光电技术及应用

DOI：10.16818/j.issn1001－5868.2021.04.028

基于 CNN-WF 的高灵敏紫外成像仪中的图像配准与融合

侯思祖，刘雅婷*，陈天威

（华北电力大学 电气与电子工程学院，河北 保定 071003）

摘　要： 针对现有紫外成像仪中紫外光与可见光图像配准实时性差，精度不高等问题，提出一种基于卷积神经网络（Convolutional Neural Networks，CNN）与小波融合（Wavelet Fusion，WF）的紫外光与可见光图像配准融合方法，并将其应用于高灵敏紫外成像仪中。首先，结合刚体变换和卷积神经网络对采集到的图像数据进行参数模型预训练，通过自主挖掘图像特征寻找到最优空间变换参数，实现紫外光图像与可见光图像的精确配准；其次，利用二维小波分解与重构算法实现紫外光与可见光图像的融合。实验结果表明，所提方法的紫外光图像与可见光图像配准速度快，叠加精度高，且具有良好的稳定性。

关键词： 卷积神经网络；紫外成像仪；图像配准；小波融合

中图分类号： TP751　**文章编号：** 1001－5868(2021)04－0596－07

Image Registration and Fusion of High Sensitive Ultraviolet Imager Based on CNN-WF

HOU Sizu，LIU Yating，CHEN Tianwei

（School of Electrical and Electronic Engin.，North China Electric Power University，Baoding 071003，CHN）

Abstract： Aiming at the problems of poor real-time performance and low accuracy of the existing UV imagers in UV and visible image registration，a method of UV and visible image registration fusion based on convolutional neural network（CNN）and wavelet fusion（WF）is proposed and applied to high sensitive UV imager. Firstly，the parameter model of the collected image data is pre-trained by combining the rigid body transformation and convolution neural network，and the optimal spatial transformation parameters are found by self-mining image features to achieve accurate registration of UV image and visible image. Secondly，two-dimensional wavelet decomposition and reconstruction algorithm is used to realize the fusion of UV and visible images. Experimental results show that the proposed method has fast registration speed，high overlay accuracy and good stability.

Key words： convolutional neural network；ultraviolet imager；image registration；wavelet fusion

0　引言

随着国家电网规模的逐渐扩大，电力系统负荷不断增加，对电力系统运行稳定可靠性的要求也越来越高。然而输变电设备在安装、环境、机械等多种因素的综合作用下绝缘性能会逐渐降低，产生电晕放电现象，这种缺陷或故障将严重威胁电网运行的安全，所以需要研究一种能够及时发现绝缘缺陷和预防故障发生的检测手段。高灵敏度紫外成像仪利用全日盲探测技术，采用紫外光和可见光双通道图像融合的方式，可以在电力设备故障形成早期有效探测和定位微弱的电晕信号。然而受到各种捕获条件的影响，多传感器图像不能直接进行融合，必须进

收稿日期：2021－04－15.

基金项目：国家重点研发计划项目(2018YFF01011900).

* **通信作者：**刘雅婷

行预处理和配准。在这种情况下，融合之前需要应用多模态图像配准技术对这些图像进行空间坐标的精确对准和定位，配准精度越高，融合后图像结果包含的信息就越准确、越可靠[1-2]。

图像配准是图像融合的基础，而图像配准的关键在于找到最优空间变换模型。目前，针对图像配准的方法有很多[3]，文献[4]使用基于灰度的图像配准方法进行配准，但是由于紫外光图像灰度特征和可见光图像灰度特征有较大差异，配准速度较慢且效果不佳；文献[5]使用基于特征的配准方法，选择有反光特性的氧化材料制作配准靶，手动选择 3 对特征点，计算得到仿射变换矩阵，但是紫外图像纹理信息极少，很难提取到精确的特征点，所以会导致参数模型计算不准确；文献[6]提出的基于显著性和 ORB 的红外和可见光图像配准算法，能够有效解决红外和可见光图像配准过程中受灰度差异影响以及特征点难以正确匹配的问题，但是该配准方法相对耗时较长，配准效率较低。

针对紫外光与可见光图像配准速度慢、特征点不明显等问题，本文提出一种基于卷积神经网络(Convolutional Neural Networks，CNN)与小波融合(Wavelet Fusion，WF)的紫外光图像与可见光图像配准融合方法。通过 CNN 模型自动提取图像特征，训练模型得到两幅图像的几何对应关系，根据对应关系计算得到空间变换参数以完成图像配准，最后使用小波融合算法对配准图像进行融合。实验结果表明，该方法能够快速、准确地实现紫外光与可见光图像的配准与融合。

