

极紫外光刻掩模相位型缺陷检测方法

成维^{1,2}, 李思坤^{1,2*}, 王向朝^{1,2**}¹中国科学院上海光学精密机械研究所信息光学与光电技术实验室, 上海 201800;²中国科学院大学材料与光电研究中心, 北京 100049

摘要 提出了一种基于空间像的极紫外光刻掩模相位型缺陷检测方法,用于检测多层膜相位型缺陷的类型、位置和表面形貌。缺陷的类型、位置和表面形貌均会影响含缺陷掩模的空间像的分布。因此,采用深度学习模型构建含缺陷掩模的空间像与待测缺陷信息之间的映射,利用训练后的模型可从含缺陷掩模的空间像中获取待测缺陷信息。采用卷积神经网络(CNN)模型构建含缺陷空白掩模的空间像和缺陷类型与位置之间的关系,建立用于缺陷类型和位置检测的CNN模型。在获取缺陷的类型与位置后,基于测得的缺陷位置对空间像进行截取,利用截取后的空间像的频谱信息和多层感知机模型获取缺陷表面形貌参数。仿真结果表明,所提方法可对多层膜相位型缺陷的类型、位置和表面形貌参数进行准确检测。

关键词 测量; 光刻; 极紫外光刻; 掩模缺陷检测; 空间像; 深度学习

中图分类号 TN305.7 **文献标志码** A

DOI: 10.3788/AOS221209

1 引言

随着极紫外(EUV)光刻技术的发展和摩尔定律的不断延续,EUV光刻机已被用于量产技术节点为7 nm及以下的芯片^[1-2]。随着芯片技术节点的减小,EUV掩模的结构越来越复杂,对成像质量的影响也在逐渐增大^[3]。EUV掩模缺陷尤其是多层膜缺陷,会导致掩模成像质量降低,是影响EUV光刻良率的重要问题之一^[4]。多层膜缺陷可分为振幅型缺陷与相位型缺陷:振幅型缺陷位于多层膜接近顶层处,主要影响多层膜反射场的振幅;相位型缺陷分布于多层膜内部,引起多层膜变形,同时影响多层膜反射场的振幅与相位^[5-6]。相较于振幅型缺陷,相位型缺陷对掩模成像的影响更复杂且难以修复^[7]。由于EUV光刻的曝光波长短,故尺寸仅为纳米量级的相位型缺陷可使掩模衍射谱产生明显的相位变化,降低成像质量^[8]。为提高含缺陷掩模的成像质量,常采用掩模图形偏移规划技术与掩模修正技术等缺陷补偿方法降低缺陷造成的成像质量损失^[9]。对相位型缺陷的类型(凸起型或凹陷型)、所处位置和表面形貌进行准确检测对分析缺陷的影响和有效补偿缺陷具有重要意义^[10-11]。

在采用低放大率高速检测方式将掩模缺陷检出后,需要对缺陷区域进行进一步检测以获取更详细的缺陷信息。Lasertec公司的EUV空白掩模检测设备

(ABI)的1200倍高放大率模式可提供高分辨率的含缺陷掩模区域的图像^[12]。Suzuki等^[13]提出了一种基于ABI获取不同焦面的高分辨率含缺陷掩模图像的缺陷类型检测方法,通过分析含缺陷掩模成像的最佳焦面位置确定缺陷类型。在ABI的高放大率暗场成像模式^[14]中,照射在掩模上的光中心主入射角为 0° ,获取的高分辨率暗场成像图像适用于相位型缺陷的精确定位。Amano等^[15]证明了ABI获取的缺陷信号强度(DSI)与相位型缺陷的体积有关,但通过分析ABI获取的DSI仍难以得到缺陷的形貌信息。原子力显微镜(AFM)可对缺陷的表面形貌进行准确测量^[6],但需要先获取缺陷的准确位置且耗时较长。采用模型建立空间像与待测缺陷信息之间的关系,可从含缺陷掩模的空间像中获取待测缺陷信息。研究人员提出了多种基于空间像获取缺陷形貌信息的方法。Xu等^[16]提出了一种基于空间像的缺陷三维形貌检测方法。该方法采用神经网络构建空间像振幅和相位信息与缺陷形貌参数之间的关系,建立了可用于获取缺陷形貌参数的模型。Chen等^[17]提出了一种采用循环一致性学习的基于空间像的缺陷三维形貌检测方法,提高了检测精度。本课题组进一步改进了基于空间像的缺陷三维形貌检测方法^[18],利用空间像的振幅和相位信息与空洞残差网络获取缺陷形貌参数。然而,上述基于空间像的缺陷形貌检测方法都需要在缺陷类型已知且缺陷

