

引用格式: YANG Jupu, DU Jialin, LI Fanxing, et al. Deep Learning Based Method for Automatic Focus Detection in Digital Lithography[J]. Acta Photonica Sinica, 2022, 51(6):0611002

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

基于深度学习的数字光刻自动检焦方法

杨聚圃^{1,2}, 杜佳林^{1,2}, 李凡星¹, 湛庆荣¹, 王思沫^{1,2}, 严伟¹

(1 中国科学院光电技术研究所 环境光学研究院, 成都 610209)

(2 中国科学院大学, 北京 100049)

摘要: 目前基于数字微镜器件的无掩膜光刻系统离不开高精度的检焦系统, 单独设计的检焦系统不仅会增加全系统结构的复杂度, 还会增加装调的难度。因此提出一种基于深度学习的检焦方法, 通过调节光路使曝光焦面和相机成像焦面重合, 仅根据当前所成的图像即可实现焦平面的快速自动检测。该算法由粗检焦和精检焦两步组成, 粗检焦利用深度学习模型对相机记录的图像进行分类, 仅需 90 ms 就可判断当前基片的离焦区间; 精检焦利用清晰度评价函数计算图像清晰度值, 结合搜索算法即可在粗检焦的基础上准确找到焦平面。用 5 倍聚焦物镜进行实验, 在 $(-40 \mu\text{m}, 40 \mu\text{m})$ 的离焦区间内, 检焦精度可达 $2 \mu\text{m}$, 总用时不超过 300 ms。仿真分析和实验验证结果表明, 该方法具有结构复杂度低、检焦速度快、检焦精度高等优点, 能够很好地应用于数字光刻领域。

关键词: 数字光刻; 自动检焦; 深度学习; 图像处理

中图分类号: O436

文献标识码: A

doi: 10.3788/gzxb20225106.0611002

0 引言

基于数字微镜阵列器件 (Digital Micromirror Devices, DMD) 的数字光刻技术是微纳结构制备方法之一^[1], 由于其具有成本低、灵活性高的优点^[2-3], 在微纳加工方面有着巨大的优势。但是高分辨率的微纳加工需要短波长光源和高数值孔径光学系统的配合, 导致曝光焦深越来越短^[4-5], 为了保证光刻图案的质量, 基片必须处于焦深范围之内, 因此对焦面的快速高精度检测是高分辨率微纳结构制备的关键。

三角法^[6-7]是光刻中常用的检焦技术, 但是随着分辨率的不断提高, 投影物镜与基片之间的空间越来越小, 无法再采用该方法进行检焦^[8]。临界角法、针孔法、像散法等同轴检焦方法^[9-11]则能较好地克服这一问题, 但是这类方法的光路中通常包含一些复杂的光学元件, 对系统的装调要求较高。随着图像处理技术的不断发展, 不需要复杂光路的调节, 仅根据离焦图像就可以实现焦平面检测的调焦方法已经应用到了很多领域。2016 年, 王冠军^[12]利用图像处理技术实现了光电经纬仪的自动调焦, 能够达到 $12 \mu\text{m}$ 的调焦精度, 初始调焦最长耗时 5.81 s。但是该方法需要根据经验设计合适的清晰度评价函数, 并且利用搜索算法控制位移台在较大区间内往返运动寻找最佳成像位置, 耗费大量的时间。2018 年, YANG S J^[13]利用深度学习实现了生物细胞显微图像的离焦度量, 通过合成离焦图像并对其划分区间来训练分类网络, 从而实现对 11 个离焦区间的准确判断。虽然这种方法仅需一张图像就可以实现离焦区间的快速检测, 但是对焦平面的检测并不精确, 很难应用到高精度设备中来。

为了在曝光物面实时成像的同时实现快速检焦, 本文提出一种基于深度学习的数字光刻自动检焦方法, 分两步实现焦平面位置的高精度快速检测。首先利用单次曝光所成的图像, 通过训练好的深度学习模

基金项目: 四川省科技计划项目 (Nos. 2020JDJQ0007, 2021JDRC0089), 中科院关键技术团队项目 (No. YA20K023), 中科院科研仪器设备研制项目 (No. YJKYYQ20210041)

第一作者: 杨聚圃 (1999—), 男, 硕士研究生, 主要研究方向为光电成像与目标识别。Email: yangjupu20@mailsucas.ac.cn

导师 (通讯作者): 严伟 (1977—), 男, 研究员, 博士, 主要研究方向为微电子装备研制, 以及相关微纳光学、光学测量的关键技术。Email: yanwei@ioe.ac.cn

收稿日期: 2022-01-06; **录用日期:** 2022-02-23

<http://www.photon.ac.cn>

型,直接驱动位移台使得基片到达焦平面附近,实现粗检焦。然后利用清晰度评价函数结合搜索算法,在小区间内实现精确检焦。

1 检焦原理

1.1 检焦系统设计

提出的基于深度学习的数字光刻自动检焦系统如图1所示。该系统主要由光源、蝇眼阵列、反射镜、会聚透镜、DMD、Tube透镜、长通二向色镜、聚焦物镜、CCD探测器组成。光源通过蝇眼阵列匀光系统,均匀地投射到DMD靶面上,DMD上的数字图案经过Tube透镜1、长通二向色镜和聚焦物镜后投影到基片上,反射光经过Tube透镜2后在CCD上成像。调节光路保证CCD与DMD共轭,使得DMD的曝光焦面和CCD的成像焦面重合。若基片未处于DMD曝光焦面位置,CCD所成的像将变得模糊,此时将CCD采集的图像传至粗检焦网络模型中对焦平面进行粗定位,判断当前所在位置并输出信号,控制位移台移动到焦平面附近。位移台稳定后,基片与焦平面间的距离将达到微米级别,此时再利用清晰度评价函数和搜索算法实现小离焦区间下的焦平面高精度定位。

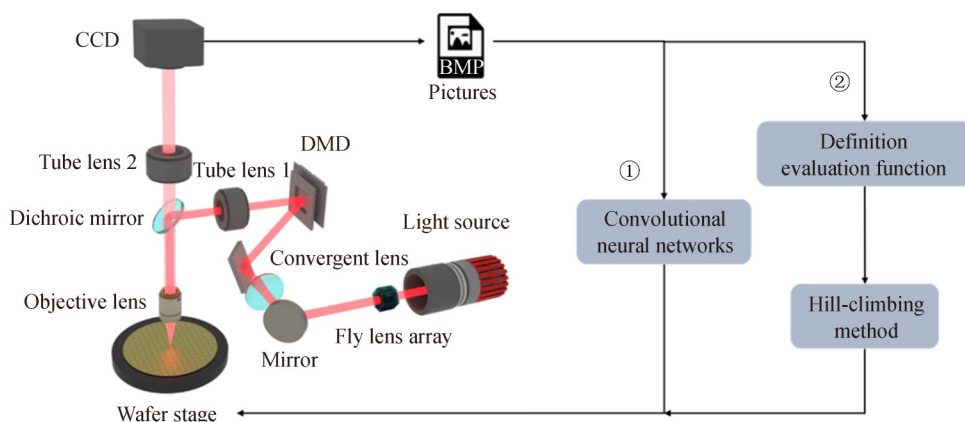


图1 基于深度学习的数字光刻自动检焦系统原理示意图

Fig.1 Schematic diagram of a deep learning based digital lithography autofocus system

