

基于改进 ResNet-50 的图像特征提取网络

汤博宇¹, 焦良葆^{1,2}, 徐逸¹, 魏小玉¹, 孟琳¹

(1. 南京工程学院 人工智能产业技术研究院, 南京 211167;

2. 江苏省智能感知技术与装备工程研究中心, 南京 211167)

摘要: 为了提高图像的特征质量, 保证最后提取到的特征高度精炼, 提出了一种新的方法; 该方法首先将低分辨率图像经过小波变换分解成高频分量和低频分量, 并结合插值法进行插值, 最后通过小波逆变换得到高分辨率图像来为后续的特征提取提供高质量的照片输入; 接着, 选取 ResNet-50 网络作为基础网络, 将 ECA 模块与 ResNet 残差结构结合形成一个全新的 ECA-ResNet50 模块, ECA 模块具有的通道级的注意力机制, 可以让整个网络更加专注于提取显著特征; 经实验测试, 该方法对于图像特征提取的质量有着明显的提升, 均方误差下降可达 6.65; 结果表明, 该方法可行有效, 具有良好的工程应用前景。

关键词: 特征提取; 超分辨率; 小波变换; 残差网络; 通道注意力

Image Feature Extraction Network Based on Improved ResNet-50

TANG Boyu¹, JIAO Liangbao^{1,2}, XU Yi¹, WEI Xiaoyu¹, MENG Lin¹

(1. AI Industrial Technology Research Institute, Nanjing Institute of Technology, Nanjing 211167, China;

2. Jiangsu Intelligent Perception Technology and Equipment Engineering Research Center, Nanjing 211167, China)

Abstract: In order to improve the quality of image features, and ensure that final extracted features are highly refined, a new image feature extraction method is proposed; Firstly, the low resolution image is decomposed into high frequency component and low frequency component by wavelet transform, which is interpolated by interpolation method; then, the high resolution image is obtained by inverse wavelet transform to provide high quality image input for subsequent feature extraction; Finally, ResNet-50 network is selected as the basic network, and an Efficient Channel Attention (ECA) module is combined with a ResNet residual structure to form a new ECA-Resnet50 module; the ECA module has a channel-level attention mechanism, which can make the whole network more focused on extracting salient features; Experimental results show that this method can significantly improve the quality of image feature extraction, and the mean square error can be reduced up to 6.65; The results show that the method is feasible and effective, and has a good engineering application prospect.

Keywords: feature extraction; super resolution; wavelet transform; residual network; channel attention

0 引言

图像的特征反应出了一幅图像的独特之处, 其中包含着明显的结构性信息, 是与其他图像产生区别的重要属性^[1]。图像的特征一般分为人造特征和自然特征, 人造特征主要是人们为了对图像进行更好的分析研究所赋予图像的一些外部特征(平均梯度、熵等), 自然特征是图像自带的内部特征(轮廓、纹理等)^[2]。图像特征提取是对一幅图像进行深入解读的必要手段, 如今, 图像特征提取在各大领域中被广泛地运用, 如目标检测、图像检索、运动结构等领域。

传统的特征检测算法^[3]有 Harris 角点检测算法、SIFT 算法、SURF 算法、ORB 算法等。Harris^[4]角点检测法利

用图像的灰度参数来对图像进行描述, 缺点是缺少尺度不变性, 而尺度不变性在图像特征的提取中是不可或缺的一项重要特性; SIFT^[5]算法最早于 1999 年被提出, 得益于它的仿射不变性等各种优良特性, 在图像特征提取领域被广泛使用, 相较于 Harris 角点检测算法, 图像配准的准确度大大地提升, 缺点是运算速度较慢; SURF^[6]算法是对 SIFT 算法的进一步改进, 优化了计算的方式, 使得算法的整体运算速度得到了提升, 弥补了 SIFT 算法的缺点; ORB^[7]算法的最大优点是速度快, 是一种快速的对特征点进行描述以及提取的检测算法, 其由两部分组成, 分别是 FAST 算法和 BRIEF 算法, FAST 算法负责对特征点的提取, BRIEF 算法负责对特征点的描述。这些传统算法主要

收稿日期: 2022-10-17; 修回日期: 2022-11-17。

基金项目: 国家自然科学基金青年基金资助项目(61903183)。

作者简介: 汤博宇(1999-), 男, 江苏南通人, 硕士研究生, 主要从事图像处理、深度学习方向的研究。

焦良葆(1972-), 男, 安徽安庆人, 博士, 教授, 主要从事图像信息处理、嵌入式图像处理方向的研究。

引用格式: 汤博宇, 焦良葆, 徐逸, 等. 基于改进 ResNet-50 的图像特征提取网络[J]. 计算机测量与控制, 2023, 31(6): 162-167.