收稿日期: 2022-05-27; 修回日期: 2022-06-13; 录用日期: 2022-06-20; 网络首发日期: 2022-06-30

基金项目: 国家自然科学基金(U22A2070)、国家科技重大专项(2017ZX02101004-002)

通信作者: *lisikun@siom.ac.cn; **wxz26267@siom.ac.cn

位于掩模测量区域的中心时使用,即需要采用额外的方法准确地检测缺陷的类型与位置。

提出了一种基于空间像的 EUV 光刻掩模相位型缺陷检测方法,可利用一次测得的含缺陷掩模的空间像获取缺陷的类型、位置和表面形貌参数。采用卷积神经网络(CNN)^[19]模型构建缺陷类型和位置与含缺陷掩模的空间像之间的关系,建立用于缺陷类型和位置检测的 CNN 模型。基于 CNN 模型获取的缺陷位置坐标对空间像进行截取,采用多层感知机(MLP)^[20]模型构建缺陷表面形貌参数和截取的空间像的低通频谱信息之间的关系,建立用于缺陷表面形貌参数检测的 MLP 模型。利用训练后的 CNN 模型和 MLP 模型从含缺陷掩模的空间像中获取缺陷的类型、位置和表面形貌参数。

2 理论模型

2.1 含缺陷掩模的空间像的仿真方法

典型的含相位型缺陷的空白掩模如图 1 所示。其中,图 1(a)为含凸起型缺陷的空白掩模示意图,图 1(b)为含凹陷型缺陷的空白掩模示意图,多层膜相位型缺陷由高斯型缺陷模型表征。虽然实际中引起多层膜变形的缺陷形貌各异,但是由于在缺陷上最先沉积的数层多层膜可以平滑缺陷的不规则性从而使得缺陷导

致的多层膜变形具有较平滑的分布,故高斯型缺陷模型可以有效地表征缺陷形貌^[21]。采用缺陷表面高度 h_{top} 和缺陷表面半峰全宽(FWHM) ω_{top} 表征缺陷表面形貌,采用缺陷底部高度 h_{bot} 和缺陷底部半峰全宽 ω_{bot} 表征缺陷底部形貌。根据缺陷表面和底部的形貌参数,以及缺陷所处的位置,含缺陷的空白掩模表面与底部的形貌分布的计算公式为

$$z_{\text{top}} = h_{\text{top}} \exp\left[g \frac{(x - x_{\text{pos}})^2}{\omega_{\text{top}}^2}\right] \exp\left[g \frac{(y - y_{\text{pos}})^2}{\omega_{\text{top}}^2}\right], \quad (1)$$

$$z_{\text{bot}} = h_{\text{bot}} \exp\left[g \frac{(x - x_{\text{pos}})^2}{\omega_{\text{bot}}^2}\right] \exp\left[g \frac{(y - y_{\text{pos}})^2}{\omega_{\text{bot}}^2}\right], \quad (2)$$

式中: g 为高斯形貌调制因子; $(x_{\text{pos}}, y_{\text{pos}})$ 为当掩模中心为原点时缺陷的位置坐标; z_{top} 和 z_{bot} 分别为含缺陷的空白掩模在 (x, y) 处的表面和底部的高度分布。多层膜缺陷表面与底部之间的多层膜形变可根据缺陷的压缩情况计算^[22],无缺陷掩模中 Mo/Si 双层膜的厚度为 6.95 nm (Mo 层的厚度为 2.78 nm, Si 层的厚度为 4.17 nm),当被压缩的 Mo/Si 双层膜总层数为 N_{cp} 时,第 k 层 Mo/Si 双层膜的厚度 T_k 为

$$T_k = 6.95 + 2(z_{\text{bot}} - z_{\text{top}}) \times \left[\frac{k}{N_{\text{cp}}(N_{\text{cp}} + 1)} - \frac{1}{N_{\text{cp}}} \right], \quad (3)$$

$$k = 1, 2, 3, \dots, N_{\text{cp}}$$




图 1 含缺陷的空白掩模的示意图。(a)凸起型缺陷;(b)凹陷型缺陷

Fig. 1 Schematic diagram of defective mask blanks. (a) Bump defect; (b) pit defect