1.2 基于深度学习的粗检焦原理

不同离焦程度下的图像具有不同的特征,对离焦距离的各个区间进行合理划分,可以寻找到各离焦区间内图像的共性特征,从而根据各离焦区间内图像特征的区别,判断出当前图像所处的离焦区间,最后以此为依据控制位移台将基片移动到焦平面附近。随着人工智能的不断发展,基于深度学习的分类网络进入了大家的视野,它不需要手工设计相应的特征提取算子,而是通过学习的方式获得同类目标的共性特征,表现出极高的性能。本文将该检焦问题看作一种分类问题,提出了一种基于深度学习的粗检焦方法。首先采集不同离焦程度下的图像并对其进行标注,然后将图像及标签输入分类网络,选择合适的损失函数,通过梯度反向传播来最小化损失函数,从而实现分类网络的训练。

在数据采集之前,准备9种不同的DMD数字图案用于成像,通过使用不同的数字图案,可以提升网络模型的泛化能力,保证模型在遇到未参与训练的图案时还能够很好地对图像清晰度做出评价。将硅片固定到位移台上,选取一个DMD数字图案通过曝光光路用5倍聚焦物镜将其投影到硅片上,再经过成像光路将图案成像到CCD上。找到最佳成像位置后,将位移台此时的位置标记为焦平面,控制软件自动采集焦平面以及正负离焦 $40\ \mu\text{m}$ 下的图像,连续图像之间的间距为 $1\ \mu\text{m}$,曝光时间为 $20\ \text{ms}$,图像分辨率为 5120×5120 。然后更新DMD数字图案,使基片移动至标记的焦平面位置,重复以上操作,最终获取729张图像。

由于连续离焦图像之间差异极小,将不同离焦状态下的每张图像都作为一个类别,即用深度学习的方法实现精检焦。这需要大量高质量的数据对网络模型进行训练,但是由于位移台存在回程误差,很难保证所采集数据的质量,容易造成网络模型训练不收敛。而且由于各类别间的图像非常相似,采用卷积神经网络提取图像特征时,随着网络层数的加深,特征会被抽象到较高的层次,离焦量相近的图像之间特征难以区

分。所以提出了粗检焦加精检焦的两阶段检焦策略,按照离焦距离把采集到的所有图像分为9个区间:四级负离焦(-40 μm, -31 μm)、三级负离焦(-30 μm, -21 μm)、二级负离焦(-20 μm, -11 μm)、一级负离焦(-10 μm, -6 μm)、粗焦面(-5 μm, 5 μm)、一级正离焦(6 μm, 10 μm)、二级正离焦(11 μm, 20 μm)、三级正离焦(21 μm, 30 μm)、四级正离焦(31 μm, 40 μm)。通过对数据集进行随机划分,最终用于训练的图像有658张,用于测试的图像有71张,图2展示了各离焦区间中心下三种数字图案在CCD上所成的图像和对应的准焦图像。




图2 各离焦区间中心在CCD上所成的图像
Fig.2 Image of the centroid of each out-of-focus range on the CCD

选取交叉熵函数作为训练的损失函数,即

$$L = \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^M y_{ic} \ln(p_{ic}) \quad (1)$$

式中, N 表示每个训练批次中样本的个数; M 表示类别的数量; y_{ic} 是符号函数,当样本 i 的真实类别为 c 时 y_{ic} 的值取1,否则取0; p_{ic} 表示样本 i 属于类别 c 的预测概率。交叉熵函数求导简单,在梯度反向传播时能够减少计算量,并且损失仅与正确类别的概率有关,非常适合作为多分类网络的损失函数。

