

视觉测量系统中基于深度学习的自动对焦方法

郑博文^{1,2,3}, 刘绍锦^{1,2,3*}, 沈铖武^{1,2,3}, 李建荣^{1,2,3}, 韩岩^{1,2,3}, 孙浩洋^{1,2,3}¹中国科学院长春光学精密机械与物理研究所, 吉林 长春 130033;²中国科学院长春光学精密机械与物理研究所相对位姿测量实验室, 吉林 长春 130033;³中国科学院大学, 北京 100049

摘要 针对传统对焦法需要采集较多的离焦图像、对焦耗时长、在视觉测量系统场景应用中存在限制等问题,提出了一种基于深度学习的自动对焦方法。该方法将自动对焦问题转化为图像的离焦距离预测问题,利用 ShuffleNetv2 与多层感知机构建轻量化深度回归网络并对工作场景中采集的目标图像数据集进行训练。通过合理的对焦策略,利用两帧图像即可完成对焦,减少了对焦耗时,同时也可以避免传统对焦法因局部极值点导致对焦误差较大的问题。实验结果表明,该方法的对焦耗时仅为传统对焦法的 15%~24%,对焦稳定性相比传统对焦法提升约为 40%,具有对焦速度快、对焦稳定性高、模型复杂度低等优点,能够很好地应用于视觉测量系统中。

关键词 自动对焦; 深度学习; 成像系统; 图像处理; 视觉测量

中图分类号 TP751.1

文献标志码 A

DOI: 10.3788/LOP240938

Autofocus Method Based on Deep Learning in the Visual Measurement System

Zheng Bowen^{1,2,3}, Liu Shaojin^{1,2,3*}, Shen Chengwu^{1,2,3}, Li Jianrong^{1,2,3},Han Yan^{1,2,3}, Sun Haoyang^{1,2,3}¹Changchun Institute of Optics Fine Mechanics and Physics, Chinese Academy of Sciences,
Changchun 130033, Jilin, China;²Relative Pose Measurement Laboratory, Changchun Institute of Optics Fine Mechanics and Physics,
Chinese Academy of Sciences, Changchun 130033, Jilin, China;³University of Chinese Academy of Sciences, Beijing 100049, China

Abstract Aiming at the problem that the traditional autofocus method needs to collect more defocused images, which greatly increases focusing time and limits its application in visual measurement systems, an autofocus method based on deep learning is proposed. This method transforms the autofocus problem into an image defocus distance prediction problem. First, a lightweight deep regression network is constructed using ShuffleNetv2 and a multilayer perceptron (MLP). The network is subsequently trained on the collected target image dataset in the working scene. Through a reasonable focusing strategy, two frames of images can be used to complete the focusing, which reduces the focusing time, thereby circumventing the problem of large focusing error caused by local extreme points in the traditional autofocus method. The experimental results show that the focusing time of this method is only 15%~24% of the traditional autofocus method, and the focusing stability is improved by about 40% compared with the traditional autofocus method, providing the advantages of fast focusing speed, high focusing stability, and low model complexity, which can be well applied to the visual measurement system.

Key words autofocus; deep learning; imaging system; image processing; visual measurement

1 引言

随着计算机视觉技术的发展,人们对更智能、更快

速的机器视觉设备的需求也越来越多^[1]。视觉测量系统是一种借助光学设备以及图像传感器来获得被测目标的特征图像,并通过计算机处理图像信息,进而实现

收稿日期: 2024-03-21; 修回日期: 2024-04-11; 录用日期: 2024-04-24; 网络首发日期: 2024-05-06

基金项目: 吉林省科技发展计划项目(20220201096gx)

通信作者: *evsv@sohu.com

测量的机器视觉设备。视觉测量系统被广泛应用于目标中心定位、尺寸测量、位姿估计^[2-4]等领域中。清晰图像的边缘细节丰富、对比强烈,是提高测量精度的关键因素^[5],因此自动对焦方法是视觉测量的关键技术之一。