将 EUV 光刻成像系统视为部分相干成像系统,含缺陷掩模的空间像可通过 Abbe 成像公式^[22]计算,即

$$I(\hat{x}, \hat{y}) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} J(\hat{f}, \hat{g}) \left\{ \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} H(\hat{f} + \hat{f}', \hat{g} + \hat{g}') O(\hat{f}', \hat{g}') \exp[-j2\pi(\hat{x}\hat{f}' + \hat{y}\hat{g}')] d\hat{f}' d\hat{g}' \right\}^2 d\hat{f} d\hat{g}, \quad (4)$$

式中: (\hat{x}, \hat{y}) 为归一化的像方空间坐标; $I(\hat{x}, \hat{y})$ 为空间像强度分布; (\hat{f}, \hat{g}) 为归一化的光瞳面空间频率坐标; $J(\hat{f}, \hat{g})$ 为光源强度分布; $H(\hat{f}, \hat{g})$ 为投影物镜的光瞳函数; (\hat{f}', \hat{g}') 为归一化的掩模衍射光空间频率坐标; $O(\hat{f}', \hat{g}')$ 为掩模衍射谱。本论文采用严格耦合波分析法(RCWA)^[23]仿真计算含缺陷掩模的衍射谱 $O(\hat{f}', \hat{g}')$ 。

当空白掩模不含缺陷时,照射在空白掩模上的光以相同的反射率被反射,理想无缺陷空白掩模的空间像强度为常数值。相位型缺陷会导致多层膜的膜层分布发生变化,影响掩模衍射谱的振幅与相位,从而对掩模空间像造成影响。不同缺陷的类型、位置和形貌对掩模空间像的影响也不同。

2.2 相位型缺陷检测方法

在采用低放大率高速检测方式将掩模相位型缺陷检出后,需要对缺陷区域进行进一步检测,基于缺陷所

在区域的空间像获取相位型缺陷的类型、位置和表面形貌信息。当测得缺陷在所测掩模区域的相对位置后,可根据缺陷所处区域内基准标记的坐标获取缺陷在掩模上的具体位置。文中含缺陷掩模的空间像均指掩模缺陷所在区域的空间像。缺陷的类型、位置和表面形貌均会影响含缺陷掩模的空间像分布,采用深度

学习模型构建含缺陷掩模空间像与待测缺陷信息之间的映射,利用训练后的模型可从含缺陷掩模的空间像中获取待测缺陷信息。所提的基于空间像的相位型缺陷检测方法的流程图如图 2 所示。所提方法可分为两个阶段:1)对多层膜相位型缺陷的类型与位置进行检测;2)对缺陷的表面形貌进行检测。