1　相关理论

1.1　卷积神经网络

卷积神经网络(CNN)是一类包含卷积计算的深度神经网络，目前在图像分类[7-8]、目标检测[9-11]、语义分割[12-13]等领域应用广泛。CNN 模型可以通过特有的网络平移不变性、卷积运算和池化操作实现自适应学习样本特征，所以使用 CNN 模型进行紫外光与可见光图像配准的优势在于 CNN 可以通过多层网络结构自主挖掘图像特征。浅层的卷积层可以提取丰富的局部特征，深层的卷积层将局部特征结合，提取图像隐式特征，解决了人工提取特征局限性的问题，而且 CNN 卷积层网络稀疏连接，卷积核权值共享的特点也提高了网络结构的泛化能力，适应性更强。

卷积神经网络结构如图 1，一般包括输入层、卷积层、池化层、全连接层以及输出层[14]。卷积层和池化层交叉出现，并连接到一个或多个全连接层。

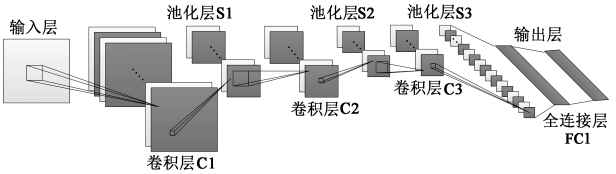

图 1　卷积神经网络模型

卷积层(Convolution Layer，Conv)包含若干个随机产生的卷积核，每个卷积核分别与输入图像进行卷积操作提取图像局部特征，得到多个特征图谱，不同特征图谱上的神经元通过卷积核连接。前一层特征图谱和一个卷积核进行卷积运算，然后经过一个激活函数处理得到输出特征图谱，其中，卷积核的权重值可以根据目标函数自动学习更新且权值共享，计算过程如式(1)所示：

$$y=f\left(\sum_{i\in G_m} x_i^{p-1}\otimes w_{im}^{p}+b_m^{p}\right) \tag{1}$$

其中，f 是激励函数，G_m 是前一层特征集合，x_i^{p-1} 是第 $p-1$ 层第 i 个特征图谱的输出，w_{im}^{p} 是卷积核，b_m^{p} 是偏置项，$\otimes$是卷积操作。

常见的激活函数有饱和非线性激活函数，如 sigmoid 函数、tanh 函数等，以及不饱和非线性激活函数，如 ReLu 函数、Leaky ReLU 函数等[15-16]。其中 tanh 函数与 sigmoid 函数两端饱和，容易导致神经网络梯度消失，而且权重更新缓慢；而 ReLu 函数的神经元只需要进行加、乘和比较的操作，能够减少计算量，而且不会产生梯度消失的问题。与此同时，采用 ReLu 函数能加快网络收敛，提高计算效率。ReLu 函数如式(2)所示：

$$\mathrm{ReLu}(x)=\begin{cases}0, & x<0\\ x, & x\geqslant 0\end{cases} \tag{2}$$

池化层(Pooling Layer，PL)又称为下采样层，在提取图像特征的同时可以降低图像维度，减少模型参数，且保持局部不变性，这不仅能够有效提高运算速度且在一定程度上抑制了过拟合现象的产生。目前常见的池化层种类有：最大池化层、平均池化层、重叠池化层等。平均池化是计算出区域内神经元总和再取平均值；重叠池化的方法需要满足池化窗口大于步长，使得相邻的池化窗口间有重叠区域；最大池化操作如图 2 所示，池化窗口对滑动窗口中的最大值进行子采样，输出维度减少到原来的一半，

既可以减少时间复杂度又能够防止过拟合现象的产生。

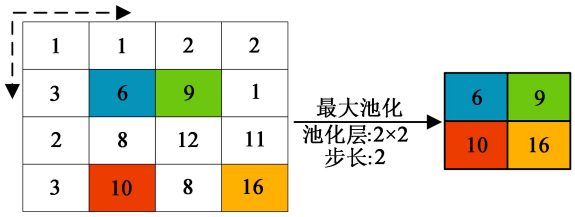

图 2 最大池化操作

全连接层(Fully Connected Layers,FC)将在卷积层或池化层学习到的所有局部特征整合为整体特征,线性变换映射到样本的标签空间,而后传递给输出层。