粗检焦的网络模型结构如图3所示,其主干框架为ResNet^[14]分类网络。ResNet网络的结构主要由

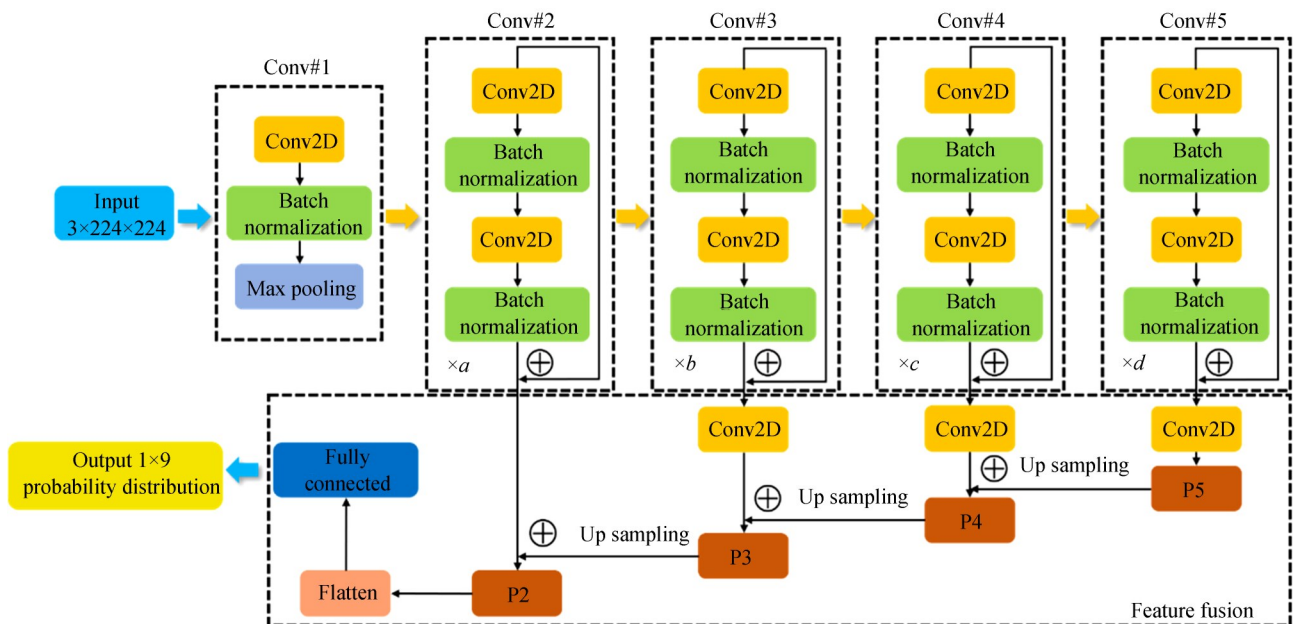


图3 粗检焦网络结构
Fig.3 Coarse check focus network structure

Conv#1、Conv#2、Conv#3、Conv#4 和 Conv#5 这五个卷积模块构成,其中 Conv#2、Conv#3、Conv#4 和 Conv#5 分别是由 Bottleneck 模块(如图 4 所示)重复堆叠 a 、 b 、 c 、 d 次而构成,这四个卷积模块能够分别提取输入图像不同尺度下的特征。图 3 中组成这四个卷积模块的 Bottleneck 模块即图 4(a)所示的结构,但是省略了图 4(a)中的虚线部分,该部分仅在 Bottleneck 模块输入和输出的通道数不同时才存在。由于本实验分类的对象为不同离焦状态下的图像,不同类别图像之间非常相似,浅层特征图中的信息对于实现准确的分类有很大帮助。所以,在 ResNet 结构的基础上添加了特征融合结构(Feature Fusion, FF),选取 Conv#2、Conv#3、Conv#4 和 Conv#5 的输出作为中间层,生成的不同尺度特征图的大小分别为: 56×56 , 28×28 , 14×14 , 7×7 。对这些不同尺度的特征图进行单独的卷积和上采样操作来统一不同特征图的通道数和尺寸,最后依次将其相加实现特征的融合。

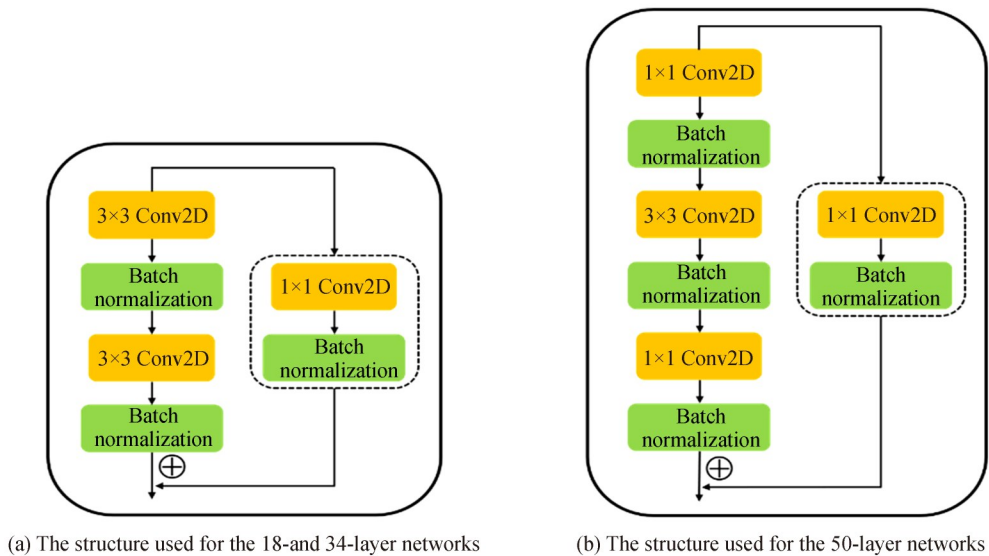


图 4 Bottleneck 模块
Fig.4 Bottleneck modules

当网络模型实现对输入图像的分类后,还需要一定的调焦策略,控制位移台沿某一方向移动相应的距离才能够将基片移动到焦平面附近,在对离焦区间进行划分时就已经考虑了这一问题。当网络模型检测到图像处于粗焦面时则不需要移动位移台;若处于某一离焦区间时,仅需将位移台沿当前离焦区间的反方向移动一段距离,该距离为当前离焦区间中心所对应的值。例如:网络模型检测到当前的图像处于二级正离焦,那么位移台移动的方向即为负方向,相应的移动距离为 $15 \mu\text{m}$,这样就将原来位于 $(11 \mu\text{m}, 20 \mu\text{m})$ 离焦区间的基片移动到了粗焦面区间,之后再使用基于评价函数和搜索算法的精检焦方法实现精确调焦。

1.3 基于评价函数及搜索算法的精检焦原理

离焦图像在空域中表现为边缘细节的模糊,而且这种现象会随着离焦程度的变化而变化。一般而言 CCD 在焦平面处获得的图像清晰度最高,在焦平面两侧随着离焦距离的不断增加,图像的清晰度也将不断下降。清晰度评价函数是一种能够量化图像清晰程度的工具,当基片处于任意离焦位置时,都可以通过评价函数获取当前位置图像的清晰度值,然后配合一定的搜索算法移动位移台,并对下一位置的图像进行评价,直到找到清晰度值最高的图像为止,该图像对应的基片位置即为焦平面位置。用基于空间域的评价函数^[15]进行焦平面的精确检测,其表达式为

$$F = \frac{1}{PQ} \sum_x^P \sum_y^Q (f(x, y) * T)^2 \quad (2)$$

式中, F 为图像的清晰度评价价值, P 和 Q 分别为图像的宽和高对应的像素个数, $f(x, y)$ 表示以像素点 (x, y) 为中心的灰度值矩阵,其大小与 T 相同, T 为图像梯度算子, $*$ 表示两个矩阵对应元素相乘后再求和的卷积运算。通过改变图像梯度算子的形式,可以使评价函数具有不同的性质。通过选择合适的清晰度评价函数,并且结合一定的搜索算法,能够实现焦平面的精确检测。

2 仿真分析

2.1 粗检焦网络结构及性能分析

粗检焦网络是使用 Pytorch1.10 深度学习框架在 Pycharm 开发环境下搭建的,实验使用的图形处理器为 RTX3090,中央处理器为 i9-10900K。该网络的输入为 5120×5120 像素的高清图像,为了减轻模型内存空间的占用,在训练的过程中先通过随机裁减将图像调整为 224×224 像素,然后将其输入网络并计算损失,最后使用 Adam 优化器以 0.000 1 的学习率对网络的权重进行优化。