在众多自动对焦方法中,传统对焦法 Depth from focus (DFF) 是目前最常用的方法。此方法首先通过 Brenner 等函数计算图像清晰度评价^[6],并将评价作为调焦状态的评价标准,然后利用爬山法等搜索策略^[7]寻找最佳对焦位置。2023 年,杨海等^[8]改进了 DFF,提出利用模拟退火算法实现显微镜的静态对焦,但其对焦耗时仍需要 2~4 s。这是因为 DFF 的过程中透镜必须沿着既定方向获取离焦图像序列,每个序列至少包括 10~20 幅图像,这增加了对焦耗时,还会导致误差积累。

随着人工智能技术与图形处理器 (GPU) 运算平台的发展,深度学习与光学成像技术融合的方法受到了广泛关注。2021 年,李强等^[9]设计了端对端的网络模型,从一帧离焦图像中直接获得准焦子图像,并应用在数字病理扫描系统中。原理上该模型是对子图像进行网络虚拟的自动对焦。但在视觉测量系统中,虚拟自动对焦会造成后续测量精度的下降。2022 年,杨聚圃等^[10]提出多段式的检焦策略,先利用残差神经网络 (ResNet) 对图像的离焦程度进行分类,完成粗检焦,再利用 DFF 完成精检焦。这种方式虽然可以有效减少镜头移动次数,但却增加了对焦过程的复杂程度。

本文将自动对焦问题转化为离焦距离预测问题。首先建立了视觉测量系统目标数据集与离焦距离预测模型,完成了目标图像与离焦距离的一对一映射^[11]。然后根据视觉测量系统的实际工作特点,提出了基于深度学习模型的对焦策略,并成功应用于视觉测量系统中。最终实验结果证明,相比于 DFF,本文方法具有对焦速度快、稳定性高等特点。

2 视觉测量系统自动对焦原理

2.1 视觉测量系统的构成

视觉测量系统是采用摄影测量的方法获得目标的空间位置坐标的设备,其构成如图 1 所示,主要由水平转台、工业相机、电控调焦镜头、嵌入式处理器以及被测目标等部分组成。系统成像主要参数如表 1 所示。系统工作流程为:首先在采集图像中利用预处理算法识别并提取目标图像;然后利用处理器对目标图像的模糊程度进行分析,驱动电控调焦镜头至检测对焦位置,进而使系统采集到清晰的目标图像;最后通过测量算法利用清晰目标图像解算出被测目标的位置和姿态。

被测目标为单一场景下的具有一定外形特征的靶标(徕卡棱镜目标、被测零件、工装等),通常测量范围在 0.15~10.00 m 之间。在系统工作过程中,为了获




图 1 视觉测量系统组成

Fig. 1 Visual measurement system composition

表 1 视觉测量系统成像主要参数

Table 1 Main imaging parameters of vision measurement system

Parameter	Value
Focal distance/m	0.15–10.00
Resolution	2592(H)×2048(V)
Pixel dimension/ μm	4.8

取到清晰的图像,需要对测量场景进行自动对焦。DFF 需要多次动态调整镜头,难以满足视觉测量系统对实时性、稳定性的较高要求。因此需要进行快速对焦算法的研究,以提升系统的对焦效率。

2.2 镜头离焦成像

光学成像过程中,当被测目标位置固定时,像面与焦平面的距离越远,所成的像也越模糊。因此实现自动对焦主要有两种方式:一种是利用机械装置移动图像传感器或镜头组,从而将像面调节至焦平面位置;另外一种较为新颖的方式是采用液体调焦镜头,通过改变电压值来改变液体的折射率,从而将像面调节到焦平面位置,此种方式具有响应速度快、功耗低等优点^[12]。

本文采用第二种对焦方式,并且将离焦距离^[13]定义为当前像面位置与最佳对焦位置间的电压值之差。在光学成像系统中,成像的模糊程度与离焦距离有直接的对对应关系^[14]。因此可以利用图像中的模糊信息通过深度学习的方法来预测离焦距离,进而完成对焦。