为了使训练模型得到更准确的参数值,引入损失函数,回归问题常用的损失函数为均方误差RMSE,公式如下:

$$RMSE=\sqrt{E[(x-\hat{x})^2+(y-\hat{y})^2]} \tag{3}$$

式中,$E[\cdot]$是统计平均运算符,(x,y)表示数据实际值,$(\hat{x},\hat{y})$为神经网络预测值。

1.2 空间变换模型

传统的图像配准方法主要分为两类:基于特征的配准方法和基于互信息的配准方法。基于特征的配准方法需要进行关键点检测,然后进行特征点匹配,而基于灰度的配准需要定义相似性度量函数,将配准问题转换为迭代优化问题,但无论何种配准方法,目的都在于寻找最佳几何空间变换模型以及最优空间变换矩阵。图像配准过程用数学公式表达如下:

$$I_r(x_1,y_1)=F[I_f(T(x_2,y_2))] \tag{4}$$

式中,$I_r(x_1,y_1)$为参考图像的像素值,$T(x_2,y_2)$为参考图像与待配准图像所需空间变换模型,$I_f(T(x_2,y_2))$为变换后的参考图像的像素值坐标,F 表示待配准图像像素映射到参考图像坐标上所需插值操作。

目前应用较多的空间变换模型有:刚体变换模型、仿射变换模型、投影变换模型和非线性变换模型,如图 3 所示。刚体变换模型对浮动图像进行平移和旋转操作,大小和形状不会发生改变;仿射变换模型由刚体模型演化而来,是指对图像进行平移和缩放处理;投影变换会对图像大小和形状进行变换。因为紫外成像仪已经过机械配准,所以只需要进行简单的平移操作,采用刚体变换模型即可。

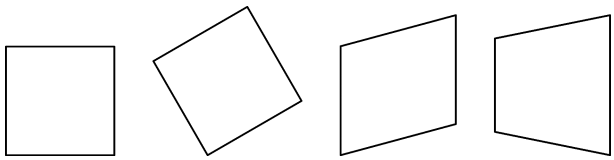

(a) 原图像 (b) 刚体变换 (c) 仿射变换 (d) 投影变换

图 3 常用的图像变换模型

刚体变换模型的数学模型定义如式(5)~(6):

$$\begin{bmatrix}x'\\y'\end{bmatrix}=\begin{bmatrix}\cos\theta & -\sin\theta\\ \sin\theta & \cos\theta\end{bmatrix}\begin{bmatrix}x\\y\end{bmatrix}+\begin{bmatrix}t_x\\t_y\end{bmatrix} \tag{5}$$

$$\boldsymbol{R}=\begin{bmatrix}\cos\theta & -\sin\theta\\ \sin\theta & \cos\theta\end{bmatrix},\boldsymbol{t}=\begin{bmatrix}t_x\\t_y\end{bmatrix} \tag{6}$$

其中,(x,y)是原始图像灰度值坐标,(x',y')是经过刚体变换后的图像灰度值坐标。θ 为旋转角度,t_x,t_y 分别表示图像在横纵坐标上的平移量,$\boldsymbol{R}$ 为旋转矩阵。

1.3 小波分解与重构

小波变换在时域和频域都具有良好的局部特性[17],它可以将一个信号分解为多个具有不同空间分辨率的子信号且不丢失原始信息,其中低频分量包含图像的近似信息,高频分量表示图像的边缘细节等信息。此外,小波分解还可以找到正交基,实现无冗余的信号分解[18-19]。

二维小波分解的具体过程为:先对图像 C_j 每一行一维数据进行一维小波行分解,然后再对分解形成的高、低频信息中的每一列做列分解,最终可以得到 4 个子带:C_{j+1,k_1,k_2},D^1_{j+1,k_1,k_2},D^2_{j+1,k_1,k_2},D^3_{j+1,k_1,k_2}。计算公式如下:

