选自适应门限阈值;  $I$  表示角点筛选门控信号的门控值;  $\zeta$  表示测度值  $\zeta$  与门控信号  $I$  的点积值;  $\text{Max}\{\zeta 5 \times 5\}$  表示非极大值抑制操作, 即选取  $5 \times 5$  像素范围内  $\zeta$  最大的像素点进行保留;  $\zeta_{\min}$  表示两个相邻角点连线上各像素测度值之中的最小值,  $\zeta_{\min 1}$  和  $\zeta_{\min 2}$  分别表示以特征角点为顶点, 左、右侧连线上各像素之中的测度值最小值; RRA 表示图像旋转回归角;  $\sigma_k^{(t)}$  表示第  $t$  次迭代后, 异源图像连线组斜率的标准差;  $\sigma_h$  表示斜率误差阈值, 指考虑系统误差时, 连线倾斜角的允许波动范围, 由连线斜率均值计算得到。

## 2 ARSR 算法原理

### 2.1 Dual-AGDD 特征点筛选与定向机制

电力设备图像集合为  $Q, q_i(\mathbf{x}) \in Q, i=1, 2, 3, \dots$ ,  $\mathbf{x}=[n_x, n_y]^T$ ,  $\mathbf{x}$  为像素点位置,  $i$  为图像标识序号。利用各向异性高斯核(anisotropic Gaussian kernels, ANGKs)生成滤波窗, 各向异性高斯核函数<sup>[37]</sup>为:

$$\begin{cases} g_{[\delta, \rho, \theta]}(\mathbf{x}) = \frac{1}{2\pi\delta^2} \exp\left(\frac{-1}{2\delta^2} \mathbf{x}^T \mathbf{R}_{(-\theta)} \mathbf{H} \mathbf{R}_{(\theta)} \mathbf{x}\right) \\ \mathbf{H} = \begin{bmatrix} \rho^2 & 0 \\ 0 & \rho^{-2} \end{bmatrix}, \mathbf{R}_{(\theta)} = \begin{bmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{bmatrix} \end{cases} \quad (1)$$

式中: 函数名  $g_{[\delta, \rho, \theta]}$  的下标括号内容表示滤波器所设参数;  $\theta$  为高斯核方向,  $\theta=(l-1)2\pi/L$  表示不同采样方向;  $l=1, 2, \dots, L$ ;  $L$  为总方向导数个数;  $\mathbf{R}_{(\theta)}$  表示方向为  $\theta$  的旋转矩阵;  $\mathbf{H}$  为各向异性因子矩阵;  $\delta \in (0, \infty)$  为高斯尺度, 尺度越大, 核函数对噪声的

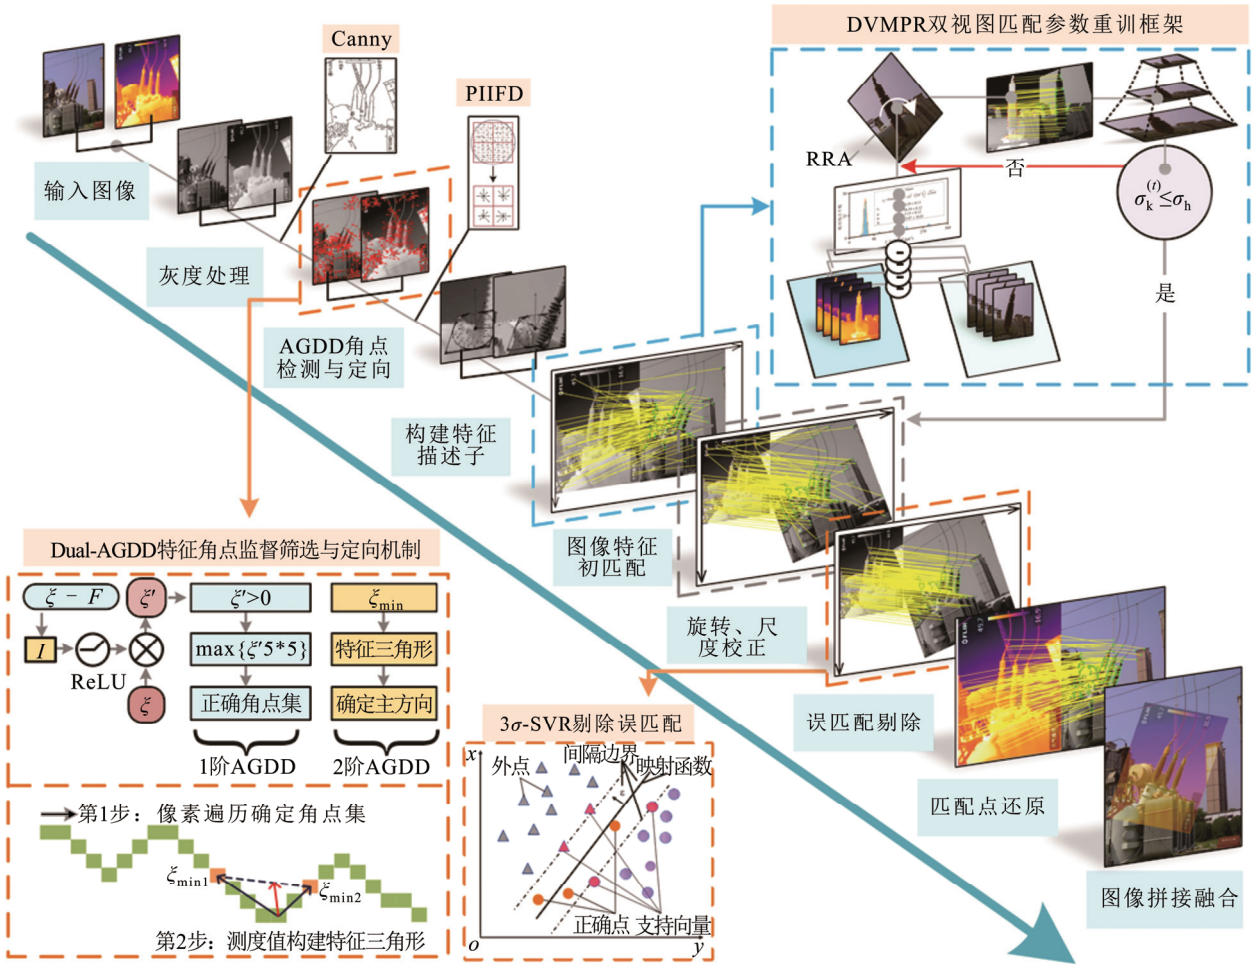


图1 ARSR算法总流程图

Fig.1 Flowchart of the ARSR algorithm

抑制能力越强； $\rho \in [1, \infty]$ 为各向异性因子，各向异性因子越大，核函数的方向选择性越强，对边缘像素和角点的区分能力越强。但随着尺度 $\delta$ 和各向异性因子 $\rho$ 的增大，角点定位性能下降，导致临近角点计算位置重叠。为兼顾噪声稳定性与角点定位准确性， $\rho^2$ 与 $\delta^2$ 的选择范围为[4,8]。

图像数据的存在形式为二维离散信号，所以将高斯核函数与其方向导数进行离散处理得：

$$g_{[\delta, \rho, \theta]}(\mathbf{n}) = \frac{1}{2\pi\delta^2} \exp\left(-\frac{1}{2\delta^2} \mathbf{n}^T \mathbf{R}_{(-\theta)} \mathbf{H} \mathbf{R}_{(\theta)} \mathbf{n}\right) \quad (2)$$

与 $q_i(x) \in Q$ ， $\mathbf{x}=[n_x, n_y]^T$ 对应，经离散处理后，取 $x$ 的整数值，得到 $\mathbf{n}=[n_x, n_y]^T \in \mathbf{Z}$ 表示图中各像素点。将式(2)对 $\pi/2+\theta$ 求导即可得到各向异性高斯方向导数。

$$\lambda_{[\delta, \rho, \theta]}(\mathbf{n}) = \frac{\partial g_{[\delta, \rho, \theta]}(\mathbf{n})}{\partial \theta}(\mathbf{R}_{(\theta)} \mathbf{n}) = -\frac{\rho^2}{\delta^2} (n_y \cos \theta - n_x \sin \theta) \cdot g_{[\delta, \rho, \theta]}(\mathbf{n}) \quad (3)$$

电力设备图像 $q_i(x)$ 的各向异性高斯方向导数响应 $\nabla q(\mathbf{n}, l)$ 为：

$$\begin{cases} \nabla_{[\delta, \rho]} q(\mathbf{n}, l) = \sum_{n_x} \sum_{n_y} q_i(\mathbf{n} - \mathbf{n}_1) \lambda_{[\delta, \rho, \theta]}(\mathbf{n}_1) \\ \mathbf{n}_1 = [n_{x_1}, n_{y_1}]^T \in \mathbf{Z} \end{cases} \quad (4)$$

式中： $\mathbf{n}_1$ 表示各向异性高斯卷积核坐标。

### 2.1.1 1阶AGDD自适应阈值角点监督筛选

常见的角点类型皆可用多个简单角点模型叠加表示，则通用角点模型可表示为：

$$\mathcal{G}(r, \alpha) = \sum_{i=1}^m T_i C_{[\alpha_i, \alpha_{i+1}]}(r, \alpha) \quad (5)$$