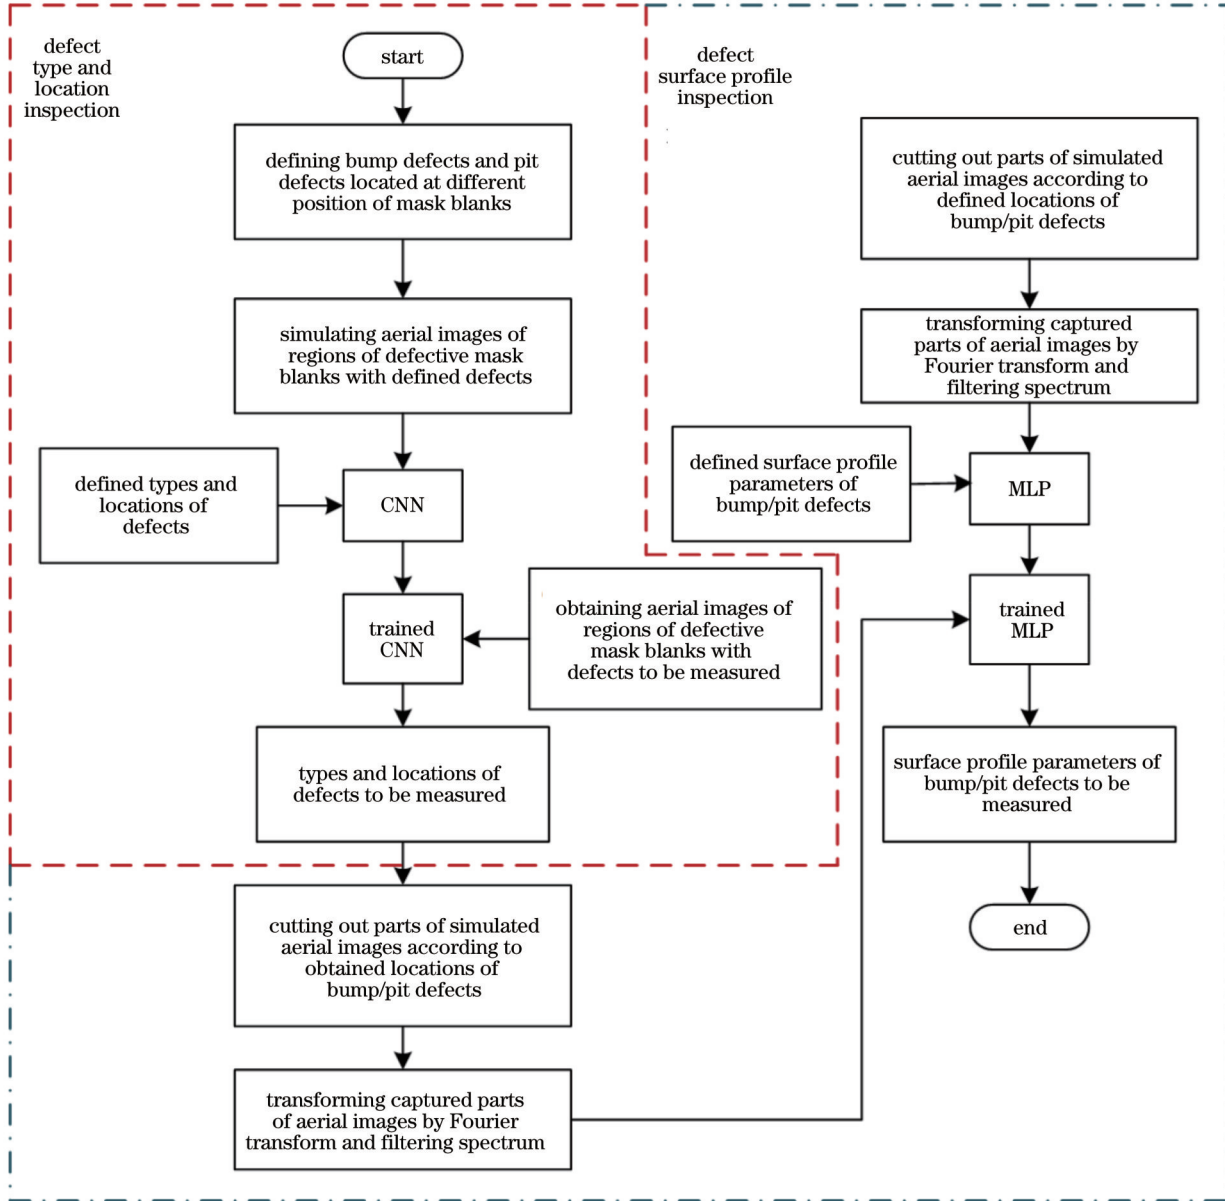


图 2 基于空间像的相位型缺陷检测流程图

Fig. 2 Flow chart for inspection of phase defects based on aerial images

在缺陷类型与位置检测阶段,由于 CNN 具有优异的特征选取能力^[19],可自动提取空间像特征,故采用 CNN 模型建立含缺陷掩模的空间像与缺陷的类型和位置之间的关系。缺陷的类型由缺陷类型因子 f_c 表征,缺陷位置由掩模中心为原点时缺陷中心的位置坐标 (x_{pos}, y_{pos}) 表征。为使训练时设置的学习率对缺陷类型因子与位置参数的回归均有效,将缺陷类型因子与位置参数均调整至 $(0, 1]$ 范围内:当缺陷为凸起型缺