$$C_{j+1,k_1,k_2}=\sqrt{2}\sum_{m,n}H^*_{m-2k_1}H^*_{n-2k_2}C_j \tag{7}$$

$$D^1_{j+1,k_1,k_2}=\sqrt{2}\sum_{m,n}H^*_{m-2k_1}G^*_{n-2k_2}C_j \tag{8}$$

$$D^2_{j+1,k_1,k_2}=\sqrt{2}\sum_{m,n}H^*_{m-2k_1}G^*_{n-2k_2}C_j \tag{9}$$

$$D^3_{j+1,k_1,k_2}=\sqrt{2}\sum_{m,n}H^*_{m-2k_1}G^*_{n-2k_2}C_j \tag{10}$$

其中,C_{j+1,k_1,k_2} 为低频子带包含图像近似信息,由行低通、列低通得到;D^1_{j+1,k_1,k_2} 由行低通、列高通得到,代表垂直方向上的高频成分,即水平边缘细节信息,也可以记为 D^{LH}_{j+1};D^2_{j+1,k_1,k_2} 由行高通、列低通得到,即 D^{HL}_{j+1},代表垂直边缘细节信息;D^3_{j+1,k_1,k_2} 由行高通、列高通得到,包含对角方向上的高频成分,即对角边缘细节信息,记为 D^{HH}_{j+1}。其中,G^* 是高通滤波器 G 的反转共轭,H^* 是低通滤波器 H 的共轭反转[20]。

2　实验步骤

实验装置为双通道日盲型高灵敏度紫外成像仪和十字低压汞灯，紫外成像仪装置结构如图 4 所示。该装置中紫外光相机使用深截止“日盲”紫外滤波片，紫外通道仅接收 240～280 nm 波段的紫外光，所以紫外图像必须与可见光通道捕获的图像进行配准与融合才能更加全面、准确地定位放电点位置。



(a)　主视图　　(b)　内置模块

图 4　高灵敏紫外成像仪

2.1　图像配准融合流程图

基于 CNN-WF 的紫外与可见光图像配准融合流程如图 5 所示。

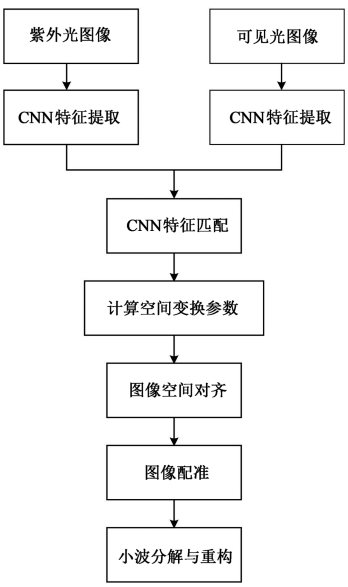

图 5　配准融合流程图

首先，对紫外光图像（待配准图像）和可见光图像（参考图像）进行 CNN 特征提取；然后，根据 CNN 特征进行匹配，计算出空间变换矩阵，利用刚体变换模型进行空间对齐，实现紫外光图像与可见光图像的配准；最后根据二维小波变换实现紫外与可见光图像融合。

2.2　卷积神经网络模型结构参数

表 1 列出了 CNN 模型的结构参数，由表可知输入图像为 216×193 像素的 3 通道图像，卷积层含有 32 个 5×5×3 的卷积核，步长为 1，池化窗口为 3×3，步长为 2，经过前 8 层卷积池化层交替处理后输出 32 个 53×47 像素的特征图，最后经过全连接层处理后输出一个 9 行 1 列的变换矩阵。

表 1　卷积神经网络结构参数

层名称	结构参数	输出特征图大小
输入层	216×193×3	216×193×3
卷积层 1	32@5×5×3，步幅=[1　1]	216×193×32
归一化层 1	32 个通道	216×193×32
最大池化层 1	3×3，步幅=[2　2]	107×96×32
激活函数层 1	ReLU 激活函数	107×96×32
卷积层 2	32@5×5×3，步幅=[2　2]	107×96×32
归一化层 2	32 个通道	107×96×32
最大池化层 2	3×3，步幅=[2　2]	53×47×32
激活函数层 2	ReLU 激活函数	53×47×32
全连接层 1	1×1×288	1×1×288
激活函数层 3	ReLU 激活函数	1×1×288
全连接层 2	1×1×288	1×1×9
输出层	1×1×9	—