式中： $C(r, \alpha)$ 表示一个简单角点模型； $r$ 为角点对应极径； $\alpha$ 代表极角； $T$ 代表不同区域的灰度信息； $m$ 为该角点包含的简单角点模型个数。

则任意一个双边极角分别为 $\alpha_1, \alpha_2$ 的通用角点的AGDD响应表示为：

$$\nabla_{[\alpha_1, \alpha_2]}(\theta) = \iint_{R^2} \mathcal{G}(r, \alpha) \lambda_{[\delta, \rho, \theta]}(-r, -\alpha) r dr d\alpha = \frac{\rho}{2\sqrt{2\pi}\delta} \sum_{i=1}^m \frac{(T_i - T_{i-1}) \cos(\theta - \alpha_i)}{\sqrt{\rho^4 \sin^2(\theta - \alpha_i) + \cos^2(\theta - \alpha_i)}} \quad (6)$$

当  $\alpha_1 - \alpha_2 = \pi$  时, 该角点模型即为边缘模型, 其 AGDD 响应即为:

$$\nabla_{[\alpha_2 - \alpha_1 = \pi]}(\theta) = \frac{\rho}{\sqrt{2\pi}\delta} \frac{(T_1 - T_2) \cos(\theta - \alpha_1)}{\sqrt{\rho^4 \sin^2(\theta - \alpha_1) + \cos^2(\theta - \alpha_1)}} \quad (7)$$

响应在  $\theta = \alpha_1$ ,  $\theta = \pi + \alpha_1$  两处存在幅值极值。

$$\max |\nabla_{[\alpha_2 - \alpha_1 = \pi]}(\theta)| = \left| \frac{\rho}{\sqrt{2\pi}\delta} (T_1 - T_2) \right| \quad (8)$$

图像中多个方向灰度都剧烈变化的像素点被定义为角点, 由式(6)可知, AGDD 响应幅值大小正比于像素周围的灰度差。因此, 边缘像素的 AGDD 响应幅值谱仅在灰度变化梯度方向存在较大响应幅值, 而常见角点的 AGDD 响应在多个方向上都存在峰值, 如图 2 所示, 其中 A、B、C 分别为 L 型角点、Y 型角点和边缘像素点, 它们的响应幅值谱依次展示于图右侧。

为从红外、可见光图像中提取完整、有效且准确对应的角点集, 本文遍历异源图像边缘轮廓上的每一个像素点, 求得各像素 AGDD 响应进行标准化处理并求和, 设置自适应门限阈值, 对每个像素的响应选择自适应限值, 从而克服经验阈值的限制, 降低角点漏判、错判率。角点筛选流程如图 3 所示。

角点自适应门限阈值  $F$  经 AGDD 响应标准化并积分求和而得, 计算式为:

$$F = \int_0^\pi \frac{|\nabla_{[\alpha_2 - \alpha_1 = \pi]}(\theta)|}{\max |\nabla_{[\alpha_2 - \alpha_1 = \pi]}(\theta)|} d\theta \quad (9)$$

实际各方向 AGDD 响应标准化测度值  $\zeta$  的计算式为:

$$\begin{cases} \xi(\mathbf{n}) = \Delta\theta \cdot \sum_{l=1}^L \frac{\nabla_{[\sigma, \rho]} q(\mathbf{n}, l)}{\max(\nabla_{[\sigma, \rho]} q(\mathbf{n}, l))} \\ \Delta\theta = \pi / L \end{cases} \quad (10)$$

图 3 中, 角点门控信号的门控值  $I$  通过 ReLU 激活函数对像素点进行流通控制。当测度值  $\zeta$  小于门限阈值  $F$  时, 神经元未激活, 门控值  $I$  与测度值  $\zeta$  点积为 0, 流通门关闭, 并将该像素点认定为边缘像素点; 当测度值  $\zeta$  大于门限阈值  $F$  时, 神经元激活, 角点核验通过一层筛选, 生成候选角点集。对候选角点集进行非极大值抑制, 经过二层筛选得到异源图像的最终角点集。

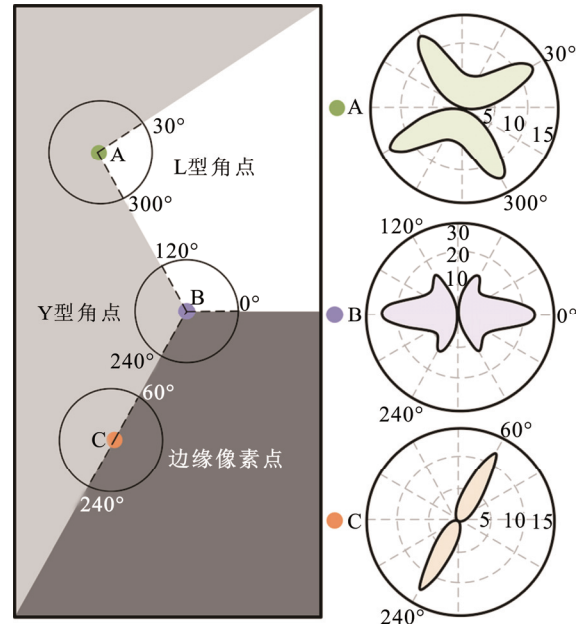


图 2 常见角点与边缘像素的 AGDD 响应幅值谱示意图  
Fig.2 Schematic representation of AGDD amplitude spectrum of common corner and edge pixels




图 3 自适应门限阈值特征角点双层筛选流程图  
Fig.3 Flowchart of adaptive threshold feature corner two-stage screening

### 2.1.2 2 阶 AGDD 轮廓像素特征点定向

确定角点集后, 需对每一个角点选定特征主方向, 从而实现特征描述子构建。1 阶 AGDD 阶段已求得红外图像与可见光图像角点集与边缘各像素的 AGDD 响应。以各特征角点为顶点, 以特征角点指向其两侧测度值  $\zeta$  极小值  $\zeta_{\min 1}$  和  $\zeta_{\min 2}$  的特征向量为边, 构建高斯特征三角形, 该三角形中线所指的方

向定为特征角点的主方向，主方向分配示意如图 4 所示，其中  $\varphi$  表示特征点主方向角。

采用特征角点与特征主方向向量构建 PIIFD 描述子<sup>[25]</sup>，将可见光图像与红外图像的 PIIFD 描述子进行初匹配。

**2.2 DVMPR 双视图匹配参数重训框架**

特征描述符的特性表明，异源图像在尺度归一化、图像信息旋转角一致时，可实现最高特征点配准精度。为从算法本质上预先消除异源图像的旋转差异与视野差异，提升异源图像配准性能，本文提出 DVMPR 双视图匹配参数重训框架。

文献[36]中提出“连线一致性理论”，即在红外和可见光图像尺度相同且无相对旋转时，理论上所有正确匹配特征连线的倾斜角和长度相等，且所有正确匹配特征点对的主方向角度差应为同一角度值，等于实际红外、可见光图像的相对旋转角度。受此启发，若能将红外图像固定，可见光图像按照该相对角度进行旋转，即可消除异源图像间旋转错位，本文称之为“旋转回归角”(rotation regression angle, RRA, 用  $\theta_{RRA}$  表示)。在消除旋转错位后，若 2 张尺度比例因子一致的异源图像横向同轴摆放，所有正确配准连线的斜率应一致。其中，尺度比例因子等于垂直分辨率相同的红外和可见光图像中相同区域的像素面积比。基于此，可通过配准连线斜率调整异源图像尺度参数一致。若多次迭代中异源图像配准线组始终无法平行，则由算法质疑旋转回归角计算结果。对旋转角度与尺度进行循环制约校正，优化异源图像配准参数。具体步骤如下所述。

1) 选定初始旋转回归角。根据 PIIFD 初配准特征点对，计算特征点坐标与特征点对的主方向角差，并进行角度分区统计。取角度统计正态拟合曲线数学期望为可见光图像 RRA 估计值。

2) 计算连线斜率均值、标准差。采用主方向角差  $3\sigma$  法则剔除明显误匹配连线，降低误匹配连线的干扰。随后计算连线组斜率及其均值  $\mu_k$ 、标准差  $\sigma_k$ 。

3) 尺度、旋转角重训。本文选取 3% 为迭代步长，依照迭代表现对图像尺度进行连续变化。若尺度迭代次数超过限值，斜率标准差  $\sigma_k$  仍无法收敛至自适应阈值  $\sigma_h$  内，则在标准差最接近阈值  $\sigma_h$  处重新返回 RRA 训练，再次循环迭代。

4) 确认图像尺度与旋转回归角，进行图像精

配准。反复迭代重训后，当斜率标准差  $\sigma_k^{(t)}$  小于自适应斜率误差阈值  $\sigma_h$  时，选取此时双视图的旋转角和尺度参数为最优匹配参数，进行图像精匹配。

图 5 为主方向角差直方图，其中， $\mu$  表示主方向角差数学期望，即为可见光图像主方向旋转回归角 RRA 估计值； $y_0$  和  $A$  分别表示标准正态分布的偏移量与缩放量； $\Delta\varphi$  表示特征点主方向角差。