陷时,将 f_c 设为 0.5;当缺陷为凹陷型缺陷时,将 f_c 设为 1.0。生成不同类型、位于掩模不同位置、具有不同缺陷形貌参数 $(h_{top}, \omega_{top}, h_{bot}, \omega_{bot})$ 的相位型缺陷,仿真获取含定义的相位型缺陷的空白掩模空间像。将仿真的含缺陷空白掩模的空间像、对应的缺陷类型因子 f_c 和缺陷中心的位置坐标 (x_{pos}, y_{pos}) 组合作为 CNN 模型的训练集对 CNN 模型进行训练以获取训练后的 CNN 模型,其中空间像为 CNN 模型的输入, f_c 和 (x_{pos}, y_{pos}) 为

CNN模型的输出。将含待测缺陷空白掩模的空间像输入训练后的CNN模型中可输出该待测缺陷的缺陷类型因子 f'_c 和缺陷中心的位置坐标 (x'_{pos}, y'_{pos}) :当 $|f'_c - 0.5| \leq |f'_c - 1.0|$ 时,待测缺陷为凸起型缺陷;当 $|f'_c - 0.5| > |f'_c - 1.0|$ 时,待测缺陷为凹陷型缺陷。

在获取缺陷的类型和位置后,在缺陷表面形貌检测阶段,利用已知的缺陷类型和位置信息对含缺陷掩模的空间像进行预处理以提高检测精度。对两种不同类型的缺陷(凸起型缺陷和凹陷型缺陷)分别建立用于检测缺陷表面形貌参数的MLP模型。根据获取的缺陷位置对含缺陷掩模的空间像进行截取。由于缺陷的位置检测存在误差,故按照获取的位置坐标进行截取的空间像与按照实际位置坐标进行截取的空间像之间可能存在偏移。图像的频谱振幅对图像偏移不敏感,对截取的空间像进行傅里叶变换以获取截取的空间像的频谱振幅。在空间像成像过程中,光瞳函数对掩模衍射谱有低通滤波作用,空间像的大部分有效信息集中在低频部分。所提方法截取空间像频谱中以0级频谱为中心的 5×5 频谱区域,并展平为25个元素,作为MLP模型的输入。以表征缺陷表面形貌的缺陷表面形貌参数(缺陷表面高度 h_{top} 和缺陷表面半峰全宽 ω_{top})作为MLP模型的输出。将缺陷类型与位置检测阶段训练集中的含缺陷空白掩模的空间像按照不同缺陷类型分为两部分。将含缺陷空白掩模的空间像对应的缺陷位置坐标从掩模面的坐标 (x_{pos}, y_{pos}) 转化为像面坐标 $(\hat{x}_{pos}, \hat{y}_{pos})$,截取空间像上以 $(\hat{x}_{pos}, \hat{y}_{pos})$ 为中心、边长为原空间像边长1/2的部分组成截取空间像标准集。对于含待测缺陷掩模的空间像,将在缺陷类型与

位置检测阶段输出的待测缺陷的位置坐标 (x'_{pos}, y'_{pos}) 转化为像面坐标 $(\hat{x}'_{pos}, \hat{y}'_{pos})$,截取空间像上以 $(\hat{x}'_{pos}, \hat{y}'_{pos})$ 为中心、边长为原空间像边长1/2的部分。分别采用截取的含凸起型/凹陷型缺陷掩模的空间像标准集的低通频谱振幅与相应的缺陷表面形貌参数作为训练集,对用于凸起型/凹陷型缺陷表面形貌参数检测的MLP模型进行训练。按照缺陷的类型与位置检测阶段获取的位置坐标截取含待测缺陷的空间像,将截取的空间像的低通频谱振幅输入与获取缺陷类型相应的训练后的MLP模型中,以输出缺陷表面形貌参数。