利用一些数学原理, 比如梯度特征、局部灰度值等, 通过这些参数能够将物体本身的特征信息表达出来^[8]。但是, 传统的特征检测算法在面对弱纹理图像或者是亮度较暗的图像时, 其特征提取的效果就会显得捉襟见肘, 主要原因是这些图片的特征不够明显, 如轮廓模糊, 灰度值没有区分度等, 都是导致传统算法特征提取效果不理想的原因^[9]。针对这些问题, Huang^[10]等人提出了利用 FAST 算法对 Shi-Tomasi 特征点检测算法进行加速, 提高特征点的检测速度; Li^[11]等人提出了一种改进的 KAZE 算法, 改变对特征点的检测方法等步骤来提高算法的及时性; Chang^[12]等人提出了一种基于 FAST-SIFT 组合的局部特征检测算法, 使用 FAST 检测算法进行快速的特征提取, 利用 SIFT 的 128 维描述子进行准确的特征描述, 从而实现快速的局部特征提取; Zhang^[13]等人提出了一种多尺度 Harris 特征点检测算法, 采用分组映射和模版匹配技术, 实现了复杂背景图像的多尺度 Harris 特征点检测, 提高图像特征点的定位识别能力。Zhang^[14]等人提出了以 ResNet50 神经网络为基础, 并在其中融入 SE 模块, 提高了图像特征提取的质量, 可是 SE 模块会在使用的过程中会为了降低模型的复杂度而降低维度, 这就会使特征提取的效率产生了一定的影响^[15]。

为了解决上述已有算法所面临的特征提取效果不理想的问题, 本文提出了一种基于改进 ResNet50 的特征提取方法: 首先, 用改进过的超分辨率法对初始的低分辨率图像进行处理: 图像经过小波变换分解成高频和低频分量, 再对这两种分量分别进行双线性插值和双三次插值, 接着进行小波逆变换, 输出高分辨率图像, 为后面的特征提取环节提供高质量的输入图片。接着, 以 ResNet-50 网络为基础, 将其与轻量级通道注意力模块——ECA (efficient channel attention) 模块相融合, 产生了一个全新的 ECA-ResNet50 模块。相较于其他通道注意力模块, ECA 模块在保证能够高效地获取所有通道的依赖关系的同时, 保持图像的维度不会发生改变, 同时还能对输入特征图的通道特征进行加强。将进行过超分辨率处理的图像输入改进后的网络中, 进行特征的识别以及提取操作, 并生成特征点的坐标, 最后通过对孪生网络生成的单应性矩阵 H 进行实验验证来证明网络的提升效果。

1 图像分辨率处理

图像分辨率的高低对于图像特征的提取有着一定的影响, 低分辨率的图像中细节模糊, 边缘不清楚, 特征不明显, 在后续的特征检测的过程中很容易出现特征点不准确, 误匹配的情况。为了解决这些问题, 需要对图像实行超分辨率处理, 随后再用高分辨率图像进行后续的图像特征提取步骤。

1.1 传统超分辨率方法

在图像重建领域, 传统的图像重建方法会对图像边缘

处的高频部分产生平滑效应, 使得大量的高频信息产生丢失的现象, 这是图像重建领域存在的一个难题, 这将直接导致最终重建图像的模糊不清。而基于小波变换的图像超分辨率重建的方法能够很好地缓解这些问题^[16]。小波变换是把基本小波函数进行位移 τ , 再在不同尺度 α 下, 与待分析信号 $f(t)$ 作内积, 具体如式 (1) 所示。在频域以及时域内的一些局部信息, 通过小波变换能够完好地保留下来, 同时还能够提取图像的细节以及边缘信息, 通过这些操作, 可以在对图像的重建过程中充分利用图像中存在的各种信息。从而, 最终重建的图像中将会保留更多有用的信息, 图像的细节方面也会更加地清晰准确^[17]。传统的小波变换图像超分辨率重建主要有 3 个步骤: 1) 对图像进行分解, 分成低频和高频分量; 2) 对低频分量和高频分量进行重建; 3) 将重建后的分量进行小波逆变换, 最终将会得到经过超分处理后的图像。