为了选择合适的网络结构实现粗检焦的目的,用不同层数的网络结构测试其对粗检焦性能的影响。首先在不添加特征融合结构的 ResNet18、ResNet34 和 ResNet50 网络结构中,只取最后一层输出的特征图用于分类,使用采集到的训练数据并且设置完全相同的超参数在设备中训练 300 轮。其中 34 层和 18 层的四个卷积模块是由图 4(a) 所示的 Bottleneck 模块重复堆叠 $a、b、c、d$ 次而成,34 层网络结构对应的 $a、b、c、d$ 取值分别为 3、4、6、3;18 层网络结构对应的取值分别为 2、2、2、2;50 层的四个卷积模块主要由图 4(b) 所示的 Bottleneck 模块重复堆叠 3、4、6、3 次而成。训练完成后,使用测试集对网络模型进行测试,测试结果如表 1 所示。可以看出 ResNet50 和 ResNet34 的准确率更高,但是综合图 5 各个网络的混淆矩阵可以看出并不是

表 1 不同层结构网络模型在测试集上的准确率

Table 1 Accuracy of network models with different layer structures on the test set

Network model	Accuracy/%
ResNet18	70.0
ResNet34	77.5
ResNet50	77.5

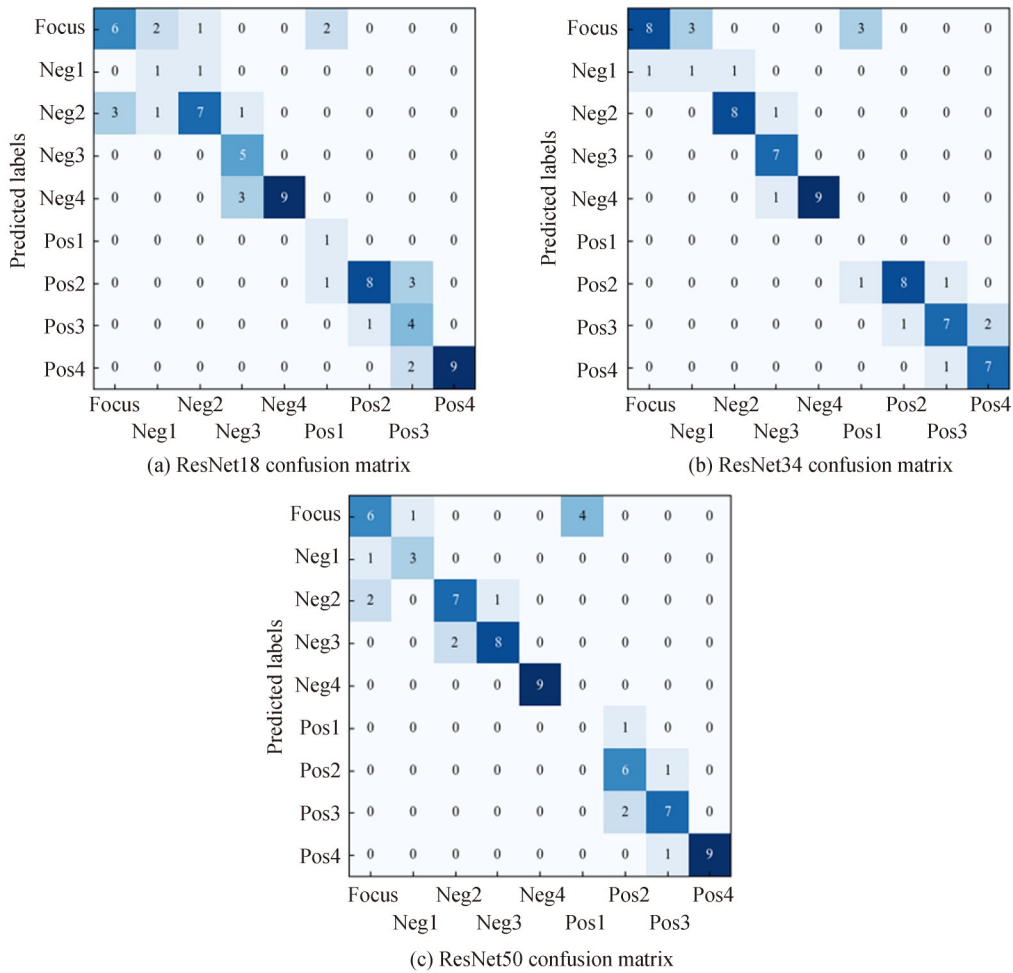


图 5 不同层结构的网络模型在测试集上的混淆矩阵

Fig.5 Confusion matrix for network models with different layer structures on the test set

网络结构越深,分类效果越好。对于 ResNet34 来说虽然有一些类别没有划分正确,但是也都被划分到了相邻的类别中,而 ResNet50 有一些属于焦平面的样本却被划分到了二级负离焦类别。反映出随着网络结构的加深提取的特征抽象程度就会更高,而对于连续的离焦图像来说,相似度本来就很高,如果特征被抽象到很高的层次后,相似的特征将会成为分类的主导因素,所以有必要融合浅层特征一起实现分类。

为了验证特征融合结构的有效性,分别对 ResNet18、ResNet34 和 ResNet50 添加了特征融合结构,然后在同一台设备中设置相同的超参数进行了 300 轮训练,结果如表 2 所示。比较表 1~2 可以发现,特征融合结构能很好的提升网络模型的性能,添加了特征融合结构的 ResNet18 网络在准确率上达到了与未添加特征融合结构的 ResNet34 网络相同的水平,而且融合了浅层特征之后,深层网络的性能提升也非常明显。

表 2 添加特征融模块的不同层结构网络模型在测试集上的准确率

Network model	Accuracy/%
ResNet18+FF	77.5
ResNet34+FF	83.1
ResNet50+FF	84.5

通过实验可以看出选择合理的网络层数并且融合不同尺度下的特征能够有效提升网络模型的性能,而一味地堆叠卷积模块并不能线性提升网络模型性能,只有选取合适的网络结构,才能以最小的计算量得到较高的性能。最终选取图 4(a)所示的 Bottleneck 重复堆叠 3、4、3、3 次组成 ResNet28 网络,并且添加特征融合结构作为粗检焦的网络模型。使用训练集在该网络模型上训练到 280 轮时,训练损失的下降趋势逐渐减缓,如图 6(a)所示,所以在训练到达第 300 轮时停止训练,最终该网络模型在测试集上的准确率达到 88.7%,观察此时混淆矩,如图 6(b)所示,可以发现该模型能够较好地实现离焦区间的判定。同时,为了验证网络模型的检测时间能否满足需求,对测试集中全部图像进行离焦区间的判定,并对所用时间进行平均,最终处理一张图像的时间仅为 90 ms,能够很好地满足粗检焦的需求。