此外，斜率误差阈值  $\sigma_h$  随每次图像迭代后的连线组斜率均值  $\mu_k$  变化而变化。考虑现有红外、可见光图像的常见分辨率比值，本文选用连接线倾斜角误差波动值为  $\pm 3^\circ$ 。自适应斜率误差阈值  $\sigma_h$  即为：

$$\begin{cases} \sigma_h = \sqrt{\frac{1}{N} \sum_{i=1}^N (\omega - \mu_k^{(i)})^2} = |\omega - \mu_k^{(i)}| \\ \omega = \max(\tan(\arctan(\mu_k^{(i)}) - 3^\circ), \tan(\arctan(\mu_k^{(i)}) + 3^\circ)) \end{cases} \quad (11)$$

式中： $N$  为图像配准连线数； $t$  为迭代次数； $\omega$  为连线倾斜角波动换算量。

每次迭代对可见光图像尺度修正参数  $Z$  进行  $\pm 3\%$  的调整。初步迭代时，先对可见光图像进行  $-3\%$  的尺度调整，持续 3 次迭代，若斜率标准差持续减小，则继续减小可见光图像尺度；若斜率标准差增大，则反向以  $+3\%$  进行可见光尺度逐步增大。一次尺度修正后，根据特征点坐标变动，计算配准连线




图 4 AGDD 响应特征角点主方向分配示意图

Fig.4 Schematic diagram of the principal direction assignment of AGDD response feature corners




图 5 直方图正态拟合估计旋转视角的原理图

Fig.5 Schematic of the histogram normal fit to estimate the rotational perspective

斜率  $k_i^{(1)}$ 、连线斜率均值  $\mu_k^{(1)}$  与斜率标准差  $\sigma_k^{(1)}$ 。

若第  $t$  次迭代后整组连线斜率标准差  $\sigma_k^{(t)}$  小于斜率误差阈值  $\sigma_h$ , 则认为此时所有连线平行。若尺度迭代次数超过限值(本文根据数据集红外图像分辨率设置迭代限值  $t_h$  为 30 次), 斜率标准差  $\sigma_k$  仍无法收敛至自适应阈值  $\sigma_h$  范围内, 则选用该轮迭代中标准差  $\sigma_k$  最接近阈值  $\sigma_h$  的图像尺度, 返回旋转回归角制约更新。对 RRA 进行  $\pm 2^\circ$  的迭代校正。首先对可见光图像进行  $-2^\circ$  的旋转, 计算连线斜率, 持续 3 次迭代, 若斜率标准差持续减小则继续减小可见光图像旋转角度; 若斜率标准差增大, 则反向以  $+2^\circ$  进行可见光旋转角逐步增大。在标准差最接近阈值  $\sigma_h$  处进行二轮尺度校正, 循环迭代。直至连线斜率标准差  $\sigma_k^{(t)}$  小于斜率误差阈值  $\sigma_h$ , 结束迭代。选用经 DVMPR 框架旋转、尺度校正后的两张异源图像进行图像精配准。DVMPR 双视图匹配参数重训框架流程如图 6 所示。

### 2.3 ARSR 算法复杂度分析

ARSR 算法可分为 3 部分: Dual-AGDD、DVMPR、 $3\sigma$ -SVR, 各部分时间、空间复杂度分析如表 1 所示。其中  $b$  为图像像素数;  $B$  代表特征点数量( $B \ll b$ )。

在特征点提取与定向阶段, Canny 边缘检测和 AGDD 响应值的计算均为线性操作, 时间复杂度主要取决于图像像素数, 空间复杂度主要取决于图像数据大小、边缘像素和 AGDD 响应计算结果, 均为  $O(b)$ 。PIIFD 特征匹配的时间复杂度主要取决于算法的复杂度, 为  $O(B \lg B)$ , 空间复杂度主要取决于特征描述子的数量, 为  $O(B)$ 。在 DVMPR 阶段利用特征连线斜率对异源图像尺度和旋转角度进行相互制约的迭代矫正, 因此时间复杂度主要取决于迭代次数和特征点数量, 为  $O(tB)$ , 占用存储空间的校正参数和临时矫正结果均由特征点信息求出, 可认为空间复杂度为  $O(B)$ 。 $3\sigma$ -SVR 误匹配剔除算法的时间复杂度主要取决于训练过程的核函数计算, 空间复杂度主要由支持向量数量决定, 支持向量数与特征点数量相关, 因此该过程时间复杂度为  $O(B)$ 、空间复杂度为  $O(B)$ 。

舍弃低阶项后, ARSR 算法的总时间复杂度为  $O(b) + t \times O(B) + O(B^2)$ , 空间复杂度为  $O(b) + O(B)$ 。主要计算负载来源于图像大小、特征点数量以及重训迭代次数。

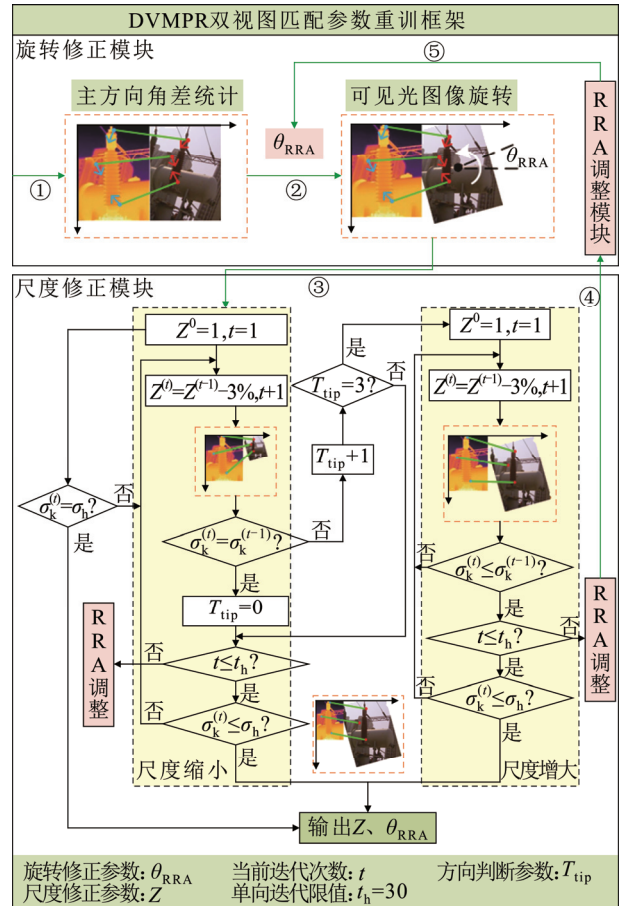


图 6 DVMPR 双视图匹配参数重训框架流程图

Fig.6 Flowchart of double-view matching parameter retraining (DVMPR)

表 1 ARSR 算法复杂度分析

Table 1 ARSR complexity analysis

ARSR 算法组成部分	具体步骤	时间复杂度	空间复杂度
Dual-AGDD	Canny 边缘提取	$O(b)$	$O(b)$
	求取 AGDD 响应	$O(b)$	$O(b)$
	PIIFD 特征匹配	$O(B \lg B)$	$O(B)$
DVMPR	最佳旋转角、尺度因子选取	$O(tB)$	$O(B)$
$3\sigma$ -SVR	支持向量机训练预测	$O(B^2)$	$O(B)$

### 3 实验分析

本实验以某变电站在运 110 kV 有载调压变压器为测试对象, 实地采集可见光图像和红外热成像, 进行异源数据配准测试, 验证 ARSR 算法的有效性。本实验使用的主要软、硬件参数为: 计算主机的 CPU 处理器为: Intel Core i7-13700KF 3.4 GHz, GPU 为 NVIDIA GeForce RTX 4090; 相机为 FLIR T420 双光谱相机, 操作系统为 Windows 11。

实验数据集采用实地采集的变电站 110 kV 在

运 1 号主变多角度异源图像, 所采集红外图像的分辨率为  $240 \times 320$ , 可见光图像分辨率为  $711 \times 949$ 。数据集涉及 5 种类型图像, 共 126 对。

I) 无明显旋转尺度差异的变压器 3 套管图像对, 呈现精细电力设备常见的锯齿轮廓特征。用于 Dual-AGDD 角点检测与特征点主定向实验, 共 26 对。

II) 有明显视野旋转、无尺度差异的变压器单支套管图像对。用于 Dual-AGDD 角点检测与特征点主定向性能测试与 ARSR 算法的旋转鲁棒性测试, 共 30 对。

III) 有明显尺度差异、无视野旋转的变压器 3 套管图像对。用于检测 ARSR 算法图像的尺度鲁棒性, 共 40 对。

IV) 尺度、旋转、视角差异明显的变压器 3 套管图像对。用于测试电力设备目标所占像素面积较小时 ARSR 算法图像旋转、尺度不变性能, 共 30 对。

V) 有明显视角差异与视野旋转的变压器箱体图像对。用于测试 ARSR 算法对不同设备的适用性, 共 35 对。

I—V 组图像分别在不同时间人工采集, 呈现不同的尺度、旋转、视角差异, 模拟巡检机器人和无人机红外、可见光采集传感器的差异。

### 3.1 评估指标

本文选用准确率( $P$ )与召回率( $R$ )作为图像配准性能评价指标<sup>[38]</sup>, 除此之外引用均方根误差(root mean square error, RMSE)评估图像拼接融合性能。