$$WT(\alpha, \tau) = \frac{1}{\sqrt{\alpha}} \int_{-\infty}^{+\infty} f(t) * \varphi\left(\frac{t-\tau}{\alpha}\right) d(t) \quad (1)$$

式中, $\alpha > 0$, 称为尺度因子。在图像处理领域, 还可以通过插值的方法来增加图像的像素。假设原图像为 $g(x, y)$, 在经过一番插值运算之后, 输出的图像为 $g'(x', y')$, 其中 x' 为插值后图像的横坐标, y' 为插值后图像的纵坐标, 插值运算实际上就是映射运算, 如式 (2) 所示。常见的插值算法有最近邻点法、双三次插值、双线性插值这 3 种^[18]。1) 最近邻点法是零阶插值, 在一个尺度空间内给定一个待采样点和一个点集, 点集中离待采样点最近的那个点的像素值即为待采样点的像素值, 此方法原理简单, 但插值效果不那么理想; 2) 双三次插值, 在待采样点的邻近选取 16 个点, 对这 16 个点的像素值实行加权平均计算, 最后将计算结果作为待采样点的像素值。此插值算法效果良好, 缺点就是计算复杂, 运行速度慢; 3) 双线性插值, 在最近邻点法的基础上进行了改进, 通过用待采样点四周的 4 个邻点的像素值, 分别在 x 方向和 y 方向上进行线性内插的操作, 从而得到了待采样点经过插值后的新像素值。3 种插值方法在速度和插值效果方面不同, 可根据不同的情况按需选择。

$$g'(x', y') = h(g(x, y)) \quad (2)$$

式中, h 为映射计算。

1.2 超分辨率方法改进

用传统的超分辨率方法对图像进行处理后发现, 虽然图像的清晰度相较于原始图像有所提升, 但是图像仍存在着不同程度的失真以及模糊等问题。因此, 提出了一种新的方法^[19], 具体步骤如下:

1) 通过小波变换的分解, 图像被分成了低频和高频分量。与此同时, 对图像用 Canny 算法进行边缘提取, Canny 算法由于其较低的错误率以及出色的边缘定位能力, 一直被使用至今。

2) 大部分的图像信息储存在低频分量中, 比如图像的

轮廓信息；而一些边缘以及细节部分的信息则存储在高频分量中。为了达到最理想的效果，需要对两种分量采取不同的插值方法：对于低频分量可直接用双三次插值法；高频分量存在有检测出的轮廓不清晰等现象，因此对于高频部分，需要结合 Canny 的边缘信息来得到新高频信息，并针对新高频信息采用双线性插值，可有效保留边缘信息并提高了插值速度。

3) 通过小波逆变换得到高分辨的图像。具体的流程如图 1 所示。

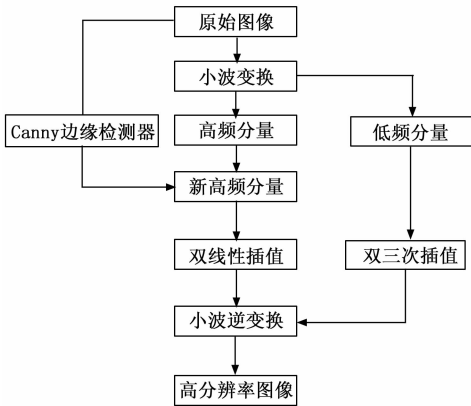


图 1 图像超分辨率处理流程图

2 图像特征提取

2.1 网络模型

孪生网络，是一种结构对称的网络^[20]，如图 2 所示。在网络中存在两个编码器，编码器一般是由 ResNet，VGG 等一些基础的网络构成，input1 和 input2 分别进入两个编码器中，两个编码器会将权值进行共享，所以正常情况下，两个编码器将会采用同一种卷积神经网络，以便更容易实现权值共享。两个输入进入编码器，被神经网络映射后，以一种全新的方式表现出来，最后再通过对 Loss 的计算，检测两个输入的相似度，同时也能够发现输入对之间的差异。