用于缺陷类型和位置检测的CNN模型如图3所示。将卷积层、批标准化(BN)层、激活函数和最大池化层作为一个卷积单位,采用的CNN模型由5个卷积单位、1个展平层和2个全连接(FC)层组成。卷积层的作用是特征提取,第一个卷积层中含有32个大小为 7×7 的卷积核,第二个卷积层和第三个卷积层中均含有32个大小为 5×5 的卷积核,第四个卷积层和第五个卷积层中均含有64个大小为 3×3 的卷积核。批标准化层^[24]将卷积层的输出进行标准化以缓解梯度弥散和梯度爆炸,加速网络的收敛。激活函数的作用是加入非线性因素,采用的激活函数为整流线性单元(ReLU)函数。最大池化层的作用是对输出进行下采样,降低待处理数据的数量。为了将卷积单位提取到的含缺陷掩模的空间像的特征映射到缺陷类型因子 f_c 和缺陷中心的位置坐标为 (x_{pos}, y_{pos}) 的标记空间中,先采用展平层将卷积单位的输出展平为一维数据,再采用全连接层建立空间像特征与模型输出 $[f_c, (x_{pos}, y_{pos})]$ 之间的联系,采用的两层全连接层分别含有100个神经元和50个神经元,采用的激活函数同样为ReLU函数。

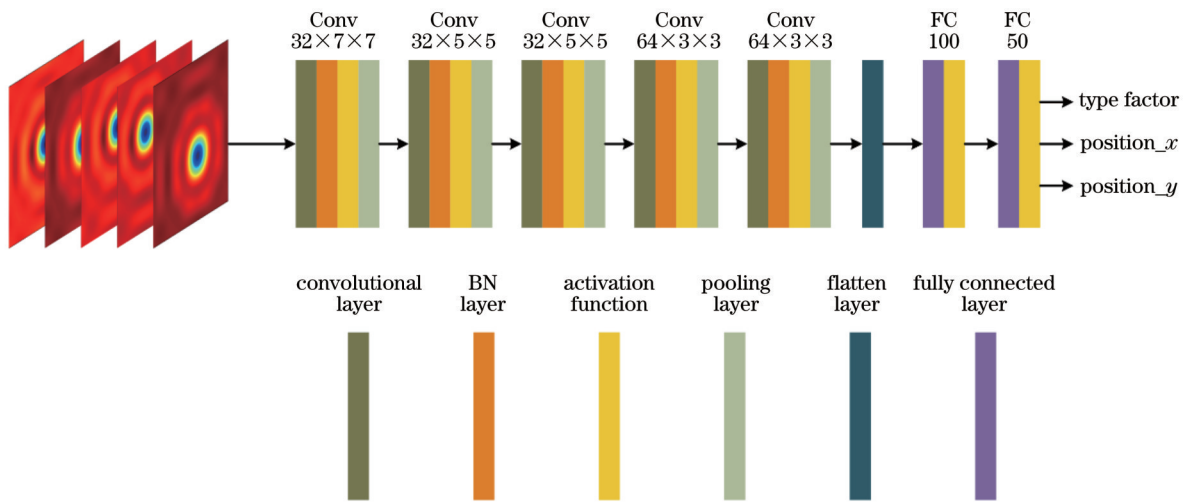


图 3 基于卷积神经网络的缺陷类型与位置检测示意图

Fig. 3 Schematic diagram of inspection for defect type and location based on convolutional neural network

用于缺陷表面形貌参数检测的 MLP 模型如图 4 所示,检测凸起型缺陷与凹陷型缺陷表面形貌参数的模型结构一致,采用的训练集不同。MLP 模型由输入层、4 层含 80 个神经元的隐藏层和输出层组成,各层中采用的激活函数均为 ReLU 函数。由于实际空间像大

小可能与本文不同,可根据实际情况在训练过程中对 CNN 模型和 MLP 模型的结构进行调整。MLP 模型的输入为根据缺陷位置坐标截取的空间像的低通频谱振幅,输出为缺陷表面高度 h_{top} 和缺陷表面半峰全宽 ω_{top} 。