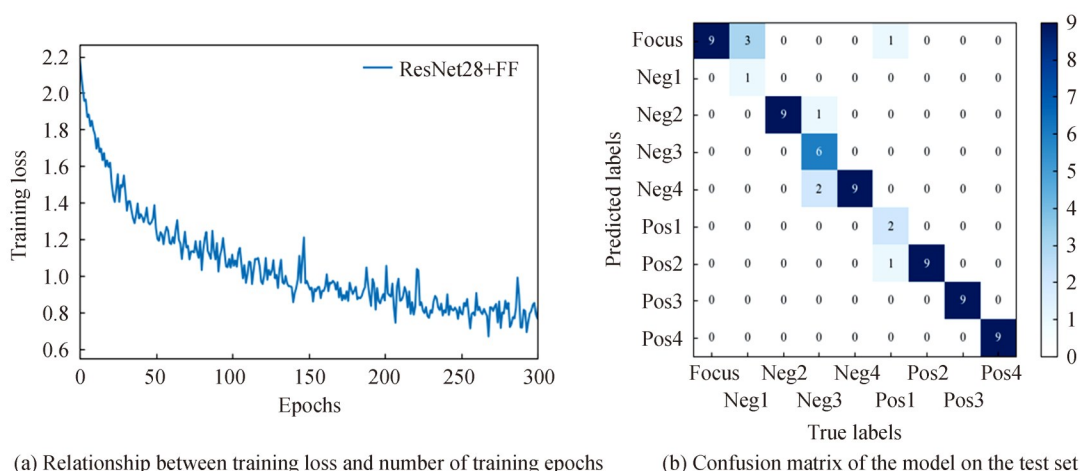


图 6 ResNet28+FF 的训练结果
Fig.6 Training results of ResNet28+FF

2.2 精检焦清晰度评价函数性能分析

为了选取合适的清晰度评价函数,选取一级负离焦、粗焦面、一级正离焦三个区间中的同一组图片用不同的清晰度评价函数进行评价,并绘制如图 7 所示的归一化评价曲线。可以看出 Laplacian 评价函数的表现最好,然后依次为 Energy 函数和 Brenner 函数。由于曝光图案一般都位于靶面中心,而且所成图像的视场远大于曝光区域,CCD 所成图像四周都为纯黑背景,所以在精检焦时,先对图像大小进行调整然后对其中心裁剪,以减少计算量,加快处理速度。表 3 为各评价函数对单张预处理后的图像(500×500)评价所用的时间,结合图 7 和表 3 可以看出,Laplacian 函数评价图像清晰度的性能准确而且处理图像所需的时间远远小于

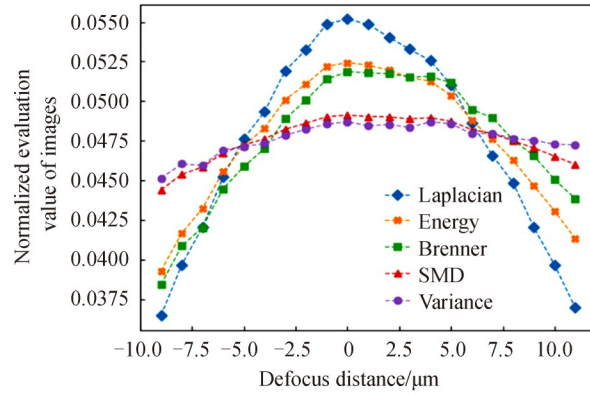


图7 不同清晰度评价函数在一组离焦图片中的归一化评价曲线
Fig.7 Normalized evaluation curves for different definition evaluation functions in a set of out-of-focus images

表3 不同清晰度评价函数处理图片所需时间

Table 3 Time required to process images with different definition evaluation functions

Image definition evaluation function	Time taken to evaluate a single image /s
Laplacian	0.005
Energy	0.998
Brenner	0.247
SMD	0.991
variance	0.771