2.3 深度学习模型

卷积神经网络 (CNN) 是常应用于图像处理领域的深度学习模型,可以提取到图像中局部不变的特征,其训练过程一般是将带有标签值的图像输入网络后,通过优化算法,调整网络的权重使得损失函数最小。

本文提出的离焦距离预测网络结构由 ShuffleNetv2^[15]与多层感知机^[16] (MLP) 两部分构成。ShuffleNetv2 的结构如表 2 所示,输入图像依次经过卷积层 (Conv2D)-最大池化层 (Max pool)-模块组 (Stage 1、2、3)-卷积层-全局池化层 (Global pool) 后得到

表 2 离焦距离预测网络结构

Table 2 Network structure used to predict defocus distance

Type	Convolutional kernel size or stride	Output size
Input	—	$224 \times 224 \times 3$
Conv2D	$3 \times 3/2$	$112 \times 112 \times 24$
Max pool	$3 \times 3/2$	$56 \times 56 \times 24$
Stage 1	1×unit for spatial down sampling ^[15] /2 3×basic unit ^[15] /1	$28 \times 28 \times 116$
Stage 2	1×unit for spatial down sampling/2 7×basic unit/1	$14 \times 14 \times 232$
Stage 3	1×unit for spatial down sampling/2 3×basic unit/1	$7 \times 7 \times 464$
Conv2D	$1 \times 1/1$	$7 \times 7 \times 1024$
Global pool	$7 \times 7/1$	$1 \times 1 \times 1024$
FC 1	—	$1 \times 1 \times 1024$
FC 2	—	$1 \times 1 \times 256$
FC 3	—	$1 \times 1 \times 1$

1024 维特征,其中模块组是由基本单元(Basic unit)与下采样单元(Unit for spatial down sampling)叠加而成。由于 ShuffleNetv2 采用了通道重排等轻量化技术,可以在保证精度的同时降低计算量,在视觉测量系统等计算能力有限的设备上部署时性能较好。因此本文保留了 ShuffleNetv2 的卷积核大小、步长设计及关键结构^[15],再将其最后的分类层替换为具有单隐藏层结构的多层感知机(FC 1、FC 2、FC 3),进而完成对 1024 维特征的非线性拟合,其中隐藏层节点数根据文献[16]中的设计方式设置为 256 个。整体网络可表示为

$$d = F[I_{(l)}, \theta], \quad (1)$$

式中: d 为预测离焦距离; F 为离焦距离预测网络; I 为输入离焦图像; l 为真实离焦距离; θ 为网络参数。

网络训练及预测流程如图 2 所示。首先采用已标注离焦距离的训练集图像对网络的相关参数进行训练,得到具有固定权重的离焦距离预测模型。然后利用该模型对系统工作场景中的多种目标图像进行离焦距离预测。

3 图像的离焦距离预测

3.1 数据集的生成

数据集是在视觉测量系统工作环境中采集到的。将镜头对准目标后控制镜头以 0.2 V 为步长进行调整,初始电压从 30 V 增加至 50 V,每变换一次电压采集一幅目标图像,从而获得目标的离焦-对焦-离焦的图像序列。序列中每幅图像分辨率固定为 $224 \text{ pixel} \times 224 \text{ pixel}$ 。然后利用 Brenner^[17]清晰度评价函数获得




图 2 模型训练及预测流程

Fig. 2 Model training and prediction process

此序列中清晰度最高的图像,即最佳对焦位置图像,并将其真实离焦距离标注为 0。序列中非最佳对焦位置图像的离焦距离可表示为

$$l = |V_f - V_{df}|, \quad (2)$$

式中: l 、 V_{df} 分别为此位置图像的真实离焦距离与电压值; V_f 为最佳对焦位置图像的电压值。

视觉测量系统的工作环境难以保证采集图像的光照强度的一致性,若数据集图像的光照强度差别较大,则会使模型更加注重图像的光照特征而非关键的离焦特征。因此使用自适应的 Gamma 变换对数据集图像进行光照强度归一化。 γ 值^[18]可表示为

$$\gamma = \lg 0.5 / \lg_{255} \mu, \quad (3)$$

式中: μ 为图像的灰度均值。

按照上述的采集步骤,本文共采集了 652 个目标图像,每个目标的标注图像数目在 50~90 幅之间。数据集中共有 61933 幅图像,并且将按照 7:2:1 的比例分为训练集、验证集、测试集。部分数据集图像及真实离焦距离如图 3 所示。