本文将采用改进后的 ResNet 网络作为孪生结构的编码器模块。残差块是 ResNet 残差网络主要组成部分，在此之前，网络结构比较浅，网络层数越多，训练集 loss 便逐渐下降至一个饱和值，当网络层数继续增加时，loss 不会一直趋于平稳，反而逐渐增大。残差块的使用，使得网络的




图 2 孪生网络结构

深度能够在保证正常工作的前提下得到进一步的加深。ResNet 网络结构内的残差单元具体结构如图 3 所示。




图 3 ResNet 网络残差单元

残差单元将跨层传递的信息与经过卷积后的信息相加后输出。假定输入的图像为，经过卷积后输出的图像为，则最终输出的结果是，此输出仍然可执行非线性变换。上述式子中的即为残差，网络因此可以看作是对残差函数的求取，这样的残差函数相较于优化效果会更加明显。

ResNet-50 网络中一共包含 50 层网络，我们可以把 ResNet-50 网络看作是七个部分组成的一种网络，第一部分是对输入网络的信息进行卷积计算，正则化，激活函数以及最大池化的操作，第二、三、四、五部分继续进行卷积运算，且这些部分中包含了残差块^[21]。第六部分进行平均池化的操作，第七部分是全连接层，具体的示意图见图 4。

2.2 改进策略

孪生网络存在着不足之处，假如只是将孪生网络进行简单的学习操作，那么最终会输出“崩溃解”，即无论输入的是什么是，模型为了将 loss 降到最低，最后会输出一个相同的常量，导致整个训练过程没有意义。为防止这种现象的发生，在孪生网络中加入预测器（由两个全连接层构成）以及 stop-gradient 操作，预测器主要用于对左侧编码器生成的特征图进行映射，具体结构如图 5 所示。将一组图像




图 4 ResNet-50 网络组成示意图

对分别输入两个编码器中进行特征的提取, 预测器将左侧编码器生成的特征图进行映射操作, 最后再进行两个图像之间相似度的计算。

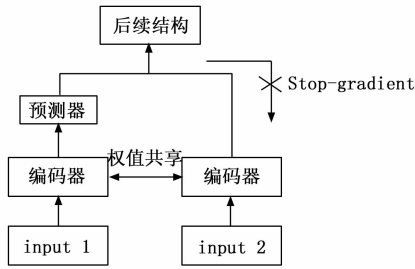


图 5 改进后的孪生网络结构

下文设计的特征提取网络将作为上文所述的孪生结构的编码器模块。ResNet 残差神经网络不同于一般的卷积神经网络, 通过在加入残差学习, 一定程度上缓解了梯度弥散以及精度下降的问题。ResNet-50 网络结构简单, 易操作, 其网络的参数量较其他网络更少, 而其网络性能却更加强大。因此, 在图像处理领域, 经常被用作特征提取的网络, 容易优化的网络结构, 具有很大的研究价值。

把 ECA 模块融合到 ResNet-50 网络中, 以此来实现提高图像特征提取质量的目的。ECA 模块是一种轻量级通道注意力模块, 其通道注意力机制, 使得神经网络在对特征进行提取的时候, 能够对显著特征更加地关注^[22]。同时, 与其他的通道注意力模块相比, ECA 模块不仅能够不降低维度, 还能够保证高效地获取所有通道的依赖关系, 同时还能对输入特征图的通道特征进行加强^[23]。恰当的跨通道交互不仅能够降低模型结构的复杂程度, 同时还能保证模型的高效率和可靠性。其具体的工作原理是, 首先通过全局平均池化对空间信息进行压缩, 然后使用 1×1 的卷积来学习通道注意力信息, 接着将获取到的通道注意力信息与原始的输入特征图相结合, 最后会输出一张具体通道注意力的特征图。其原理如图 6 所示。