2.3　小波融合

假设相同距离且同时拍摄的一组紫外与可见光图像分别为 I_1，I_2，最终融合后的图像为 C_{j+1}，该融合算法可分为以下几个步骤：

(1)对源图像 I_1，I_2 分别进行二维 Haar 小波分解，由式(7)～(10)可以得到 1 个低频子带系数和 3 个高频子带系数。

(2)对分解得到的低频子带系数，采用局部能量的加权融合方法。

(3)对于高频子带系数，采用绝对值取大融合方法。

(4)对经过融合规则得到的低频融合系数和高频融合系数使用重构算法，得到重构图像 C_{j+1}。

对于低频分量需要分别计算两幅图像低频带内局部区域 Q 的能量：

$$E(I_1,p)=\sum_{q\in Q}\omega(q)C_J^2(I_1,q) \tag{11}$$

$$\sum_{q\in Q}\omega(q)=1 \tag{12}$$

其中，$\omega(q)$为权值，Q 为 q 的邻域，当 q 点越靠近 p 点，权值就会越大[21]。

为了达到更好的融合效果，还需要定义匹配函数 $M(p)$和阈值 T_{H}：

$$M(p)=\frac{2}{E(I_1,p)+E(I_2,p)}\sum_{q\in Q}\omega(q)C_J(I_1,q)\cdot C_J(I_2,q) \tag{13}$$

其中，$0\leqslant M(p)\leqslant 1$，$M(p)$的值越接近于 1，表示相关程度越高。$0.5\leqslant T_{\mathrm{H}}\leqslant 1$。

当 $M(p)<T_H$ 时，

$$G(F,P)=\begin{cases}C_J(I_1,p), E(I_1,p)\geqslant E(I_2,p)\\ C_J(I_2,p), E(I_1,p)<E(I_2,p)\end{cases} \tag{14}$$

若 $M(p)\geqslant T_H$，那么

$$G(F,p)=\begin{cases}\text{if}\quad E(I_1,p)\geqslant E(I_2,p),\\ W_{\max}C_J(I_1,p), W_{\min}C_J(I_2,p)\\ \text{else if } E(I_2,p)<E(I_1,p),\\ W_{\max}C_J(I_2,p), W_{\min}C_J(I_1,p)\end{cases} \tag{15}$$

$$W_{\min}=0.5-0.5\left(\frac{1-M(p)}{1-T_H}\right) \tag{16}$$

$$W_{\max}=1-W_{\min} \tag{17}$$

对于高频分量，采用绝对值取大的融合方法：

$$D_F=\max(D_1,D_2) \tag{18}$$

式中，D_1，D_2 分别表示图像 I_1，I_2 的高频分量；D_F 为融合图像 F 的高频分量，最后通过式(19)重构低频分量与高频分量，得到融合图像 C_{j+1}：

$$C_{j+1}=\sum_{m,n}H_{k_1-2m}H_{k_2-2n}C_j+\sum_{m,n}H_{k_1-2m}G_{k_2-2n}D_{j+1}^{\mathrm{LH}}+\sum_{m,n}G_{k_1-2m}H_{k_2-2n}D_{j+1}^{\mathrm{HL}}+\sum_{m,n}G_{k_1-2m}G_{k_2-2n}D_{j+1}^{\mathrm{HH}} \tag{19}$$

3 实验结果分析

3.1 CNN 均方根误差和损失函数图像分析

图 6 为 CNN 的实验结果，从图 6 可以看出，随着迭代次数的增加，训练样本的均方根误差(RMSE)曲线和损失函数值(Loss)曲线逐步递减，最终趋于平稳，趋近于 0 时，网络开始收敛。

从图 6 还可以看出，验证样本的误差曲线和损失函数曲线也呈现下降趋势，并趋于平稳，说明所提方法没有出现过拟合现象。

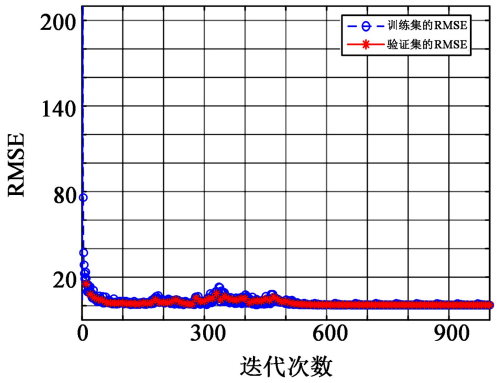

(a) 均方根误差变化趋势

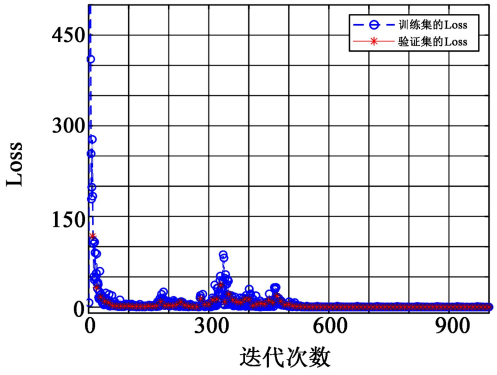

(b) 损失值变化趋势

图 6 CNN 模型实验结果

3.2 主观评价

图 7～9 分别表示 6，10，14 m 距离下采用基于 CNN-WF 的图像融合算法对十字低压汞灯紫外图像与可见光图像的配准融合结果。可以明显地观察到紫外光图像与可见光图像的空间对齐效果很好，这表明基于 CNN-WF 的图像配准融合算法已满足主观视觉要求。