3.2 模型训练及验证

模型训练过程中,损失函数选用 SmoothL1 并添加 L2 正则项用以降低模型过拟合程度,正则项参数设置为 10^{-4} ,学习率为 0.0001,优化函数采用 Adam 随机梯度下降法。表 3 为训练及预测过程中模型的参数。

训练集及验证集的损失下降情况如图 4 所示。可以发现,训练集损失的下降幅度逐渐减缓,而验证集损失虽出现波动但下降趋势与训练集损失基本保持一致,这表明模型具备一定的泛化性,在面对非训练集图像时可以输出可靠的预测结果,同时也验证了数据集的可靠性。

当 epochs 延续至 200 时输出离焦距离预测模型,使用平均绝对误差(MAE)衡量模型性能,具体可表示为




图 3 部分数据集图像及其真实离焦距离

Fig. 3 Partial dataset images and their real defocus distance

表 3 深度学习训练及预测参数

Table 3 Deep learning training and prediction parameters

Parameter	Value
Training set images	43354
Validation set images	12386
Test set images	6193
Computer disposition	NVIDIA GeForce RTX 3070 Ti
Training environment	PyTorch
Batch size	256
Epochs	200
Training duration /min	312
Predicting duration /ms	23
Model memory /M	6.04




图 4 训练集损失及验证集损失的下降情况

Fig. 4 Decline of training set loss and validation set loss

$$E_{\text{MAE}} = \frac{1}{N} \sum_{n=1}^N |y_n - \hat{y}_n|, \quad (4)$$

式中: N 为测试集中图像数量; y_n 为测试集中第 n 幅图像的真实离焦距离; $\hat{y}_n$ 为第 n 幅图像的预测离焦距离。计

算后可知,模型的 MAE 指标为 0.4252 V, 仅为本文中半采集量程的 4.25%, 小于文献[11]中的 MAE 指标。

模型在测试集中的离焦距离预测结果如图 5 所示, 预测结果保证了一定的主观一致性^[16], 但是模型预测的误差随着离焦距离的增加而有所增加。原因在于以下几点: 1) 失焦程度高的图像中缺少可利用的深度信息; 2) 如图 6 所示, 图像的清晰度评价与离焦距离呈非线性关系, 当离焦距离大于平缓区临界点^[19]时, 每个图像的清晰度评价差距很小, 模型的离焦距离预测值也会非常接近。比如将图 6 中 c、d 图像传入模型后会输出两个相似的预测值分别为 8.58 V 与 8.89 V, 误差较大, 而离焦距离小的 a、b 图像则会输出相对准确的预测值分别为 0.90 V 与 2.07 V。




图 5 测试集中模型离焦距离预测情况

Fig. 5 Defocusing distance of model prediction in test set

4 实际场景下自动对焦实验

4.1 基于深度学习模型的对焦策略

视觉测量系统工作时图像分辨率、图像复杂背景




图 6 单一离焦图像序列清晰度评价曲线

Fig. 6 Single defocus image sequence sharpness evaluation curve

等因素会影响深度学习对焦方法的适用性,这使得此方法需通过合理的对焦策略才可应用到实际对焦任务中。

4.1.1 对焦子区域

由于模型的输入尺寸固定为 $224 \text{ pixel} \times 224 \text{ pixel}$, 所以需要从单帧目标图像中提取出对焦子区域后才可获得此图像的离焦距离预测值。由图 7 所示, 目标图像被划分为边界明显、内容丰富的子区域与少量边界的稀疏内容子区域。一般来说, 内容丰富的子区域离焦、对焦的差别明显, 因此对焦过程中应尽可能对此类区域进行预测^[8]。本文则利用图像方差度量每个子区域的内容丰富程度, 然后提取出其中方差最大的 k 个子区域 $\{w_1, w_2, \dots, w_k\}$ 作为对焦子区域, 其中每个子区域尺寸为 $224 \text{ pixel} \times 224 \text{ pixel}$ 。