图 6 ECA 模块原理图

将 ECA 模块与 ResNet 残差结构相结合, 形成一个全新的 ECA-ResNet50 模块, 具体结构如图 7 所示。

全新的模块由于增加了 ECA 轻量级通道注意力模块, 因此在参数量和计算量上面会有一些量的增加, 将其与原始的 ResNet 残差结构进行对比, 这两种结构的参数量和计算量如表 1 所示。

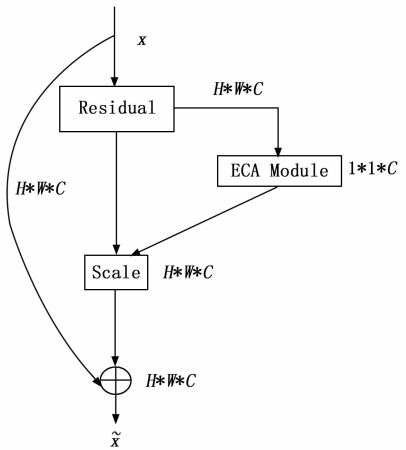


图 7 ECA-ResNet50 模块

经过比较, 我们发现经过改进后的 ECA-ResNet50 结构在参数上仅比原本的 ResNet 残差结构多了 6%, 在计算量上更是仅仅增加了 0.176%, 在增加了少量的计算量的基础上, 为网络带来了通道级的注意力机制, 提高了特征的检测精度, 性价比非常的高。

表 1 参数量与计算量

| 网络结构 | params | FLOPs |
|-----------------|--------------|-----------------|
| ResNet 残差结构 | 25 557 032.0 | 4 111 514 624.0 |
| ECA-ResNet50 结构 | 27 091 876.0 | 4 118 753 608.0 |
| 增加量 | 6% | 0.176% |

3 实验结果与分析

3.1 实验准备

本文中所使用的图像均来自于旷视科技开源数据集。所有实验均在 Windows10 系统下的 Matlab R2020a 和 Py-torch 深度学习框架下训练和测试, 编程语言为 Python3.9, 训练和测试过程使用高性能服务器, 其 CPU 为 Intel (R) Xeon (R) Gold 5118, 显卡为一块英伟达 GTX1080Ti。

3.2 实验结果

小波变换和插值方法的结合, 使得图片的分辨率得到了有效的提升。为了验证分辨率提升后的效果, 将从主观视觉方面以及客观数据方面进行呈现。利用改进后的超分辨率方法对原始的低分辨率图片进行处理, 得到的效果如图 8 所示。可见, 进行超分辨率后的图像比原图更清晰了, 图片的细节方面也得到了有效的处理: 第一组图片中的建筑物轮廓以及窗户的线条变得更加的清晰, 原本迷糊不清的树枝经过超分辨率后变得清晰可见; 第二组图片中建筑物阳台上的线条原本模糊不清, 经过处理后可清楚地辨别出线条的分界线, 细节处得到了加强; 第三组图片中, 原图中卡车后尾的英文字母看不清, 超分辨率后的图中可清晰地看到其英文字母; 第四组图片中, 屋顶的花纹, 门口石狮的脸部细节以及墙上的字的轮廓都更加明显; 第五组

图片中，远处的树以及近处屋顶的砖瓦的细节也得到了加强，更易分辨。由上可知，经过改进后的超分辨率方法在图像的边缘以及细节进行了很好地处理。



图 8 图像超分辨率处理前后对比图

图 8 从主观视觉效果上对改进后的图像预处理进行了初步的说明，为了进一步验证图像预处理的有效性，将会从客观数据方面进行说明，这里以平均梯度为评价指标，公式如式 (3) 所示，平均梯度就是图像的清晰程度，平均梯度的值和图像的清晰度成正比。具体数据如表 2 所示。从表中的数据中可以看出，经过超分辨率后的图像的平均梯度得到了有效的提升，说明图像的清晰度得到了增强，为下一步特征提取的操作提供更加显著的特征细节，保证了最终输出特征的高度精炼。