准确率表示正确匹配对数  $N_{\text{correct}}$  与实际总匹配对数  $N_{\text{all}}$  的比值, 由配准算法与特征描述符区分性确定。配准算法越严谨, 误匹配率越低, 配准准确率越高。

$$P = \frac{N_{\text{correct}}}{N_{\text{all}}} \quad (12)$$

召回率表示正确匹配点对数  $N_{\text{correct}}$  占 AGDD 角点检测器提取的正确匹配角点对数  $N_{\text{AGDD}}$  的比例。召回率用于表征算法从异源图像中提取正确匹配点对的能力, 召回率越大, 配准方法区分特征点的适应性越强。

$$R = \frac{N_{\text{correct}}}{N_{\text{AGDD}}} \quad (13)$$

基于结构相似性的均方根误差用于评估图像细节对齐效果<sup>[20]</sup>。RMSE 指图像匹配点  $(x, y)$  与理论匹配参考点  $(x^{\text{set}}, y^{\text{set}})$  之间的均方根误差。均方根误差

越小, 图像细节处的对准程度越高。

$$e_{\text{RMSE}} = \sqrt{\frac{\sum_{i=1}^{N_{\text{all}}} \|(x_i, y_i) - (x_i^{\text{set}}, y_i^{\text{set}})\|_2}{N_{\text{all}}}} \quad (14)$$

### 3.2 各改进策略效果验证

为证明 ARSR 算法各创新措施的实用性、有效性, 本节设置分步实验逐步探究 Dual-AGDD 特征点监督筛选与定向机制、DVMPPR 双视图匹配参数重训、 $3\sigma$ -SVR 误匹配剔除方案对电力设备异源图像匹配的性能改善。并以基于轮廓曲率角点提取的 PIIFD 特征匹配算法为基准算法设置消融实验, 验证本文 3 种创新策略皆具备独立存在的意义, 不存在冗余性。

#### 3.2.1 Dual-AGDD 特征点筛选与定向机制测试

在应对细节结构较多的电力设备图像配准融合任务中, 特征角点的提取准确率与数量, 以及特征角点主方向选择准确性, 将直接影响细节处配准精度。为测试 Dual-AGDD 双阶角点检测与定向算法的性能, 将其与 CSS、CPDA、Harris 角点检测算法进行对比, 分别计算角点定位误差。假设  $R = \{R_k, k=1, 2, \dots, M_1\}$  表示真实角点集, 集合  $D = \{D_k, k=1, 2, \dots, M_2\}$  表示通过不同角点检测器检测到的角点集。当真实角点与检测器检测到的角点之间的距离小于距离阈值(本文设置 5 个像素点)则判定角点检测正确。定位误差  $L_{\text{eq}}$  数学表达式为:

$$L_{\text{eq}} = \sqrt{\frac{1}{M_r} \sum_{k=1}^{M_r} \|R_k - D_k\|_2^2} \quad (15)$$

式中:  $M_r$  代表检测正确的角点个数, 等于真实角点数  $M_1$  减去错误角点数减去漏检角点数。

图像中任意一条边缘轮廓的 AGDD 角点测度值提取示意如图 7 所示。

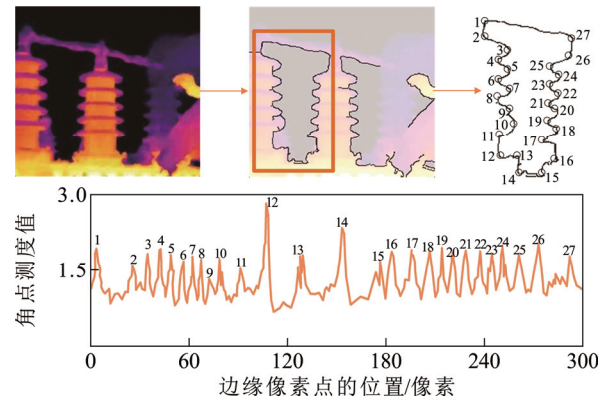


图 7 变压器套管红外图像轮廓角点 AGDD 测度值

Fig.7 AGDD measurement value  $x$  of the contour corner of the infrared image of the transformer bushing

采用第 I 组(26 对)无明显旋转尺度差异的变压器 3 套管红外、可见光图像与第 II 组(30 对)有明显视野旋转、无尺度差异的变压器单支套管图像进行角点提取, 异源图像角点平均定位误差、平均漏检角点数与误检角点数如表 2 所示。

将 ARSR 算法角点集主方向分配结果与 SIFT-LPM 算法<sup>[39,23]</sup>、PIIFD 算法<sup>[19,26]</sup>、CAO-C2F<sup>[27]</sup>算法比较, 如图 8 所示, “白框”内各算法主方向选择差异最显著。由 4 种方法计算的特征主方向可见, SIFT-LPM 算法基于灰度梯度变化进行特征方向提取, 红外图像与可见光图像灰度变化相反<sup>[19]</sup>, 导致该算法检测到的异源图像特征方向几乎相反; PIIFD 算法的描述子为解决梯度方向差异的问题引入了连续均方梯度, 但该算法提取的特征点过于冗余, 且主方向差异过大, 将对后续匹配造成困难; CAO-C2F 算法基于常规 CSS 算法进行角点提取, 当遇到变压器套管、绝缘子等锯齿边缘时, 常出现细节处特征点漏检现象, 导致整条锯齿边缘均无角点被提取, 最终将导致锯齿边缘配准错位的问题; ARSR 算法提取的特征点分布较均匀, 未产生特征点堆积现象, 且异源图像的主方向相似性较高, 提高了特征描述子的辨识度。

本文 ARSR 算法中, Dual-AGDD 特征点检测与定向机制的角点误检率、漏检率显著低于其他 3 种对比算法, 且检测器提取出的角点定位误差最小, 由 AGDD 高斯特征三角形定位的异源图像特征主方向相似性最高。

### 3.2.2 DVMPR 双视图匹配参数重训测试

为验证双视图匹配参数重训框架的性能, 采用 DVMPR 框架对数据集内 5 组图像进行迭代训练, 训练前后的准确率、召回率对比如表 3 所示。

经指标对比显示, DVMPR 框架调整图像旋转角、尺度一致后, 最大限度消除了因旋转、尺度差异造成的特征匹配困难, 图像配准性能改善显著。无论是针对旋转、尺度差异明显还是细节复杂的图像, 经过重训框架校正后, 配准准确率与召回率均有所提升。尤其是第 IV 组的尺度、旋转、视角差异都明显的变压器 3 套管图像, 经校正后配准召回率显著提升了约 25%, 第 V 组有明显视角与视野旋转的变压器箱体图像对, 经校正后配准准确率提升了约 18%。第 II 组、第 IV 组校正前后的配准对比如图 9 所示, 可看出经旋转与尺度校正后图像的误配点对减少, 图像正确连线尤其是套管边缘处的匹配连

表 2 I、II 组图像角点检测比较结果

Table 2 Comparison results of corner detection of I, II

对比 算法	$L_{eq}$ /像素		漏检角点数/个		误检角点数/个	
	I 组	II 组	I 组	II 组	I 组	II 组
CSS	4.573	4.651	64.314	32.274	22.384	8.370
CPDA	4.466	3.536	59.367	19.288	27.904	12.378
Harris	3.062	2.968	31.873	24.284	24.379	8.992
本文算法	1.734	2.650	18.263	5.398	16.355	3.981




图 8 4 种算法红外(左)可见光(右)图像特征主方向

Fig.8 Main directions of image features for four algorithms

表 3 旋转、尺度校正前后准确率、召回率对比

Table 3 Comparison of precision and recall before and after rotation and scale correction

图像 组别	$P$		$R$	
	校正前	校正后	校正前	校正后
I 组	0.774 9	0.892 5 ↑	0.593 1	0.6905 ↑
II 组	0.802 4	0.903 8 ↑	0.553 9	0.706 0 ↑
III 组	0.795 8	0.873 2 ↑	0.492 6	0.663 7 ↑
IV 组	0.864 1	0.897 6 ↑	0.412 9	0.665 4 ↑
V 组	0.727 9	0.906 4 ↑	0.380 6	0.611 1 ↑

线数量增加。

### 3.2.3 $3\sigma$ -SVR 误匹配点对剔除测试

现有误匹配连线剔除常用的随机样本一致性算法(random sample consensus, RANSAC)当误配点过多时, 可能出现误剔除率过高的情况。采用  $3\sigma$ -SVR 剔除方案, 以上述第 II 组、第 IV 组图像经双视图匹配参数重训校正结果进行误匹配剔除测试, 与 RANSAC 剔除算法指标对比如表 4 所示。

如图 10 与表 4 测试结果显示, 虽然 2 种剔除算法较剔除前的匹配准确率均有提升, 但 RANSAC 算法因剔除正确匹配连线过多造成召回率下降, 而  $3\sigma$ -SVR 算法能保持召回率与剔除前不变。说明