图 4 基于 MLP 的缺陷表面形貌参数检测示意图

Fig. 4 Schematic diagram of inspection for defect surface profile parameters based on MLP

3 仿真结果与分析

3.1 含缺陷掩模的空间像的仿真

所采用的含缺陷掩模的空间像的仿真方法如 2.1 节所述,成像仿真的参数设定如表 1 所示。空间像测量设备采用和 EUV 光刻机相同的 13.5 nm 光源波长、相似的照明条件和相同的物方数值孔径 $NA_{\text{obj}} = 0.0825$ 来模拟 EUV 光刻机成像^[25],其图像分辨率与

空间像测量设备的缩放倍率和图像传感器电荷耦合器件 (CCD) 的分辨率有关,缩放倍率的设定不影响空间像的分布。本文采用缩放倍率为 1 来仿真计算空间像,实际中可根据采用的空间像测量设备的缩放倍率来计算空间像。将含缺陷的空白掩模的周期设定为 480 nm (掩模面尺寸)。光源设定为中心主入射角为 6° 的环形照明光源,内部相干因子 σ_{in} 为 0.6,外部相干因子 σ_{out} 为 0.8,偏振态为 Y 方向偏振。

表 1 成像仿真参数设定

Table 1 Parameter setting for imaging simulation

Simulation object	Submodule	Description
Optics	Illumination	Wavelength: 13.5 nm; chief ray angle: 6° ; annular source; $\sigma_{\text{in}} = 0.6$; $\sigma_{\text{out}} = 0.8$
	Projection	$NA_{\text{obj}} = 0.0825$
Mask	Multilayer	40 pairs of Mo/Si bilayers; Mo thickness: 2.78 nm; Si thickness: 4.17 nm; refractive index of Mo: 0.9238–0.0064j; refractive index of Si: 0.9990–0.0018j
	Substrate	SiO ₂ thickness: 30 nm; refractive index of SiO ₂ : 0.9260–0.0436j

表 2 中定义了 6 种具有不同缺陷参数的含缺陷的空白掩模,其中掩模 A、B、C 为含凸起型缺陷的掩模,掩模 D、E、F 为含凹陷型缺陷的掩模。缺陷的位置坐标 $(x_{\text{pos}}, y_{\text{pos}})$ 与形貌参数 $(h_{\text{top}}, \omega_{\text{top}}, h_{\text{bot}}, \omega_{\text{bot}})$ 如表 2 所示。缺陷参数不同的含缺陷空白掩模的空间像如图 5

所示,图 5(a)~(f) 分别对应掩模 A~F 的空间像,缺陷导致的强度损失最大处坐标分别为 $(-5, -1)$ 、 $(-7, -1)$ 、 $(33, 40)$ 、 $(5, -1)$ 、 $(0, -1)$ 、 $(40, 39)$ 。在掩模 A、B、D、E 中缺陷均位于掩模中心位置,但由图 5(a)、(b)、(d)、(e) 可知缺陷导致的强度损失最大处均不位

于空间像的中心。由于 EUV 光刻采用斜入射光照明,故掩模在成像过程中存在图形偏移。对于含缺陷的掩模,缺陷造成的强度损失也存在一定的偏移,掩模的缺陷位置难以从空间像的光强分布中直接获取。掩模 A 和掩模 B、掩模 D 和掩模 E 分别为缺陷位于掩模中心但形貌不同的含凸起型缺陷的掩模与含凹陷型缺陷的掩模。由图 5(a)、(b)、(d)、(e) 的对比可知,当缺陷处于相同位置但形貌和类型不同时,强度损失最大处的偏移量也不同,故难以直接提前计算偏移量。对比图 5(a) 和图 5(b)、图 5(d) 和图 5(e) 可知,当缺陷的形貌不同时,空间像的强度分布不同,缺陷导致的强度损失大小不同。掩模 B 和掩模 C、掩模 E 和掩模 F 分别为缺陷形貌相同但所处位置不同的含凸起型缺陷的掩模与含凹陷型缺陷的掩模。对比图 5(b) 和图 5(c)、图 5(e) 和图 5(f) 可知,形貌相同的缺陷导致的空间像的强度损失大小相似,位置会随缺陷位置的移动而移动。掩模 A~C 为含凸起型缺陷的掩模,掩模 D~F 为含凹