图 7 对焦子区域划分示意图

Fig. 7 Schematic diagram of focus sub-region division

由表 4 所示, 将图 7 中方差最大的 4 个子区域 $\{w_1, w_2, w_3, w_4\}$ 分别传入模型后输出对焦子区域的离焦距离序列 $O = \{d_1, d_2, d_3, d_4\}$, 其中 d_1 表示 w_1 的预测离焦距离。本文中单帧目标图像的离焦距离 D 可表示为

$$D = \frac{1}{k-2} \sum_{i=2}^{k-1} \hat{O}_i, \quad (5)$$

式中: $\hat{O}$ 为 O 按递增排列的序列; i 为对焦子区域的

表 4 单帧目标图像离焦距离预测方法

Table 4 Single frame target image defocus distance

prediction method		unit: V
Focus sub-region	Region defocus distance	Single frame target image defocus distance D
w_1	2.12	2.10
w_2	2.69	
w_3	1.62	
w_4	2.09	

位置。

可以发现, k 值较大对焦总耗时会成倍增加; k 值较小则可能会丢失单帧目标图像中部分特征信息。所以根据目标图像的分辨率, 要在 k 值足够大的同时保证实时性。因此本文将 k 值定义为

$$k = \lceil \max\{M, N\} / 224 \rceil, \quad (6)$$

式中: $M \times N$ 为视觉测量系统提取的目标图像的分辨率; $\lceil \cdot \rceil$ 为向上取整符号。

4.1.2 两步对焦算法

由 3.2 节可知, 模型预测误差与离焦距离有关, 根据此种特性, 本文提出两步对焦算法。算法流程如图 8 所示, 其中 j 表示镜头调整次数。首先, 获得当前帧图像的对焦子区域; 其次, 将其进行光照归一化传入模型; 然后, 模型预测并计算出目标图像离焦距离

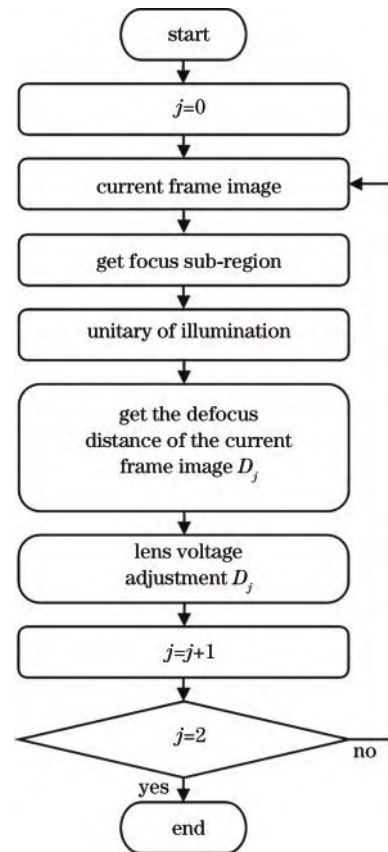


图 8 两步对焦算法流程图

Fig. 8 Two-step focusing algorithm flow chart

$D_j(j=0,1)$,并且将镜头像面沿既定方向调整(电压增大或减小) D_j ;最后,当上述步骤重复两次后停止对焦,此时镜头的电压值即为检测对焦位置 V_D 。第一次根据模型预测值调整镜头 D_0 后,此时相对最佳对焦位置仍有少许距离,然后对当前帧图像再进行预测后调整镜头 D_1 ,便可以将检测对焦位置调整至最佳对焦位置附近。