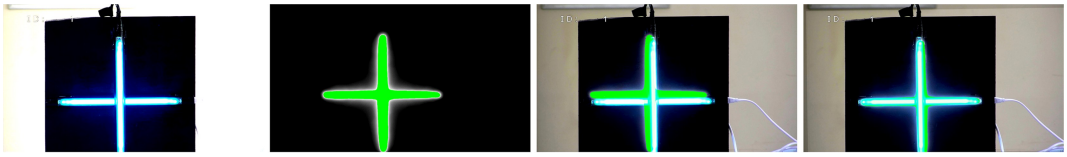

(a) 可见光图像 (b) 紫外光图像 (c) 未配准图像 (d) 配准后图像

图 7 6 m 距离下基于 CNN-WF 的图像配准融合算法仿真结果



(a) 可见光图像 (b) 紫外光图像 (c) 未配准图像 (d) 配准后图像

图 8 10 m 距离下基于 CNN-WF 的图像配准融合算法仿真结果



（a） 可见光图像　（b） 紫外光图像　（c） 未配准图像　（d） 配准后图像

图 9　14 m 距离下基于 CNN-WF 的图像配准融合算法仿真结果

3.3　客观评价指标

紫外成像仪中紫外光图像与可见光图像的配准精度指标为叠加精度，单位为 mrad，它表示紫外成像仪中两通道对同一紫外光源成像的最大叠加角度偏差[22]。测试原理如图 10 所示，紫外积分球光源发出的紫外光、可见光的混合光通过分划板射入平行光管，通过平行光管的出射光被紫外成像仪接收，成像后分别求取紫外图像中心点与可见光图像质心，由式(20)计算得到最大叠加角度偏差：

$$\mathrm{d}\theta=\sqrt{\left(\frac{\mathrm{d}x}{W}\times\theta_{\mathrm{W}}\right)^{2}+\left(\frac{\mathrm{d}y}{H}\times\theta_{\mathrm{H}}\right)^{2}} \tag{20}$$

式中，$\mathrm{d}x$ 和 $\mathrm{d}y$ 分别为紫外光图像与可见光图像质心坐标差值，W 是横向像素数，H 是纵向像素数，θ_{W} 是水平方向视场角度，θ_{H} 表示竖直方向视场角度。

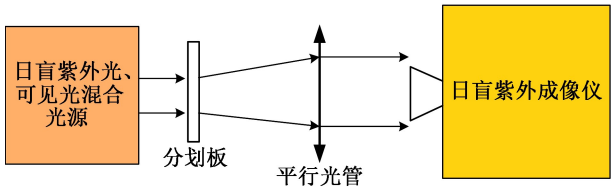

图 10　紫外可见光叠加精确度测试系统示意图

根据式(20)，可以计算出 6～14 m 距离下紫外与可见光叠加精度，如表 2 所示，由表可知基于卷积神经网络的配准叠加精度均小于项目所提指标 0.5 mrad，完全可以满足工程需求。

表 2　不同距离下紫外光与可见光配准叠加精度

距离/m	配准前				配准后			
	紫外图像质心坐标	可见图像质心坐标	叠加角度偏差 $\mathrm{d}\theta$/(°)	叠加精度 $\mathrm{d}\omega$/mrad	紫外图像质心坐标	可见图像质心坐标	叠加角度偏差 $\mathrm{d}\theta$/(°)	叠加精度 $\mathrm{d}\omega$/mrad
6	(860.75,718.25)	(827.75,664.25)	0.237 6	4.147 4	(862.25,713.75)	(862.25,715.25)	0.003 7	0.065 4
8	(1 213.30,785.80)	(1 178.8,727.30)	0.251 4	4.387 2	(1 214.80,784.30)	(1 213.30,785.80)	0.009 6	0.168 4
10	(1 003.30,695.80)	(976.25,634.25)	0.221 9	3.872 9	(1 004.80,699.80)	(1 006.30,695.80)	0.013 4	0.233 5
12	(1 022.80,669.30)	(992.75,605.75)	0.238 3	4.159 8	(1 019.80,668.80)	(1 022.80,670.30)	0.018 2	0.317 1
14	(1 094.8,668.80)	(1 067.80,614.80)	0.209 3	3.653 7	(1 091.80,667.30)	(1 093.30,662.80)	0.014 3	0.250 2