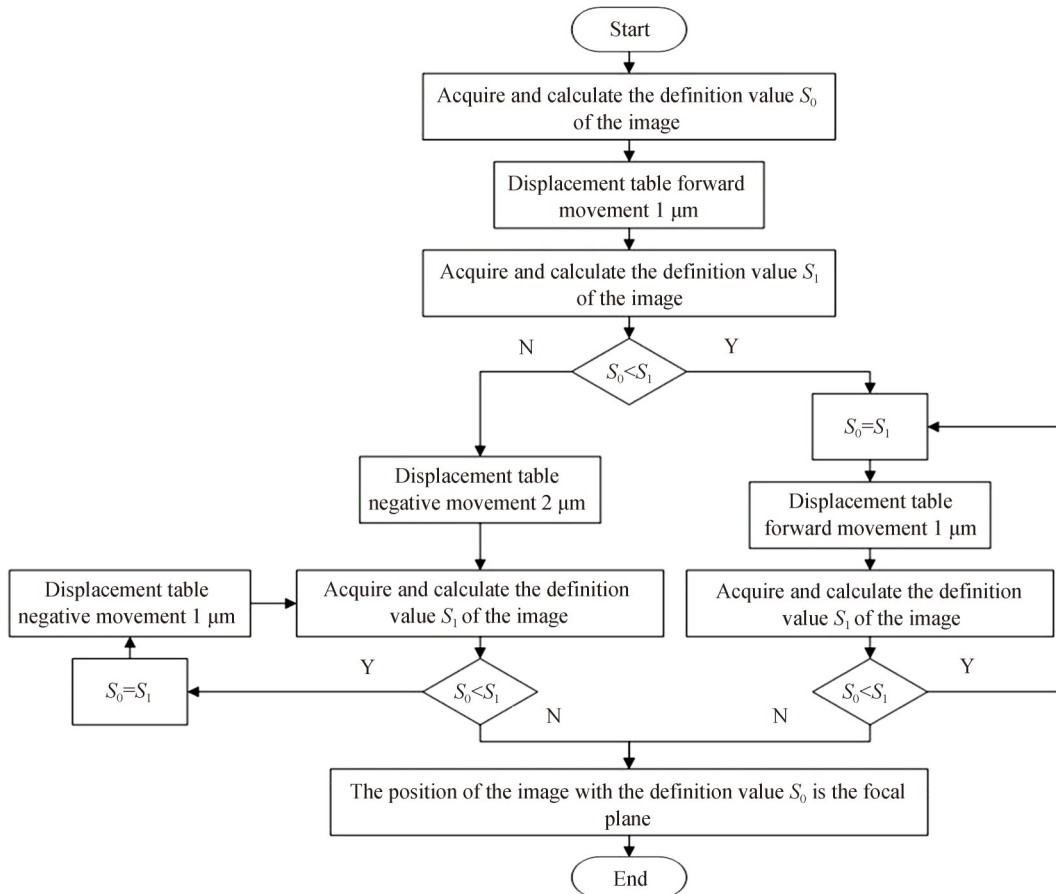


图8 搜索算法流程
Fig.8 Search algorithm flow chart

Energy 等函数,所以选取 Laplacian 函数作为精检焦的图像清晰度评价函数,最终用 Laplacian 函数对一幅图像的评价时间仅为 5 ms。

用合适的评价函数还需要配合一定的搜索算法才能以尽可能少的时间找到焦平面,由于在粗检焦时已经将基片移动到了焦平面 $\pm 5 \mu\text{m}$ 的位置,针对在小区间下焦平面搜索的问题,用图 8 所示的搜索算法来解决。首先用评价函数计算当前位置图像的清晰度值 S_0 ,然后将位移台沿正方向移动 $1 \mu\text{m}$,待位移台稳定 20 ms 后,计算此时图像的清晰度值 S_1 ,若 S_1 大于 S_0 则沿正方向继续搜索;若 S_1 小于 S_0 则改变搜索方向并对比连续图像间的清晰度值,直到下一张图像的清晰度值小于上一张图像的清晰度值为止。此时,采集上一张图像时基片的位置则为焦平面的位置。

2.3 粗精检焦与传统检焦方法的性能对比分析

为了验证本方法的性能,选取图 2 中的直线图案在不同离焦距离的情况下,分别使用本方法同传统基于清晰度评价函数及搜索算法的检焦方式进行对比。因为本文所提方法的精检焦部分已经选取了性能较强的清晰度评价函数,所以作为对照实验的传统方法采用与精检焦相同的检焦策略。通过表 4~5 可以看出,本文所提的方法与传统的检焦方法都能够准确检测出焦平面的位置,但是在检焦所用时间方面,本方法更具优势,尤其是在大离焦距离的情况下,能够节约近 3/4 的时间。另外,传统方法需要更多的检焦步骤,很容易引入由于外部环境震动所产生的误差,从而导致检焦错误;而本方法的检焦步骤远小于传统方法,离焦程度越大,检焦所用步骤的差距就越大。所以本文检焦方法有着检焦速度快、检焦步骤少的优点,相较于传统检焦方案有明显的优势。

表 4 相同图案在不同离焦情况下使用本文所提方法的检焦性能

Table 4 Focus detection performance of the same pattern in different out-of-focus situations using the proposed method

Off-focus volume/ μm	Coarse check focus results	Steps used for precision focus checks	Total time/ms	Focus check results
-40	Grade 4 negative defocus 98%	6	263.8	True
-29	Grade 3 negative defocus 53.8%	5	238.4	True
-18	Grade 2 negative defocus 88%	4	212.1	True
-10	Grade 1 negative defocus 58.4%	3	191.4	True
-1	Coarse focal plane 80%	2	168.9	True
9	Grade 1 positive defocus 54.8%	3	188.8	True
17	Grade 2 positive defocus 78.6%	4	212.9	True
28	Grade 3 positive defocus 73.5%	5	241.1	True
39	Grade 4 positive defocus 96.8%	6	263.5	True

表 5 相同图案在不同离焦情况下使用传统方法的检焦性能

Table 5 Focus detection performance of the same pattern in different out-of-focus situations using conventional methods

Off-focus volume / μm	Steps used for focus checks	Total time/ms	Focus check results
-40	41	1 023.1	True
-29	30	729.3	True
-18	19	478.1	True
-10	11	302.4	True
-1	2	75.6	True
9	10	298.1	True
17	18	520.5	True
28	29	804.1	True
39	40	1 055.2	True

3 实验结果

为了验证本方法的可行性,搭建了如图 9 所示实验系统,来测试真实曝光过程中焦面检测的准确性。实验系统主要包括 LED 光源(波长:365 nm)、DMD(像素尺寸:13.68 μm \times 13.68 μm)、两个 Tube 透镜、长通二向色镜、聚焦物镜(5 \times , NA=0.15)、CCD 探测器、位移台(垂向精度:1 μm)、图像处理工作站(图形处理器为

RTX3090、中央处理器为 i9-10900K、使用 Pycharm 开发环境)等。




图9 实验系统

Fig.9 Experimental system diagram

实验过程中选取了两个代表位置+37 μm 、-24 μm 进行展示,分别代表正负离焦情况下不同离焦距离的情况,能够很好地验证本方法的有效性。检焦过程如图 10 和 11 所示,图 10(a)中 A 是在正离焦 37 μm 时通过 CCD 采集到的图像,将其传给深度学习模型后进行分类,发现其以 83.9% 的置信度被分到了四级正离

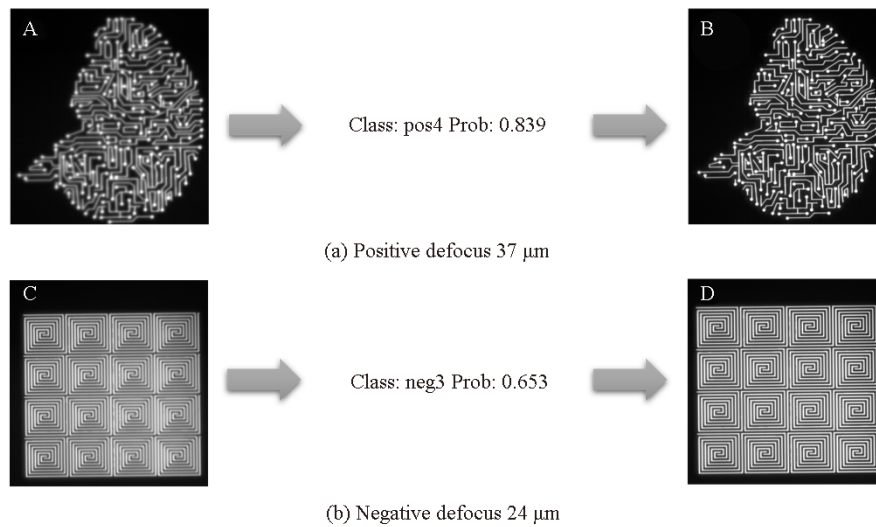


图 10 粗检焦过程展示

Fig.10 Coarse focus check process display




图 11 精检焦过程展示

Fig.11 Precision check focus process display

焦区间,据此控制位移台向负方向移动 35 μm 就可以得到 B。图 10(b)中 C 是在负离焦 24 μm 时采集到的图像,将其传给深度学习模型后进行分类,可以得到其以 65.3% 的置信度被分到了三级负离焦区间,据此控制位移台向正方向移动 25 μm 就可以得到 D。通过观察可以明显发现,B 和 D 的图像质量已经较为清晰,且明显高于 A 和 C,所以说明粗检焦具有良好的性能,可以快速找到离焦图像所在的区间。