4.2 对焦实验

对焦实验选取了一个多景深场景。由图 9 所示,场景中包含 3 个主要目标,分别为徕卡棱镜组、准直物镜、读数显微镜。从图 9 中提取出 3 组目标图像,按相对镜头的工作距离分别标记为 A(近距离目标)、B(中距离目标)、C(远距离目标),其中 A 目标图像大小为 $1088 \text{ pixel} \times 1752 \text{ pixel}$,B 目标图像大小为




图 9 实验所用多景深目标场景

Fig. 9 Multi-depth-of-field target scene used in the experiment

$640 \text{ pixel} \times 900 \text{ pixel}$,C 目标图像大小为 $480 \text{ pixel} \times 800 \text{ pixel}$ 。

实验按照图像分辨率不同的目标分为三组。首先,采集每组目标图像的离焦序列并计算出最佳对焦位置 V_i ,其中 A 组为 45.2 V ,B 组为 42.3 V ,C 组为 41.5 V ;其次,为了验证算法在不同离焦距离下对焦性能,在 $35 \sim 40 \text{ V}$ 之间,以 0.2 V 为间隔,获得了 26 个对焦初始位置;然后,每组在既定对焦方向的情况下(默认对焦方向为电压增大方向),利用本文算法与 DFF 分别从这 26 个对焦初始位置开始对目标图像进行对焦,获得 26 个检测对焦位置 V_D ;最后,统计每组的检测对焦位置与最佳对焦位置的误差 E 。因为 DFF 的精度只取决于其搜索策略的步长,所以为了方便比较,将本文方法与 DFF 的对焦精度保持一致,即保留一位小数。误差 E 的统计方式具体可表示为

$$E = |V_i - V_D| \quad (7)$$

每组分别选取 3 个对焦初始位置 $35, 38, 40 \text{ V}$, 对其对焦性能进行展示。如表 5 所示,3 组中本文方法与 DFF 都能够找到最佳对焦位置附近,但是在对焦耗时方面,本文方法更具优势。通过计算得出,本文算法的对焦耗时仅为 DFF 的 $15\% \sim 24\%$,并且稳定在 $0.7 \sim 0.2 \text{ s}$ 之间,尤其在较大离焦距离的情况下可以减少近 80% 的对焦耗时。另外,DFF 在离焦距离较小的情况下依然需要调整镜头 10 次以上;本文方法的镜头调整次数恒为两次,避免了 DFF 由于搜索步长的非自适应性导致的耗时增加问题。因此本文方法具有对焦速度快、对焦步骤少等优点,相比于 DFF 有着较为明显的优势,特别适合应用于要求成像质量高、对焦速度快的光电测量设备。

表 5 所提方法与传统对焦法实验对比分析

Table 5 Proposed method is compared with traditional autofocus method

Group	Focus start position /V	Proposed method			Traditional autofocus method			Best focus position V_i /V
		Detect focus position V_D /V	Focus time /s	Lens adjustment times	Detect focus position V_D /V	Focus time /s	Lens adjustment times	
A	35	44.7	0.602	2	44.8	2.312	15	45.2
	38	45.1	0.583	2	44.6	2.905	18	
	40	45.0	0.591	2	44.8	2.133	15	
B	35	41.5	0.305	2	40.8	1.639	16	42.3
	38	41.4	0.289	2	41.6	1.234	12	
	40	41.6	0.337	2	40.4	1.459	14	
C	35	41.3	0.293	2	41.2	1.236	12	41.5
	38	41.1	0.294	2	41.2	1.744	16	
	40	41.1	0.352	2	41.2	1.115	11	

图 10 为每组 26 个对焦误差的统计图,并且将每组对焦误差的标准差定义为对焦稳定性。可以发现,本文算法的对焦稳定性也明显优于 DFF,这是由于 DFF 容易受到外界噪声的影响出现局部极值点,进而导致搜索策略无法搜索至最佳对焦位置附近。例如,B 组

中 DFF 由于局部极值点导致平均对焦偏差达到 1.646 V ;而本文方法从原理上改变了传统对焦的方式,进而消除了局部极值点的影响,因此 B 组中平均对焦误差仅为 0.707 V 。