4　结论

紫外成像仪中紫外光图像与可见光图像配准的准确率受到特征点分布、特征点提取及传感器本身特性等多种因素影响，为了提高图像配准精度及融合速度，本文提出一种基于 CNN-WF 的紫外与可见光图像配准融合方法，将采集到的图像数据输入卷积神经网络模型，实现紫外与可见光图像在几何空间位置上的自主对齐。实验结果表明，该方法易于训练且快速收敛，配准过程不需要复杂的迭代运算，满足实时性要求，且其配准叠加精度远优于工程要求 0.5 mrad，具有良好的可靠性与适用性。

参考文献：

[1] 顾　燕，吕　扬，杨　锋，等. 紫外成像仪的紫外可见光图像叠加精确度测试系统[J]. 红外技术，2019，41(8)：695-698.
Gu Yan，Lv Yang，Yang Feng，et al. Testing system for UV imager superposition accuracy[J]. Infrared Technology，2019，41(8)：695-698.

[2] 黎振宇. 输变电设备外绝缘放电紫外成像检测方法研究[D]. 重庆：重庆大学，2016.
Li Zhenyu. Research on the ultraviolet imaging detection method of external insulation discharge on power transmission and transformation equipment[D]. Chongqing：Chongqing University，2016.

[3] 陈锦龙，陈俊全，张　旭，等. 一种放电检测中紫外和可见光图像配准方法[J]. 测绘科学，2019，44(8)：70-74.
Chen Jinlong，Chen Junquan，Zhang Xu，et al. An image registration method for power equipment discharge detection using ultraviolet and visible light image[J]. Science of Surveying and Mapping，2019，44(8)：70-74.

[4] 徐　鹏，陆启宇，马　奥，等. 基于红外、超声和紫外技术的局部放电联合检测方法研究[J]. 红外，2016，37(9)：42-48.
Xu Peng，Lu Qiyu，Ma Ao，et al. Synthetic partical discharge measurement system based on infrared，ultrasonic and ultraviolet[J]. Infrared，2016，37(9)：42-48.

[5] 岳桂金. 紫外/可见光融合的信息感知系统研究[D]. 南京：南京理工大学，2014.

Yue Guijin. Research on information perception system based on ultraviolet/visible fusion[D]. Nanjing: Nanjing University of Science and Technol., 2014.

[6] 江泽涛，刘小艳，王 琦. 基于显著性和ORB的红外和可见光图像配准算法[J]. 激光与红外，2019，49(2)：251-256.
Jiang Zetao, Liu Xiaoyan, Wang Qi. Visible and infrared image registration algorithm based on saliency and ORB[J]. Laser & Infrared, 2019, 49(2): 251-256.

[7] Sampedro C, Rodriguez V J, Rodriguez R A, el al. Deep learning-based system for automatic recognition and diagnosis of electrical insulator strings[J]. IEEE Access, 2019, 7: 101283-101308.

[8] Harikrishnan J, Sudarsan A, Sadashiv A, et al. Vision-face recognition attendance monitoring system for surveillance using deep learning technology and computer vision[C]// Proc. of the 2019 Inter. Conf. on Vision Towards Emerging Trends in Communication and Networking, Piscataway: IEEE 2019: 1-5.

[9] 林克正，白婧轩，李昊天，等. 深度学习下融合不同模型的小样本表情识别[J]. 计算机科学与探索，2020，14(3)：482-492.
Lin Kezheng, Bai Jingxuan, Li Haotian, et al. Facial expression recognition with small samples fused with different models under deep learning[J]. J. of Frontiers of Computer Science and Technol., 2020, 14(3): 482-492.

[10] 音 松，陈雪云，贝学宇. 改进Mask RCNN算法及其在行人实例分割中的应用[J]. 计算机工程，2021，47(6)：271-276，283.
Yin Song, Chen Xueyun, Bei Xueyu. Improved Mask RCNN algorithm and its application in pedestrian instance segmentation [J]. Computer Engin., 2021, 47(6): 271-276, 283.