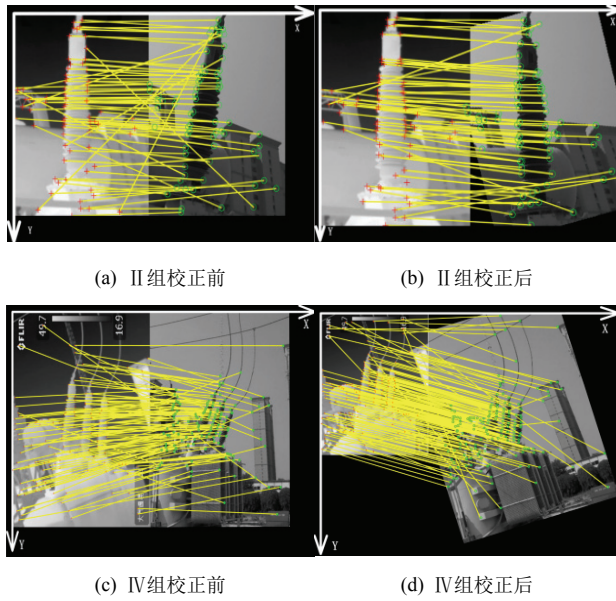


图9 双视图匹配参数重训练校正前后匹配对比图  
Fig.9 Comparison chart of the matching parameters before and after retraining and correction in the dual view

表4 3σ-SVR 与 RANSAC 算法准确率、召回率对比

Table 4 Comparison of the accuracy and recall rate of 3σ-SVR and RANSAC methods

评价指标	II组(30对)		
	经旋转、尺度校正后	RANSAC	3σ-SVR
<i>P</i>	0.903 8	0.967 7 ↑	0.982 3 ↑
<i>R</i>	0.706 0	0.689 3 ↓	0.706 0—
评价指标	IV组(30对)		
	经旋转、尺度校正后	RANSAC	3σ-SVR
<i>P</i>	0.897 6	0.957 5 ↑	0.990 1 ↑
<i>R</i>	0.665 4	0.504 2 ↓	0.665 4—

3σ-SVR 方案较 RANSAC 算法更能精确剔除错误匹配点对, 且保留了正确配准点对。

### 3.2.4 消融实验

为测试 ARSR 算法 3 种改进策略对整体性能贡献, 更好地观察各改进策略的作用表现, 本节以基于轮廓曲率角点提取的 PIIFD 特征匹配算法为基准算法, 在基准算法上组合添加①Dual-AGDD 机制、②DVMPR 框架、③3σ-SVR 误匹配剔除方案。各消融组合分别对本文自建数据集内第 II 组有明显视野旋转、无尺度差异的变压器单支套管图像(30 对)和第 IV 组尺度、旋转、视角差异明显的变压器 3 套管图像(30 对)的图像进行配准性能对比, 评价指标统计如表 5 所示。

由于 3σ-SVR 误匹配剔除方案基于斜率一致性提出, 在图像尺度相同且无相对旋转时才能发挥最




图10 3σ-SVR 与 RANSAC 算法误匹配剔除结果对比

Fig.10 Comparison of mismatched culling results using 3σ-SVR and RANSAC methods

表5 消融实验评价指标对比

Table 5 Comparison of evaluation indexes of ablation experiments

图像组别	序号	基准算法	①	②	③	<i>P</i>	<i>R</i>	$\epsilon_{RMSE}$
II	1	√				0.439 3	0.178 2	35.938 3
	2	√	√			0.802 4	0.553 9	18.548 2
	3	√		√		0.529 4	0.264 8	23.483 5
	4	√	√	√		0.903 8	0.706 0	15.374 2
	5	√		√	√	0.713 7	0.243 2	8.930 1
	6	√	√	√	√	0.982 3	0.706 0	2.998 4
IV	1	√				0.362 8	0.149 3	57.283 6
	2	√	√			0.864 1	0.412 9	22.363 8
	3	√		√		0.472 9	0.279 4	39.284 7
	4	√	√	√		0.897 6	0.665 4	14.639 4
	5	√		√	√	0.585 1	0.265 3	11.293 4
	6	√	√	√	√	0.990 1	0.665 4	1.283 9

佳性能, 所以需与 DVMPR 组合使用, 因此本节不进行 3σ-SVR 的独立实验。

结合指标对比发现, 在 Dual-AGDD 机制下准确率与召回率均有大幅提升, 如 2、4 组。这是因为 Dual-AGDD 机制相较于 CSS 算法的角点提取精度更高, 避免了过多冗余特征点的产生, 且基于响应测度值的主方向角选择生成相似性更高的主方向向量, 提升了描述符正确匹配的概率。经 DVMPR 框架调整图像旋转角、尺度一致后, 最大限度消除了因旋转与尺度差异造成的特征描述子匹配困难, 准确率与召回率均提升约 10%, 如 3 组相较于 1 组,

4组相较于2组。在DVMPR框架校正后采用3s-SVR进行误匹配剔除, 均方根误差有效降低。

在3种改进策略的逐步累加中, 双策略组合的4、5组RMSE略优于单策略改进的2、3组, 但劣于整体改进的6组结果。Dual-AGDD机制对配准准确率与召回率性能提升最为显著, 3 $\sigma$ -SVR与DVMPR框架的组合最有利于配准误差的减小。

### 3.3 本文方案与其他方案的对比

本节将近年来实现较好的基于图像特征的3种配准算法SIFT-LPM<sup>[39,23]</sup>、PIIFD<sup>[19,26]</sup>、CAO-C2F<sup>[27]</sup>和基于深度学习的3种配准算法SuperPoint-SuperGlue<sup>[28-29,40]</sup>、SuperPoint-LightGlue<sup>[28,31]</sup>、ReDFeat<sup>[33]</sup>算法与ARSR算法进行对比实验。并设置不同旋转角度与尺度差异进行算法旋转、尺度不变性测试, 设置暗光、雾霾、加噪环境进行算法环境鲁棒性测试。

其中, 3种深度学习算法均采用本文自建数据集进行训练和测试, 数据集按照各类别7:3的比例划分训练集和测试集。值得注意的是, 在SuperPoint特征提取模型训练时需要开启同形异义自适应技术进行数据增强, 对训练集内的每张图像进行多种随机单应变换, 生成多张变换图像进行特征提取, 将提取结果累加得到原始图像的真值标签, 运用真值标签训练模型。

#### 3.3.1 配准性能对比

采用6种对比算法与ARSR算法分别对数据集内的5组(共126对)不同类型的图像进行配准测试, 评价指标计算结果如表6所示。与其他6种方法相比, 无论异源图像对之间存在何种差异ARSR算法都能体现近似的精度且均方根定位误差始终最小, 如图11所示(表6与图11中“—”表示配准误差过大导致配准失败)。P-R曲线如图12所示, 在不同图像测试中, ARSR算法的P-R曲线最接近右上角顶点, 表明ARSR算法在匹配成功率和角点利用率上明显优于其他6种对比算法。

对比算法中, SIFT-LPM算法仅对第I组无明显旋转尺度差异的图像产生了较多匹配连线, 但其中仍包含约36%误匹配连线。对其余具有尺度、旋转差异的图像组无法完成图像配准融合; PIIFD算法对5组图像配准的平均准确率为0.64, 因包含过多偏移大的误匹配连线, 导致后续图像拼接融合时无法实现配准对齐; CAO-C2F算法的准确率是对比算法中最高的, 其在图像结构清晰、背景干净时具

表6 7种算法的配准评价指标对比

Table 6 Comparison of evaluation indexes of 7 methods

算法	指标	评价指标值					
		I	II	III	IV	V	
特征点配准算法	SIFT-LPM	<i>P</i>	0.633 4	0.172 3	0.98 6	0.672 8	0.967 2
		<i>R</i>	0.023 8	0.009 4	0.182 5	0.121 5	0.265 8
		$\epsilon_{RMSE}$	16.283 3	365.271	5.326 1	13.472 3	6.273 5
	PIIFD	<i>P</i>	0.500 0	0.463 7	0.882 7	0.722 3	0.672 9
		<i>R</i>	0.138 2	0.155 8	0.192 5	0.159 6	0.317 3
		$\epsilon_{RMSE}$	13.374 9	27.283 9	9.283 7	8.273 7	23.384 7
	CAO-C2F	<i>P</i>	0.744 4	0.972 9	—	0.987 1	1
		<i>R</i>	0.378 2	0.472 8	—	0.309 2	0.053 7
		$\epsilon_{RMSE}$	6.273 9	19.228 3	568.093	5.273 6	3.384 8
深度学习配准算法	SP-SG	<i>P</i>	0.792 3	0.845 7	0.853 7	0.863 5	0.837 2
		<i>R</i>	0.320 3	0.238 3	0.247 3	0.219 2	0.352 6
		$\epsilon_{RMSE}$	5.273 8	17.273 8	15.273 9	19.023 4	16.280 0
	SP-LG	<i>P</i>	0.782 5	0.912 6	0.892 9	0.825 6	0.876 1
		<i>R</i>	0.293 4	0.241 5	0.201 7	0.234 8	0.3705
		$\epsilon_{RMSE}$	7.938 2	12.232 4	17.839 2	9.293 6	17.283 9
	ReDFeat	<i>P</i>	0.841 3	0.726 8	0.939 2	0.874 2	0.952 6
		<i>R</i>	0.370 5	0.178 1	0.533 0	0.137 2	0.254 6
		$\epsilon_{RMSE}$	6.745 3	21.228 3	5.217 2	21.328 6	4.283 6
本文算法	<i>P</i>	0.986 0	0.982 3	0.970 3	0.990 1	1	
	<i>R</i>	0.690 5	0.706 0	0.652 2	0.665 4	0.611 1	
	$\epsilon_{RMSE}$	2.882 1	2.998 4	3.938 0	1.283 9	2.193 4	