图 11 描述了以上两种情况在到达粗焦面后精检焦的过程。图 11(a)首先利用清晰度评价函数对图 10(a)中的 B 进行评价,然后利用搜索算法将位移台正向移动 1 μm ,获得子图 1 后再对其进行评价,对比两次评价结果说明搜索方向不正确。此时将位移台反向移动 2 μm ,得到子图 2 并对其进行评价,结果大于子图 B 的清晰度值,说明搜索方向正确,则继续沿此方向进行搜索。直到对子图 4 进行评价后,发现子图 3 的清晰度值最高,则表明在位移台的精度范围内,采集子图 3 时基片所处的位置为焦平面位置。同理,图 11(b)仅需 3 步就可以找到焦平面的位置。理论上在粗检焦正确的情况下,最多仅需 7 步就可以在粗检焦的基础上实现焦平面的准确定位。对焦平面采集到的图像放大观察细节可以清楚看到 DMD 中每一个反射镜反射的光点,表明此刻已经很好地实现了焦平面的检测。

粗精检焦实验结果能够很好地说明本方法在自动检焦方面的有效性,进一步将通过对比本方法在同一离焦距离下,不同检焦图案的结果来说明本方法的性能。表 6~7 分别表示了正离焦 28 μm 和负离焦 18 μm 的情况下,使用本文方法对图 2 中展示的三种图案进行检焦的性能对比。通过表中的数据可以看出在不同的离焦图案之间,本方法都能快速准确地找到焦平面的位置。本方法是基于对图像各像素灰度值进

表 6 28 μm 离焦情况下不同图案的检焦性能对比

Table 6 Comparison of focus detection performance of different patterns at 28 μm out of focus

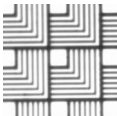





Focus check graphics	Coarse check focus results	Time for coarse focus checks /ms	Steps used for precision focus checks	Total time for precision focus checks /ms
	Grade 3 positive defocus 78.6%	93.7	5	148.6
	Grade 3 positive defocus 73.5%	93.7	5	145.5
	Grade 3 positive defocus 61.8%	93.7	5	147.2

表 7 -18 μm 离焦情况下不同图案的检焦性能对比

Table 7 Comparison of focus detection performance of different patterns at -18 μm out of focus

Focus check graphics	Coarse check focus results	Time for coarse focus checks/ms	Steps used for precision focus checks	Total time for precision focus checks/ms
	Grade 2 negative defocus 68.4%	93.7	4	123.6
	Grade 2 negative defocus 88%	93.7	4	123.3
	Grade 2 negative defocus 76%	93.7	4	125.6

行的计算,其检焦速度不会因检焦图案的变化而发生剧烈变化,并且对于同一幅离焦图像而言,其检焦的结果也具有很好的可重复性。

为了测量本方法的检焦精度,首先找到最佳成像的基片位置,并将此时刻位移台的垂向坐标作为标准焦平面坐标。然后在 $(-40\ \mu\text{m}, 40\ \mu\text{m})$ 的区间内随机选取20个位置,采用不同的检焦图案进行测试,计算粗检焦得到的检测焦平面与标准焦平面之间的误差,以及在粗检焦基础上进行精检焦得到的检测焦平面与标准焦平面之间的误差。表8统计了20次检焦过程中,粗、精检焦误差出现在各个误差范围中的次数。可以看出粗检焦的最大误差为 $7\ \mu\text{m}$,即仅通过一步就能将 $(-40\ \mu\text{m}, 40\ \mu\text{m})$ 的离焦区间缩小至 $(-7\ \mu\text{m}, 7\ \mu\text{m})$ 的离焦区间内,而精检焦能够很好地弥补粗检焦精度不高的缺点,其最大检焦误差仅为 $2\ \mu\text{m}$ 。选取最终检焦误差的最大值 $2\ \mu\text{m}$ 作为本方法的检焦精度,根据焦深公式可以计算得到本系统的焦深为 $8\ \mu\text{m}$,因此使用本方法能够将基片准确地移动到聚焦物镜的焦深范围之内。

表8 粗检焦和精检焦在20次测试中检焦误差的统计结果
Table 8 Results of the coarse and precise focus detection errors in 20 tests

Focal plane detection error/ μm	Number of times each error occurs in the coarse check focus	Number of times each error occurs in the precision check focus
0	1	2
± 1	3	15
± 2	4	3
± 3	3	0
± 4	2	0
± 5	3	0
± 6	1	0
± 7	3	0

4 结论

为了保证检焦精度,本文提出了一种基于深度学习的自动检焦方法,通过调节光路简化光刻系统,使CCD与DMD共轭,在曝光过程中实时观察曝光状态,利用深度学习模型结合基于图像处理的检焦方法,分粗检焦和精检焦两个阶段,仅根据CCD采集的图像就实现焦平面的检测。本方法在粗检焦阶段虽然有一定的几率对离焦区间产生误判,但是根据仿真结果可以发现误判区间的偏离程度不大,此误差可以在精检焦的过程中通过搜索算法进行修正,最终找到焦平面。设计光刻系统的焦深为 $8\ \mu\text{m}$ 左右,实验结果表明:本方法能够在300 ms内完成 $(-40\ \mu\text{m}, 40\ \mu\text{m})$ 离焦范围内的检焦,检焦精度可达 $2\ \mu\text{m}$,能够满足系统对检焦精度和速度的需求,可以很好地应用于数字光刻领域。

参考文献

- [1] BERTSCH A, LORENZ H, RENAUD P. 3D microfabrication by combining microstereolithography and thick resist UV lithography[J]. Sensors and Actuators A: Physical, 1999, 73(1-2):14-23.
- [2] JONUSAUSKAS L, BARAVYKAS T, ANDRIJEC D, et al. Stitchless support-free 3D printing of free-form micromechanical structures with feature size on-demand[J]. Scientific Reports, 2019, 9:1-12.
- [3] FONG J T, WINTER T W, JACOBS S J. Advances in DMD-based UV application reliability below 320nm [J]. International Society for Optics and Photonics, 2010:763718.
- [4] WANG Jian. Study on high precision measurement technology of wafer focus based on polarization modulation [D]. Chengdu: Institute of Optics and Electronics, Chinese Academy of Sciences, 2021:7-10.
王建. 基于偏振调制的高精度焦面检测技术研究[D]. 成都:中国科学院光电技术研究所, 2021:7-10.
- [5] SUN Yuwen, LI Shiguang, ZONG Mingcheng. Nanoscale focusing and leveling measurement technology based on optical spatial split[J]. Acta Optica Sinica, 2016, 36(5):0512002.
孙裕文, 李世光, 宗明成. 基于空间分光的纳米级调焦调平测量技术[J]. 光学学报, 2016, 36(5):0512002.
- [6] WITTEKOEK S, BRINK M, LINDERS H F, et al. Deep-UV wafer stepper with through-the-lens wafer to reticle alignment[C]. SPIE, 1990, 1264:534-547.
- [7] WERF J. Optical focus and level sensor for wafer steppers [J]. Journal of Vacuum Science and Technology B: Microelectronics and Nanometer Structures Processing, Measurement, and Phenomena, 1992, 10(2):735-740.