针对对焦的准确性,由表 6 所示,A、B 组中本文算




图 10 对焦误差统计图。(a)A 组;(b)B 组;(c)C 组

Fig. 10 Focus error statistics diagram. (a) Group A; (b) group B; (c) group C

表 6 所提方法与传统对焦法的对焦误差以及对焦稳定性

Table 6 Focusing error and focusing stability of the proposed method and the traditional autofocus method

Group	Average focusing error /V		Focusing stability	
	Proposed method	Traditional autofocus method	Proposed method	Traditional autofocus method
A	0.281	0.381	0.192	0.218
B	0.707	1.646	0.133	0.507
C	0.381	0.262	0.117	0.192

法平均对焦误差小于 DFF, 而 C 组中平均对焦误差略高于 DFF。这是由于 C 组图像所提取的对焦子区域中会包含内容稀疏部分及多深度的物体, 使得模型对个别子区域的预测值出现偏差。但综合来看, 本文算法可以在提升对焦效率及稳定性的同时保证较小的对焦误差。

5 结 论

为了提升视觉测量系统的对焦性能, 提出了一种基于深度学习的对焦方法。构建了离焦距离预测网络, 并且利用系统采集的离焦图像进行训练。训练结果表明: 模型具备一定的泛化性, 在实际系统工作过程中, 可以对目标图像的离焦距离做出准确预测。通过合理对焦策略, 也可以减少模型预测误差对于对焦结果的影响。实验结果表明: 本文方法的对焦耗时仅为 DFF 的 15%~24%, 对焦稳定性相比 DFF 提升了约 40%, 从原理上也避免 DFF 因局部极值点导致对焦误差较大的问题。本文方法为现有的对焦方法体系中提供了新思路, 有助于视觉测量系统向智能化方向的发展。

参 考 文 献

- [1] 朱云, 凌志刚, 张雨强. 机器视觉技术研究进展及展望[J]. 图学学报, 2020, 41(6): 871-890.
Zhu Y, Ling Z G, Zhang Y Q. Research progress and prospect of machine vision technology[J]. Journal of Graphics, 2020, 41(6): 871-890.
- [2] 汪路涵, 巩岩, 张艳微, 等. 人眼自动对焦及瞳孔中心自动对准系统[J]. 光学学报, 2023, 43(5): 0511002.
Wang L H, Gong Y, Zhang Y W, et al. Human eye autofocus and pupil center auto-alignment system[J].

Acta Optica Sinica, 2023, 43(5): 0511002.

- [3] 王志远, 刘恒龙, 刘威. 基于三维激光点云的枕簧几何尺寸测量方法[J]. 中国激光, 2023, 50(19): 1904001.
Wang Z Y, Liu H L, Liu W. Geometric dimension measurement method for bolster spring based on three-dimensional laser point clouds[J]. Chinese Journal of Lasers, 2023, 50(19): 1904001.
- [4] 周威, 杜馨瑜, 薛宪堂, 等. 高速铁路接触网几何参数立体视觉测量系统[J]. 光学学报, 2023, 43(5): 0512001.
Zhou W, Du X Y, Xue X T, et al. Stereo vision-based measurement system for geometric parameters of high-speed railway catenary[J]. Acta Optica Sinica, 2023, 43(5): 0512001.
- [5] 李明磊. 计算机视觉三维测量与建模[M]. 北京: 电子工业出版社, 2022: 24-26.
Li M L. Computer vision 3D measuring and modelling [M]. Beijing: Publishing House of Electronics Industry, 2022: 24-26.
- [6] 王烨茹. 基于数字图像处理的自动对焦方法研究[D]. 杭州: 浙江大学, 2018: 33-35.
Wang Y R. Research on auto-focus methods based on digital imaging processing[D]. Hangzhou: Zhejiang University, 2018: 33-35.
- [7] Jia D Y, Zhang C W, Wu N K, et al. Autofocus algorithm using optimized Laplace evaluation function and enhanced mountain climbing search algorithm[J]. Multimedia Tools and Applications, 2022, 81(7): 10299-10311.
- [8] 杨海, 冯选璋, 刘家屹, 等. 基于图像评价的显微镜自动对焦方法[J]. 激光与光电子学进展, 2023, 60(4): 0411003.
Yang H, Feng X Z, Liu J Y, et al. Microscope autofocus method based on image evaluation[J]. Laser & Optoelectronics Progress, 2023, 60(4): 0411003.
- [9] 李强, 刘贤明, 韩凯歌, 等. 基于深度学习的数字病理