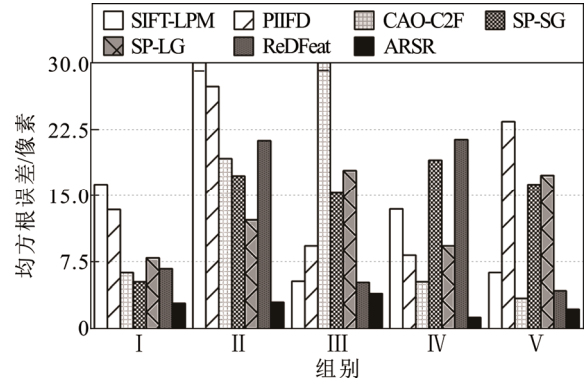


图11 对比算法与本文算法的均方根误差统计

Fig.11 RMSE statistics comparing four methods and ARSR




图12 对比算法与本文算法的准确率-召回率曲线

Fig.12 Precision-recall comparing four methods and ARSR

备较好的旋转不变性，但仍无法配准贴合套管复杂边缘，且旋转角计算鲁棒性差，导致配准成功率降低，如第III组图像；SuperPoint-SuperGlue 算法采用带有伪标签的立体图形影像对 MagicPoint 检测器进行有监督训练，随后为真实影像生成兴趣点标签，将 MagicPoint 进行迁移学习。但红外和可见光图像在光谱和图像纹理信息上存在较高差异，导致特征点相似度低、匹配困难，且对具有旋转、尺度差异的图像配准性能较差，如第IV、V组图像；SuperPoint-LightGlue 算法的平均准确率略高于 SuperPoint-SuperGlue 算法，但总体配准性能相近，同样受限于红外、可见光图像的光谱差异；ReDFeat 算法是基于多模态图像匹配任务提出的，经自建数据集训练后，能够实现旋转、尺度差异较小的电力设备红外-可见光图像对配准，但其旋转不变性能较差，在对具有明显旋转差异的第II、IV组图像进行配对时， $e_{RMSE}$  误差达到 21.2 和 21.3 像素；相比之下，ARSR 准确率最高， $e_{RMSE}$  最小，优于其他对比算法。6 种对比算法中，CAO-C2F 准确率最高，但仍无法实现变压器套管边缘的精确匹配，ARSR 能够更好地实现电力设备复杂边缘的配准贴合。

### 3.3.2 旋转、尺度不变性对比

采用第 I 组中无明显旋转、尺度差异的变压器 3 套管图像对 6 种对比算法与 ARSR 算法进行旋转、尺度不变性测试。固定红外图像，将可见光图像分别旋转  $0^\circ\sim 360^\circ$ ，测试间隔为  $10^\circ$ ；尺度缩放选择  $50\%\sim 150\%$ ，测试间隔为  $10\%$ ，图 13、图 14 分别为不同角度差异和不同尺度差异下各算法的正确匹配对数统计。

在各种不同的旋转差异和尺度差异下，ARSR 算法的正确匹配数均远多于其他对比方法。且随着旋转角度或尺度的持续变化，ARSR 算法的正确匹配数量几乎保持稳定，主要体现在旋转差异雷达图中曲线呈现类正圆形，在尺度差异折线图中未出现较大峰谷差。可见 ARSR 能够应对不同旋转、尺度差异，在 7 种算法中具有最佳的稳定性和旋转、尺度不变性。

### 3.3.3 图像匹配可视化对比

由于 CAO-C2F 算法在本文数据集的测试评价指标优于其他 5 种对比算法，采用 CAO-C2F 算法和本文算法进行拼接对比。对本文数据集中的 5 组图像分别采用 2 种算法进行配准、拼接，图 15 展示了其中最具分析价值的 3 组结果。可以看出，本文

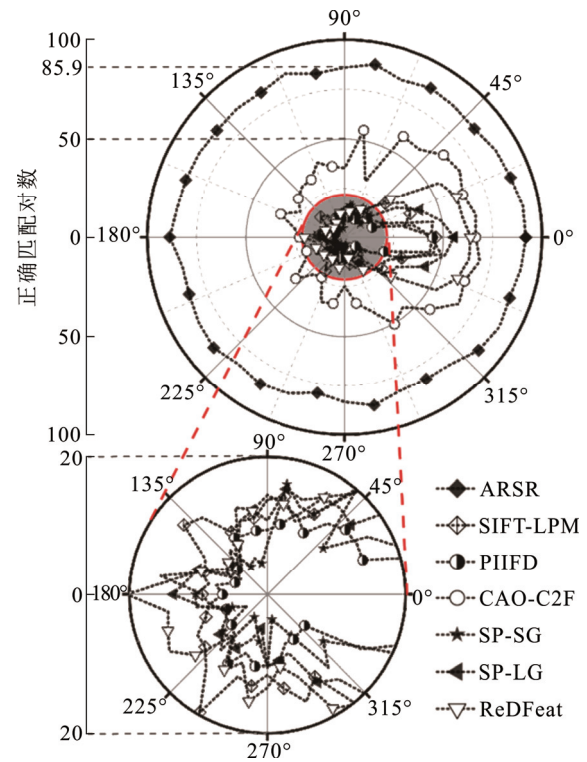


图 13 对比算法与本文算法在不同旋转差异时正确匹配数量对比示意图(下方为匹配数 0~20 对的局部放大图)

Fig.13 Comparison of correct matching quantities between comparison methods and ARSR with different rotations (the following is a magnified view of the matching pairs from 0 to 20)




图 14 对比算法与本文算法在不同尺度差异时正确匹配数量对比示意图

Fig.14 Comparison of correct matching quantities between comparison methods and ARSR with different scales

ARSR 算法的正确匹配连线显著多于 CAO-C2F 方法，能够更精准地对齐电力设备结构细节，如图中“框”所示。每个子图的上一行为源红外和可见光图像配准结果图，下一行为经 CAO-C2F 和本文 ARSR 方法对齐拼接的红外-可见光图像。




图 15 CAO-C2F 算法(左)与 ARSR 算法(右)配准精度可视化对比

Fig.15 Visual comparison of the registration accuracy of the CAO-C2F (left) and the ARSR algorithm (right)

在第 II 组图像中, 相比 CAO-C2F 算法, 本文算法能够更理想地实现变压器套管锯齿边缘的准确匹配。CAO-C2F 算法在第 III 组图像对出现配准失败的情况, V 组中出现召回率值极小的情况。分析具体原因: 在第 III 组图像中由于 CAO-C2F 算法在统计 CAO 方向偏差时, 没有进行相应旋转角度检验, 旋转角判定失误导致图像旋转至几乎颠倒, 如图 16 所示。后续又采用连线一致性理论进行误匹配剔除, 将不论正确还是异常的大部分匹配连线都予以删除, 造成配准失败。而 ARSR 算法采用双视图匹配参数重训框架对视野旋转角与透视尺度进行互相监督的制约校正, 有效避免了旋转角计算误差过大的情况。

在第 V 组图像中, 虽粗看 CAO-C2F 算法的图像融合效果较好, 但由于匹配特征点过少, 实际上绕组边缘、连接件等细节处均没有对齐。分析其主要原因是采用 CSS 算法提取的角点随机性过高, 产生较多误提取的冗余角点, 导致描述子双边匹配难度激增, 造成大量误匹配。且 CAO-C2F 算法采用的随机抽样一致性剔除算法(RANSAC)是随机性极强的算法, 在正确样本不足 50% 时, 受初始匹配情况中的误匹配率的影响大, 最终导致剔除正确样本过多, 剩余的配准点过少。而 ARSR 算法采用 Dual-AGDD 特征点筛选与定向机制, 自适应设置门限进行角点筛选, 保证了角点集的质量, 提高了正确匹配率。且采用  $3\sigma$ -SVR 剔除方案, 运用  $3\sigma$  原则先行剔除明显误匹配, 提高 SVR 的剔除精度, 能够准确保留较多的正确匹配连线, 有效提高了图像细节处的对齐精度。




图 16 III 组图像 CAO-C2F 算法配准失败原因

Fig.16 Reasons for failure of CAO-C2F for the III group

### 3.3.4 环境鲁棒性对比

电力设备巡检过程中会遇到不同的天气条件, 如阴雨天、大雾、阴霾等, 将影响巡检机器人采集的红外-可见光成像质量, 加剧电力设备异源图像配准任务的难度。为测试 ARSR 算法应对极端天气的能力, 基于正常天气下采集的 30 对变压器单支套管图像, 通过加噪、模糊、对比度调整等方法生成暗光环境、雾霾环境与噪声环境下的虚拟测试集, 如图 17 所示。