[11] 包 俊，刘宏哲. 融合可变形卷积网络的鱼眼图像目标检测[J]. 计算机工程，2021，47(4)：248-255.
Bao Jun, Liu Hongzhe. Object detection in fisheye images combining deformable convolutional networks[J]. Computer Engin., 2021, 47(4): 248-255.

[12] 肖 琳，陈博理，黄 鑫，等. 基于标签语义注意力的多标签文本分类[J]. 软件学报，2020，31(4)：1079-1089.
Xiao Lin, Chen Boli, Huang Xin, et al. Multi-label text classification method based on label semantic information[J]. J. of Software, 2020, 31(4): 1079-1089.

[13] Jaf S, Calder C. Deep learning for natural language parsing [J]. IEEE Access, 2019, 7: 131363-131373.

[14] 熊 皓，刘嘉勇，王俊峰. 基于神经网络和自回归模型的网络流量预测[JB/OL]. 计算机应用：1-8[2021-03-26]. http://kns.cnki.net/kcms/detail/51.1307.TP.20210120.1345.002.html.
Xiong Hao, Liu Jiayong, Wang Junfeng. Network traffic prediction based on neural network and autoregressive model [JB/OL]. J. of Computer Applications: 1-8[2021-03-26]. http://kns.cnki.net/kcms/detail/51.1307.TP.20210120.1345.002.html.

[15] 许 浩，王旭东，吴 楠. 基于卷积神经网络的室内可见光指纹定位方法[JB/OL]. 激光与光电子学进展：1-14[2021-03-26]. http://kns.cnki.net/kcms/detail/31.1690.TN.20210120.1033.010.html.
Xu Hao, Wang Xudong, Wu Nan. Indoor visible ling fingerprint positioning scheme based on convolution neural network[JB/OL]. Laser & Optoelectronics Progress: 1-14 [2021-03-26]. http://kns.cnki.net/kcms/detail/31.1690.TN.20210120.1033.010.html.

[16] 刘 洋，杨 晨. 基于深度学习理论的红外和可见光图像配准[J]. 激光杂志，2020，41(11)：81-85.
Liu Yang, Yang Chen. Infrared and visible image registration based on deep learning theory[J]. Laser J., 2020, 41(11): 81-85.

[17] 王晓柱，钮赛赛，张 凯，等. 基于小波变换与特征提取的红外弱小目标图像融合[J]. 西北工业大学学报，2020，38(4)：723-732.
Wang Xiaozhu, Niu Saisai, Zhang Kai, et al. Image fusion of infrared weak-small target based on wavelet transform and feature extraction [J]. J. of NorthWestern Polytechnical University, 2020, 38(4): 723-732.

[18] Huang W, Jing Z L. Evaluation of focus measures in multi-focus image fusion[J]. Pattern Recognition Lett., 2007, 28 (4): 493-500.

[19] Ellmauthaler A, Pagliari C L, Da Silva E A B. Multiscale image fusion using the undecimated wavelet transform with spectral factorization and nonorthogonal filter banks[J]. IEEE Trans. on Image Processing, 2013, 22(3):1005-1017.

[20] 朱世松，瞿佩云. 基于小波变换和引导滤波的多聚焦图像融合[J]. 测控技术，2020，39(9)：103-107.
Zhu Shisong, Qu Peiyun. Multi-focus image fusion based on wavelet transform and guided filtering[J]. Measurement & Control Technol., 2020, 39(9): 103-107.

[21] 郭 雷，程 塘，赵天云. 基于小波变换和邻域特征的多聚焦图像融合算法[J]. 西北工业大学学报，2011，29(3)：454-459.
Guo Lei, Cheng Gong, Zhao Tianyun. A New and effective multi-focus image fusion algorithm based on wavelet transforms and neighborhood features [J]. J. of Northwestern Polytechnical University, 2011, 29(3): 454-459.

[22] 侯思祖，陈 宇，刘雅婷. 基于互信息的紫外成像仪中图像配准研究[J]. 半导体光电，2020，41(4)：598-604.
Hou Sizu, Chen Yu, Liu Yating. Image registration in ultraviolet imager based on mutual information [J]. Semiconductor Optoelectronics, 2020, 41(4): 598-604.

作者简介：

侯思祖(1962—)，男，教授，博导，研究方向包括配网故障定位诊断、电力通信网综合管理和检测。