表 2 图像超分辨率处理前后平均梯度值

| | 原图 | 超分辨率后的图 |
|----|---------|---------|
| 图一 | 0.010 7 | 0.027 4 |
| 图二 | 0.012 3 | 0.031 7 |
| 图三 | 0.014 4 | 0.039 9 |
| 图四 | 0.006 0 | 0.019 8 |

$$G(x, y) = dx_i + dy_i \tag{3}$$

$$dx(i, j) = l(i+1, j) - l(i, j)$$

$$dy(i, j) = l(i, j+1) - l(i, j)$$

经过改进后的特征提取网络是否对特征点的提取质量得到提高，需通过相关实验得出具体的数据来进行验证。为此，设立了一个评价指标为均方误差 (MSE, mean-square error)^[24]，通过该指标的数据来证明改进后的网络的提升效果。

由上文可知，把两幅图输入孪生网络后，可从预测器处输出一个单应性矩阵 H 。将数据集中的图像对用手工标注特征点，在每张图像上标注 6 个特征点，并记录下相应的坐标，如图 9 所示，原图和目标图中特征点的坐标位置相同。将原图中的特征点经过单应性矩阵 H 映射到目标图上，得到映射后的特征点的对应坐标，最后跟目标图中对应位置的特征点进行均方误差的计算。

MSE 是将真实值与预测值的差值的平方然后求和，最后再进行平均，具体形式如式 (4) 所示：

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \tag{4}$$

由于标注的是 6 个特征点，所以上式中的 m 取值为 6，最后计算出的 MSE 值越小，说明经过单应性矩阵 H 映射后的特征点和目标图上的特征点的偏移量越小，特征提取的效果越精确。



图 9 图像超分辨率处理前后对比图

为了验证改进后的特征提取网络的特征提取的效果以及 ECA 模块的使用效果，将会通过消融实验来进行验证，消融实验与控制变量法类似，通过增减不同的模块来验证该模块的有效性，此处将会设置四组实验来进行验证。分别是，原图 + ResNet50 网络，超分后的图片 + ResNet50 网络，原图 + ECA-ResNet50 模块，超分后图片 + ECA-ResNet50 模块。具体的实验数据如表 3 所示。

表 3 消融实验结果

| 处理方法 | 均方误差(MSE) |
|-------------------|-----------|
| 原图+ResNet-50 | 79.92 |
| 超分辨率+ResNet-50 | 78.14 |
| 原图+ECA-ResNet50 | 74.47 |
| 超分辨率+ECA-ResNet50 | 73.27 |

由表 3 可知, 进行超分后的图片+原始的 ResNet-50 网络比原图+原始的 ResNet-50 网络降低了 1.78, 把 ECA 模块融入到 ResNet-50 后, 比之前两个实验有了大幅度的提升, 分别下降了 5.45 和 3.67。而将图片进行超分辨率处理后, 再输送进含有 ECA-ResNet50 模块的网络中, 相较于第一组原始图片+原始 ResNet-50 网络, 整体的均方误差下降了 6.65。ECA 模块为网络带来了通道注意力, 使得网络对关键特征的提取能够更加地高效凝练, 相对于原始的 ResNet-50 网络, 特征提取的效果有了显著的提升。而对图像进行超分辨率的操作, 虽然提升的效果没有 ECA 模块那么显著, 但是也有一定的效果。

4 结束语

本文主要对图像特征质量低的问题进行了研究与改进: 1) 为了获得更清晰的图像, 对图像进行了超分辨率操作, 为后续的特征提取操作提供了一个高质量的图片素材; 2) 加入了轻量级的 ECA 模块, 为整个网络增加了通道注意力机制, 使得网络能够更加关注关键部分的特征, 从而提高最终提取出的特征点的质量以及精度; 3) 为了能够更加客观地量化模块的效果, 本文采用了均方误差这一量化方式, 通过最后的实验数据来直接有效地说明超分辨率操作以及 ECA-ResNet50 模块的有效性。本文所提出的一整套图像特征提取的方法与以前原始的特征提取方法以及一些专家学者所提出的方法相比, 有着较为明显的提升, 但在后续的研究中, 还需要对图像特征检测的速度及精确度进一步的加强, 以达到更加完美的特征检测效果。本文所展示的方法应用范围广泛, 可应用于目标检测、图像识别、图像拼接等方面, 发展前景广阔, 研究价值极大。

参考文献:

- [1] 索子恒. 图像特征检测与特征提取综述 [J]. 产业创新研究, 2022 (4): 33-35.
- [2] 李秀怡. 图像纹理检测与特征提取技术研究综述 [J]. 中国管理信息化, 2017, 20 (23): 175-178.
- [3] 张千, 王庆玮, 张悦, 等. 基于深度学习的文本特征提取研究综述 [J]. 计算机技术与发展, 2019, 29 (12): 61-65.
- [4] 杨济瑞, 张晓燕, 罗攀. 基于图像匹配的特征点检测方法综述 [J]. 电子测试, 2021 (6): 53-54, 92.
- [5] 任晶秋, 武小凯. 改进 SIFT 的图像匹配算法 [J]. 吉林大学学报 (信息科学版), 2022, 40 (4): 672-676.
- [6] 崔建国, 孙长库, 李玉鹏, 等. 基于 SURF 的快速图像匹配改

进算法 [J]. 仪器仪表学报, 2022, 43 (8): 47-53.

- [7] LUO C, YANG W, HUANG P L, et al. Overview of image matching based on ORB algorithm [J]. Journal of Physics: Conference Series, 2019 (3): 29-31.
- [8] 王志瑞, 闫彩良. 图像特征提取方法的综述 [J]. 吉首大学学报自然科学版, 2011 (5): 41-42.
- [9] 邓贤明, 张天才, 刘增灿, 等. 基于目标与环境 FD 模型的多特征检测算法适应性评估 [J]. 光谱学与光谱分析, 2022, 42 (4): 1285-1292.
- [10] 黄远征, 尹春丽, 刘波, 等. 基于改进的快速 Shi-Tomasi 特征点检测算法的图像拼接算法 [J]. 机械设计与研究, 2018, 34 (4): 70-73.
- [11] 李丹, 张蒙, 孙海涛, 等. 一种改进的 KAZE 特征检测算法 [J]. 四川大学学报 (自然科学版), 2015, 52 (3): 523-528.
- [12] 常旭剑, 韩燮, 熊风光. 基于 FAST 检测及 SIFT 描述的特征检测算法 [J]. 计算机工程与设计, 2015, 36 (10): 2749-2753.
- [13] 张玲, 吴发辉. 复杂背景图像的多尺度 Harris 特征点检测算法 [J]. 内蒙古民族大学学报 (自然科学版), 2022, 37 (1): 30-36.
- [14] 张涛. 基于深度学习的图像拼接 [D]. 成都: 四川大学, 2021.
- [15] 倪黎, 邹卫军. 基于 SE 模块改进 Xception 的动物种类识别 [J]. 导航与控制, 2020, 19 (2): 106-111.
- [16] 刘光宇, 曹禹, 冯伟, 等. 基于小波变换的自适应阈值图像去噪技术研究 [J]. 安徽电子信息职业技术学院学报, 2022, 21 (1): 1-5.
- [17] 武钰瑾, 赵凤霞, 辛传福, 等. 图像清晰度的小波变换抗噪评价算法 [J]. 机械设计与制造, 2022, 374 (4): 46-49.
- [18] 魏挺. 基于平滑滤波处理的图像插值通用方法 [J]. 舰船电子工程, 2019, 39 (12): 133-136, 169.
- [19] 詹毅, 李声杰, 李梦. 图像插值的自适应邻域滤波方法 [J]. 计算机工程, 2015 (2): 224-227.
- [20] 邵婕, 王一博, 梁兴, 等. 基于孪生网络的人工震源分布式光纤传感数据噪声压制 [J]. 地球物理学报, 2022, 65 (9): 3599-3609.
- [21] KAUR T, GANDHI T K. Automated diagnosis of COVID-19 from CT scans based on concatenation of Mobilenetv2 and ResNet50 features [C] // International Conference on Computer Vision and Image Processing, Springer, Singapore, 2020: 149-160.
- [22] 孙广慧. 融合 Resnet50 与改进注意力机制的绝缘子状态识别研究 [J]. 电子技术与软件工程, 2021 (16): 247-248.
- [23] 刘强, 张道畅. 结合 SENet 的密集卷积生成对抗网络图像修复方法 [J]. 小型微型计算机系统, 2022, 43 (5): 1056-1060.
- [24] 李源. 基于均方误差的逆合成孔径雷达干扰效果评估 [J]. 信息与电子工程, 2008 (5): 342-345.