采用 ARSR 算法与 6 种对比算法分别对不同环境下的异源图像进行配准测试, 配准评价指标计算结果如表 7 所示。

对比不同环境下的配准情况, 7 种算法在暗光、雾霾、噪声环境下的准确率、召回率和均方根定位误差较正常光照时均有所下降, 其中, SIFT-LPM 算法未能实现配准。ARSR 算法在不同环境下的各项配准评价指标皆高于其他对比算法, 呈现出更好的环境鲁棒性。




图 17 不同环境图像

Fig.17 Images in different environments

表 7 不同环境下 7 种算法的配准评价指标对比

Table 7 Comparison of registration evaluation indicators for 7 algorithms in different environments

算法	指标	评价指标值				
		正常	暗光	雾霾	噪声	
特征点配准算法	SIFT-L	$P$	0.199 6	0.094 6	—	0.144 6
		$R$	0.124 4	0.006 8	—	0.017 2
	PM	$e_{RMSE}$	264.738	393.284	573.384	349.283
		$P$	0.574 6	0.389 3	0.129 3	0.203 9
	PIIFD	$R$	0.187 5	0.094 8	0.103 8	0.127 4
		$e_{RMSE}$	27.283 9	30.948 3	33.374 8	20.94 2
CAO-C2F	$P$	0.946 4	0.738 4	0.645 7	0.773 2	
	$R$	0.446 5	0.402 8	0.202 3	0.346 2	
	$e_{RMSE}$	12.246 8	13.374 8	17.230 4	13.394 8	
深度学习配准算法	SP-SG	$P$	0.875 7	0.836 4	0.403 7	0.702 3
		$R$	0.293 0	0.263 7	0.127 3	0.217 4
	$e_{RMSE}$	9.253 1	12.470 4	19.273 9	18.283 6	
	SP-LG	$P$	0.892 4	0.824 5	0.522 5	0.730 2
		$R$	0.221 7	0.203 4	0.139 2	0.210 5
	$e_{RMSE}$	12.627 2	14.278 3	17.293 1	13.958 6	
ReD-Feat	$P$	0.792 3	0.702 5	0.498 3	0.727 8	
	$R$	0.213 8	0.192 3	0.150 6	0.253 7	
$e_{RMSE}$	13.288 2	16.263 2	21.394 6	15.032 8		
本文算法	ARSR	$P$	0.982 3	0.922 6	0.832 4	0.860 1
		$R$	0.706 0	0.634 3	0.602 9	0.649 4
	$e_{RMSE}$	2.998 4	4.937 5	6.938 0	4.372 8	

对比算法中,在暗光环境下 PIIFD 算法的准确率、召回率下降较多,说明该算法的光照变化适应性较差,相比之下, SuperPoint-SuperGlue 和 SuperPoint-LightGlue 算法在暗光条件下各指标波动较小,在不同光照环境下的普适性较强。在噪声环境中, CAO-C2F 和 SuperPoint-LightGlue 算法的配准准确率高、定位误差较小,表现出较优的抗干

扰性能。但上述暗光环境和噪声环境下,对比算法的指标表现仍差于 ARSR 算法。

在不同环境的对比测试中,各算法在雾霾环境下性能下降最多,均方根定位误差明显增大,主要原因是雾霾天气造成可见光和红外图像能见度降低、纹理信息模糊,造成特征点提取困难,对基于轮廓特征提取的配准算法影响更大。对此, ARSR 算法提出的 Dual-AGDD 机制,不仅利用图像边缘特性,还结合了边缘像素点与周围像素的相关信息进行特征点提取与定向。所以相比其他算法, ARSR 对模糊的边缘仍能较精准地进行特征点提取与定向,能够在雾霾天气时保持较好的配准性能。如遇重度雾霾天气或相机异常导致图片成像过分模糊,可能引起 ARSR 算法对部分特征点定位出现偏差,产生误匹配。但随着图像采集设备的持续更新与图像质量判别算法的运用,巡检采回成像过度模糊的情况十分少见,且经测试 ARSR 算法能够在常见雾霾环境下呈现出较强的鲁棒性,其性能能够支撑普遍的智能巡检任务。

## 4 结论

针对电力设备复杂结构红外-可见光图像难以准确匹配问题,本文提出一种面向电力设备异源图像配准的自适应监督重训算法,主要结论如下:

1) 经实验验证,本文提出的 ARSR 算法能有效对齐电力设备精细化结构边缘,能够有效提高电力设备精细化结构的红外-可见光图像配准精度,准确结合温度信息与纹理信息于一体,可进一步用于电力设备故障诊断与故障定位任务中。

2) Dual-AGDD 特征点筛选与定向机制可基于图像边缘像素的 AGDD 响应特性进行分析,实现自适应设置全局阈值,降低了电力设备精细结构处的角点误提取率与漏提取率。此外,利用边缘形状特性、边缘像素和周围像素之间的相关信息提供相似性高的主方向,规避异源图像光谱、分辨率差异带来主方向选择差异过大的问题。