- [8] FENG Jinhua, TANG Yan, XIE Zhongye, et al. Coaxial focusing method based on differential modulation evaluation[J]. *Acta Optica Sinica*, 2021, 41(6):0612001.
冯金花, 唐燕, 谢仲业, 等. 基于差动调制度解析的同轴检焦方法[J]. *光学学报*, 2021, 41(6):0612001.
- [9] PAN Ping. Study on differential astigmatism detection technology [D]. Harbin: Harbin Institute of Technology, 2010:1-5.
潘萍. 差动像散离焦检测技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2010:1-5.
- [10] LIANG Fengcha. Static characteristics of auto-focusing servo system based on critical angle method for laser direct writing [J]. *Electronics Optics & Control*, 2011, 18(5):59-62.
梁凤超. 临界角法激光直写聚焦伺服系统静态特性研究[J]. *电光与控制*, 2011, 18(5):59-62.
- [11] ZONG Yonghong, ZHOU Changhe, MA Jianyong, et al. Optimized design of leveling and focusing servo control system [J]. *Acta Optica Sinica*, 2017, 37(1):0122001.
宗永红, 周常河, 麻健勇, 等. 调平聚焦伺服控制系统的优化设计[J]. *光学学报*, 2017, 37(1):0122011.
- [12] WANG Guanjun. Research on auto-focusing method of photoelectric measurement equipmet based on image processing [D]. Changchun: Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, 2016:100-104.
王冠军. 基于图像处理的光电测量设备自动调焦方法研究[D]. 长春: 中国科学院长春光学精密机械与物理研究所, 2016:100-104.
- [13] YANG S J, BERNDL M, ANDO D M, et al. Assessing microscope image focus quality with deep learning[J]. *BMC Bioinformatics*, 2018, 19(1):77.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[J]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2016:770-778.
- [15] SUN Jie, YUAN Yuehui, WANG Chuanyong. Comparison and analysis of algorithms for digital image processing in autofocusing criterion[J]. *Acta Optica Sinica*, 2007, 27(1):35-39.
孙杰, 袁跃辉, 王传永. 数字图像处理自动图像聚焦算法的分析和比较[J]. *光学学报*, 2007, 27(1):35-39.

Deep Learning Based Method for Automatic Focus Detection in Digital Lithography

YANG Jupu^{1,2}, DU Jialin^{1,2}, LI Fanxing¹, CHEN Qingrong¹, WANG Simo^{1,2}, YAN Wei¹

(1 *Institute of Environmental Optics, Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu 610209, China*)

(2 *University of Chinese Academy of Sciences, Beijing 100049, China*)

Abstract: Digital lithography based on digital micromirror array devices is one of the methods for the production of micro and nano structures, with the advantages of low cost and high flexibility, and has great advantages in micro and nano processing. As the demand for higher resolution of micro and nano structures increases, the wavelengths of lithography systems are getting shorter and the numerical apertures are getting larger, which leads to shorter and shorter exposure depths of focus. To ensure the quality of lithography patterns, the substrate must be within the depth of focus, so fast and high precision inspection of the focal plane becomes the key to the production of high resolution micro and nano structures. Most of the traditional methods require a separate design of the focus detection system, which will not only increase the complexity of the whole system structure but also increase the difficulty of mounting. With the growing development of image processing technology, focusing methods do not require complex optical path adjustment and can achieve focal plane detection based on out-of-focus images only, and the methods have been applied to many fields. Inspired by this, this paper proposes a deep learning based focus detection method, by adjusting the optical path of digital lithography so that the exposure focal plane and the camera imaging focal plane coincide, at this time the image captured by the CCD is the exposure pattern on the exposure focal plane, the blurred degree of the image directly reflects the out-of-focus degree of the exposure pattern, so the focal plane can be quickly and automatically detected using the algorithm only based on the currently formed image. The focus detection algorithm proposed in this study consists of two steps, firstly a coarse focus detection of the substrate at a large out-of-focus distance to reduce the out-of-focus range of the substrate, and then a further improvement of the focus detection accuracy at a small out-

of-focus distance. According to the characteristics of these two focusing steps, a deep learning model is used for detection in the coarse focusing and a conventional sharpness evaluation function combined with a search algorithm is used for detection in the precise focusing. Different out-of-focus ranges are firstly classified according to the out-of-focus distance, and corresponding training and test datasets are produced. The trained network can achieve 88.7% accuracy on the test set, and it only takes 90 ms to determine the current out-of-focus range of the substrate, and then move the displacement table to move the substrate to the focal plane. Compared to conventional methods, this avoids the need for a round trip movement of the displacement stage, thus reducing the impact of return errors on focus detection accuracy. The evaluation performance and evaluation speed of different sharpness evaluation functions were also compared using out-of-focus image data. The Laplacian function is chosen as the image sharpness evaluation function for precision focus detection. Using this function, the sharpness value of an image can be calculated in only 5 ms and combined with the search algorithm to find the position with the highest sharpness value near the focal plane, the focal plane can be found accurately in 7 steps on the basis of coarse focus detection. Simulation and experimental validation results show that although the method has a certain chance of error in the coarse focusing stage, the misjudged out-of-focus range is small and can be corrected by the search algorithm in the precise focusing stage to find the true focal plane. In the end, the method can be used with a $5\times$ focusing objective and the focusing accuracy can reach $2\ \mu\text{m}$ in the out-of-focus range of $(-40\ \mu\text{m}, 40\ \mu\text{m})$ with a total time of less than 300 ms. In summary, the method has the advantages of low structural complexity, fast focusing speed, and high focusing accuracy, can be well applied in the field of digital lithography.

Key words: Digital lithography; Automatic focusing; Deep learning; Image processing

OCIS Codes: 110.5220; 110.3000; 100.4996; 110.4155