- 扫描系统单次曝光自动对焦方法[J]. 中国科学: 信息科学, 2021, 51(10): 1675-1689.
- Li Q, Liu X M, Han K G, et al. Whole slide imaging via one-shot deep autofocusing[J]. Scientia Sinica: Informationis, 2021, 51(10): 1675-1689.
- [10] 杨聚圃, 杜佳林, 李凡星, 等. 基于深度学习的数字光刻自动检焦方法[J]. 光子学报, 2022, 51(6): 0611002.
- Yang J P, Du J L, Li F X, et al. Deep learning based method for automatic focus detection in digital lithography[J]. Acta Photonica Sinica, 2022, 51(6): 0611002.
- [11] Farnes S A R, Tsai D M, Chiu W Y. Autofocus measurement for electronic components using deep regression[J]. IEEE Transactions on Components, Packaging and Manufacturing Technology, 2021, 11(4): 697-707.
- [12] 兰天成, 兰荣华, 陈晓西, 等. 液晶透镜爬山自动对焦算法研究[J]. 光学学报, 2020, 40(14): 1411003.
- Lan T C, Lan R H, Chen X X, et al. Research on liquid crystal lens hill climbing autofocus algorithm[J]. Acta Optica Sinica, 2020, 40(14): 1411003.
- [13] 朱景峰, 钟平, 汤信, 等. 用于离焦图像焦点预测中的深度学习不确定性建模[J]. 光学与光电技术, 2023, 21(4): 48-58.
- Zhu J F, Zhong P, Tang X, et al. Uncertainty modeling in deep learning for focus prediction of defocused images[J]. Optics & Optoelectronic Technology, 2023, 21(4): 48-58.
- [14] 徐日辛, 周骛, 张翔云. 基于深度学习的显微离焦图像法颗粒深度测量[J]. 化工进展, 2021, 40(12): 6499-6504.
- Xu R X, Zhou W, Zhang X Y. Particle depth position measurement using microscopic defocused imaging method based on deep learning[J]. Chemical Industry and Engineering Progress, 2021, 40(12): 6499-6504.
- [15] Ma N N, Zhang X Y, Zheng H T, et al. ShuffleNetV2: practical guidelines for efficient CNN architecture design [M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11218: 122-138.
- [16] 朱丹妮, 许小华, 贺静婧, 等. 应用多层感知机回归的无参考型超分辨图像质量评价[J]. 西安工程大学学报, 2022, 36(5): 70-78.
- Zhu D N, Xu X H, He J J, et al. No-reference super-resolution image quality assessment method using multi-layer perceptron regression[J]. Journal of Xi'an Polytechnic University, 2022, 36(5): 70-78.
- [17] 刘济豪, 卢荣胜, 张紫龙, 等. 焦距测量中线纹清晰度评价函数的研究[J]. 光学学报, 2023, 43(9): 0912001.
- Liu J H, Lu R S, Zhang Z L, et al. Sharpness evaluation function for line patterns in focal length measurement[J]. Acta Optica Sinica, 2023, 43(9): 0912001.
- [18] Babakhani P, Zareh P. Automatic gamma correction based on average of brightness[J]. Advances in Computer Science, 2015, 4(6): 156-159.
- [19] 翟永平, 周东翔, 刘云辉, 等. 聚焦函数性能评价指标设计及最优函数选取[J]. 光学学报, 2011, 31(4): 0418002.
- Zhai Y P, Zhou D X, Liu Y H, et al. Design of evaluation index for auto-focusing function and optimal function selection[J]. Acta Optica Sinica, 2011, 31(4): 0418002.