3) DVMPR 双视图匹配参数重训框架基于斜率一致性理论提高了图像旋转角度与尺度差异的计算准确率,从本质上降低了图像旋转、尺度差异对配准成功率的影响。

4) 在不同复杂程度,旋转、尺度差异的异源图像集下,本文算法的准确率、召回率、均方根误差等评估指标均优于 CAO-C2F 等近年来提出的先


进配准算法, 平均配准精确率 98.57%、平均均方根误差 2.65, 对每组图像匹配的正确点对数量最多, 特征描述符区分性最强。

5) ARSR 算法对环境干扰具有更强的鲁棒性。在对暗光、雾霾、噪声等环境干扰下, 其均方根误差相较于最优方法分别降低了 7.53、10.30、9.02 像素。

## 参考文献 References

- [1] 杨挺, 耿毅男, 郭经红, 等. 人工智能在新型电力系统智能传感、通信与数据处理领域应用[J]. 高电压技术, 2024, 50(1): 19-29. YANG Ting, GENG Yinan, GUO Jinghong, et al. Applications of artificial intelligence in sensing, communication, and data processing in the new power system[J]. High Voltage Engineering, 2024, 50(1): 19-29.
- [2] 江秀臣, 臧奕茗, 刘亚东, 等. 电力设备 ChatGPT 类模式与关键技术[J]. 高电压技术, 2023, 49(10): 4033-4045. JIANG Xiuchen, ZANG Yiming, LIU Yadong, et al. Power equipment ChatGPT-type model and key technologies[J]. High Voltage Engineering, 2023, 49(10): 4033-4045.
- [3] 刘云鹏, 刘一瑾, 律方成, 等. 数字孪生技术在输变电设备中的应用前景与关键技术[J]. 高电压技术, 2022, 48(5): 1621-1633. LIU Yunpeng, LIU Yijin, LÜ Fangcheng, et al. Application prospect and key technology of digital twin in power transmission and transformation equipment[J]. High Voltage Engineering, 2022, 48(5): 1621-1633.
- [4] 胡晨龙, 裴少通, 刘云鹏, 等. 基于 LEE-YOLOv7 的输电线路边缘端实时缺陷检测方法[J]. 高电压技术, 2024, 50(11): 5047-5057. HU Chenlong, PEI Shaotong, LIU Yunpeng, et al. Real-time edge end defect detection method for transmission line based on LEE-YOLOv7[J]. High Voltage Engineering, 2024, 50(11): 5047-5057.
- [5] 赵振兵, 冯烁, 席悦, 等. 大模型时代: 电力视觉技术新起点[J]. 高电压技术, 2024, 50(5): 1813-1825. ZHAO Zhenbing, FENG Shuo, XI Yue, et al. The era of large models: a new starting point for electric power vision technology[J]. High Voltage Engineering, 2024, 50(5): 1813-1825.
- [6] 刘云鹏, 李泳霖, 裴少通, 等. 基于紫外光辐射照度特征的污秽瓷绝缘子绝缘状态评估方法[J]. 高电压技术, 2023, 49(4): 1622-1631. LIU Yunpeng, LI Yonglin, PEI Shaotong, et al. Evaluation of the insulation state of contaminated porcelain insulators based on characteristics of ultraviolet irradiance[J]. High Voltage Engineering, 2023, 49(4): 1622-1631.
- [7] 刘传洋, 吴一全. 基于红外图像的电力设备识别及发热故障诊断方法研究进展[J/OL]. 中国电机工程学报, 2024: 1-27. <http://kns.cnki.net/kcms/detail/11.2107.TM.20240226.0957.002.html>. LIU Chuanyang, WU Yiquan. Research progress of power equipment identification and thermal fault diagnosis based on infrared images[J/OL]. Proceedings of the CSEE, 2024: 1-27. <http://kns.cnki.net/kcms/detail/11.2107.TM.20240226.0957.002.html>.
- [8] 沈小军, 于忻乐, 王远东, 等. 变电站电力设备红外热像测温数据三维可视化方案[J]. 高电压技术, 2021, 47(2): 387-395. SHEN Xiaojun, YU Xinle, WANG Yuandong, et al. Three-dimensional visualization scheme of infrared thermal temperature measurement data for substaition electric power equipment[J]. High Voltage Engineering, 2021, 47(2): 387-395.
- [9] LI H, WU X J. DenseFuse: a fusion approach to infrared and visible images[J]. IEEE Transactions on Image Processing, 2019, 28(5): 2614-2623.
- [10] ZHAO Z B, ZHAO L L, QI Y C, et al. Infrared and visible image registration based on hypercolumns[C]/Second CCF Chinese Conference on Computer Vision. Singapore, Singapore: Springer, 2017: 529-539.
- [11] 盛戈峰, 钱勇, 罗林根, 等. 面向新型电力系统的电力设备运行维护关键技术及其应用展望[J]. 高电压技术, 2021, 47(9): 3072-3084. SHENG Gehao, QIAN Yong, LUO Lingen, et al. Key technologies and application prospects for operation and maintenance of power equipment in new type power system[J]. High Voltage Engineering, 2021, 47(9): 3072-3084.
- [12] 肖祥武, 王丰, 王晓辉, 等. 面向工业互联网的智慧电厂仿生体系架构及信息物理系统[J]. 电工技术学报, 2020, 35(23): 4898-4911. XIAO Xiangwu, WANG Feng, WANG Xiaohui, et al. Bionic structure and cyber-physical system for intelligent power plant oriented to the industrial internet[J]. Transactions of China Electrotechnical Society, 2020, 35(23): 4898-4911.
- [13] 李鹏, 习伟, 蔡田田, 等. 数字电网的理念、架构与关键技术[J]. 中国电机工程学报, 2022, 42(14): 5002-5016. LI Peng, XI Wei, CAI Tiantian, et al. Concept, architecture and key technologies of digital power grids[J]. Proceedings of the CSEE, 2022, 42(14): 5002-5016.
- [14] 刘云鹏, 刘一瑾, 刘刚, 等. 电力变压器智能运维的数字孪生体构想[J]. 中国电机工程学报, 2023, 43(22): 8636-8651. LIU Yunpeng, LIU Yijin, LIU Gang, et al. Digital twin conception of intelligent operation and maintenance of power transformer[J]. Proceedings of the CSEE, 2023, 43(22): 8636-8651.
- [15] 刘亚东, 严英杰, 严波, 等. 电力装备内部状态反演重构研究框架与应用展望[J]. 高电压技术, 2022, 48(8): 2883-2896. LIU Yadong, YAN Yingjie, YAN Bo, et al. Framework and application prospect of internal state inversion and reconstruction of power equipment[J]. High Voltage Engineering, 2022, 48(8): 2883-2896.
- [16] 姜骞, 刘亚东, 严英杰, 等. 电力设备多源异构数据空间合成与立体展示方法[J]. 高电压技术, 2022, 48(1): 66-74. JIANG Qian, LIU Yadong, YAN Yingjie, et al. Spatial synthesis and stereoscopic display method for multi-source heterogeneous data of power equipment[J]. High Voltage Engineering, 2022, 48(1): 66-74.
- [17] 徐奇伟, 黄宏, 张雪锋, 等. 基于改进区域全卷积网络的高压引线接头红外图像特征分析的在线故障诊断方法[J]. 电工技术学报, 2021, 36(7): 1380-1388. XU Qiwei, HUANG Hong, ZHANG Xuefeng, et al. Online fault diagnosis method for infrared image feature analysis of high-voltage lead connectors based on improved R-FCN[J]. Transactions of China Electrotechnical Society, 2021, 36(7): 1380-1388.
- [18] 刘云鹏, 董王英, 许自强, 等. 基于卷积神经网络的变压器套管故障红外图像识别方法[J]. 高压电器, 2021, 57(10): 134-140. LIU Yunpeng, DONG Wangying, XU Ziqiang, et al. Infrared image recognition method on fault of transformer bushing based on convolutional neural networks[J]. High Voltage Apparatus, 2021, 57(10): 134-140.
- [19] 杜庆磊. 多尺度可见光与红外图像配准融合研究[D]. 武汉: 武汉大学, 2019. DU Qinglei. Research on multi-scale visible light and infrared image registration and fusion[D]. Wuhan, China: Wuhan University, 2019.
- [20] GAO J, CAI X F. Image matching method based on multi-scale corner detection[C]/2017 13th International Conference on Computational Intelligence and Security (CIS). Hong Kong, China: IEEE, 2017: 125-129.

- [21] FAN Z C, LIU Z Y, QU Z, et al. ASP-SIFT: using analog signal processing architecture to accelerate keypoint detection of SIFT algorithm[J]. IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 2020, 28(1): 198-211.
- [22] HAO H, YAN S H, REN J, et al. The research on image retrieval based on PCA-SIFT[C]//2022 IEEE 10th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). Chongqing, China: IEEE, 2022: 1139-1142.
- [23] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [24] TANG C Q, TIAN G Y, CHEN X T, et al. Infrared and visible images registration with adaptable local-global feature integration for rail inspection[J]. Infrared Physics & Technology, 2017, 87: 31-39.
- [25] CHEN J, TIAN J, LEE N, et al. A partial intensity invariant feature descriptor for multimodal retinal image registration[J]. IEEE Transactions on Biomedical Engineering, 2010, 57(7): 1707-1718.
- [26] WANG Z B, FENG X G, LI D, et al. A robust multi-source image matching method for power equipment based on improved PI-IFD[C]//2023 8th International Conference on Signal and Image Processing (ICSIP). Wuxi, China: IEEE, 2023: 254-258.
- [27] JIANG Q, LIU Y D, YAN Y J, et al. A contour angle orientation for power equipment infrared and visible image registration[J]. IEEE Transactions on Power Delivery, 2021, 36(4): 2559-2569.
- [28] DETONE D, MALISIEWICZ T, RABINOVICH A. SuperPoint: self-supervised interest point detection and description[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Salt Lake City, UT, USA: IEEE, 2018: 337-33712.
- [29] SARLIN P E, DETONE D, MALISIEWICZ T, et al. SuperGlue: learning feature matching with graph neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 4937-4946.
- [30] SUN J M, SHEN Z H, WANG Y A, et al. LoFTR: detector-free local feature matching with transformers[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA: IEEE, 2021: 8918-8927.
- [31] LINDENBERGER P, SARLIN P E, POLLEFEYS M. LightGlue: local feature matching at light speed[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France: IEEE, 2023: 17581-17592.
- [32] XU S B, CHEN S P, XU R T, et al. Local feature matching using deep learning: a survey[J]. Information Fusion, 2024, 107: 102344.
- [33] DENG Y X, MA J Y. ReDFeat: recoupling detection and description for multimodal feature learning[J]. IEEE Transactions on Image Processing, 2023, 32: 591-602.
- [34] 赵洪山, 张则言. 基于文化狼群算法的电力设备红外和可见光图像配准[J]. 光学学报, 2020, 40(16): 1610003.  
ZHAO Hongshan, ZHANG Zeyan. Power equipment infrared and visible images registration based on cultural wolf pack algorithm[J]. Acta Optica Sinica, 2020, 40(16): 1610003.
- [35] 刘海桥, 刘萌, 龚子超, 等. 基于深度学习的图像匹配方法综述[J]. 航空学报, 2024, 45(3): 028796.
- LIU Haiqiao, LIU Meng, GONG Zichao, et al. A review of image matching methods based on deep learning[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(3): 028796.
- [36] 姜 骞, 刘亚东, 方 健, 等. 基于轮廓特征的电力设备红外和可见光图像配准方法[J]. 仪器仪表学报, 2020, 41(11): 252-260.  
JIANG Qian, LIU Yadong, FANG Jian, et al. Registration method for power equipment infrared and visible images based on contour feature[J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 252-260.
- [37] ZHANG W C, SUN C M, GAO Y S. Image intensity variation information for interest point detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(8): 9883-9894.
- [38] 沈 英, 黄春红, 黄 峰, 等. 红外与可见光图像融合技术的研究进展[J]. 红外与激光工程, 2021, 50(9): 20200467.  
SHEN Ying, HUANG Chunhong, HUANG Feng, et al. Research progress of infrared and visible image fusion technology[J]. Infrared and Laser Engineering, 2021, 50(9): 20200467.
- [39] MA J Y, ZHAO J, JIANG J J, et al. Locality preserving matching[J]. International Journal of Computer Vision, 2019, 127(5): 512-531.
- [40] LIU Y Q, XIA C, ZHU X B, et al. Two-stage copy-move forgery detection with self deep matching and proposal SuperGlue[J]. IEEE Transactions on Image Processing, 2022, 31: 541-555.



FAN Lanshan

范澜珊

2000—, 女, 硕士

主要研究方向为电气设备在线监测与故障诊断

E-mail: 494220021@qq.com

LIU Yunpeng  
Ph.D., Professor

刘云鹏

1976—, 男, 博士, 教授, 博导

主要从事电气设备在线监测与故障诊断方面的研究工作

E-mail: liuyunpeng@ncepu.edu.cn

ZHAO Tao  
Ph.D.

Corresponding author

赵 涛(通信作者)

1982—, 男, 博士, 讲师

主要从事电气设备状态检测与故障诊断方面的研究工作

E-mail: T.Zhao@ncepu.edu.cn

收稿日期 2024-04-23 修回日期 2024-12-14 编辑 卫李静