陷型缺陷的掩模,对比图 5(a)~(c) 和图 5(d)~(f) 可知,当凸起型缺陷与凹陷型缺陷所处位置相同,且 $|h_{\text{top}}| = |h_{\text{bot}}|$ 、 $\omega_{\text{top}} = \omega_{\text{bot}}$ 相等时,不同类型的缺陷导致的空间像的强度损失大小不同,且强度损失偏移量也不同。由图 5 可知,当缺陷的类型、位置和形貌不同时,缺陷造成的掩模空间像的强度损失分布不同。

表 2 不同含缺陷的掩模的参数设定

Table 2 Parameter setting of different defective masks

Mask	x_{pos}	y_{pos}	unit: nm			
			h_{top}	ω_{top}	h_{bot}	ω_{bot}
Mask A	0	0	2	30	10	20
Mask B	0	0	4	35	15	25
Mask C	40	40	4	35	15	25
Mask D	0	0	-2	30	-10	20
Mask E	0	0	-4	35	-15	25
Mask F	40	40	-4	35	-15	25




图 5 缺陷参数不同的含缺陷空白掩模的空间像。(a)掩模 A;(b)掩模 B;(c)掩模 C;(d)掩模 D;(e)掩模 E;(f)掩模 F

Fig. 5 Aerial images of defective mask blanks with different defect parameters. (a) Mask A; (b) mask B; (c) mask C; (d) mask D; (e) mask E; (f) mask F

3.2 缺陷类型与位置检测

含缺陷掩模的空间像与缺陷的类型和所处的位置紧密相关,采用 CNN 模型建立空间像与缺陷的类型和位置之间的映射关系。缺陷类型与位置检测流程如图 2 所示,采用的 CNN 模型如图 3 所示,该模型的总参数量为 1.60×10^6 ,总浮点运算数量为 $2.79 \times 10^9 \text{ s}^{-1}$ 。本文中 CNN 模型和 MLP 模型的建立、训练与测试均在装备了 NVIDIA PCI-E Tesla V100 显卡的服务器上基于 PyTorch 框架^[26]完成。

为获取 CNN 模型的训练集与测试集,分别定义了 3200 个位于空白掩模不同位置、具有不同缺陷形貌参

数的凸起型缺陷和凹陷型缺陷,以生成缺陷参数不同的含缺陷的空白掩模,随机选取其中 128 个含凸起型缺陷的空白掩模和 128 个含凹陷型缺陷的空白掩模用于测试,其余 6144 个含缺陷的空白掩模用于训练。其中,凸起型缺陷的缺陷类型因子 f_c 为 0.5,凹陷型缺陷的缺陷类型因子为 1.0。将空白掩模的周期设定为 480 nm,缺陷的 x 方向位置坐标 x_{pos} 和 y 方向位置坐标 y_{pos} 在 $-120 \sim 120 \text{ nm}$ 之间随机取样。由于在含缺陷掩模的多层膜沉积过程中,底部的凸起或凹陷会被平滑,故缺陷的高度会减小、宽度会增加^[27]。为符合缺陷的

平滑特性,本文中限定缺陷的表面高度 $|h_{\text{top}}|$ 小于底部高度 $|h_{\text{bot}}|$,缺陷表面的半峰全宽 ω_{top} 大于底部的半峰全宽 ω_{bot} 。缺陷表面高度 $|h_{\text{top}}|$ 在 0.5~4.5 nm 之间以 0.5 nm 为最小间隔随机取样,缺陷底部高度 $|h_{\text{bot}}|$ 在 5~20 nm 之间以 0.5 nm 为最小间隔随机取样。凸起型缺陷的 h_{top} 和 h_{bot} 为正值,凹陷型缺陷的 h_{top} 和 h_{bot} 为负值。缺陷表面的半峰全宽 ω_{top} 在 10~40 nm 之间以 1 nm 为最小间隔随机取样,缺陷底部的半峰全宽 ω_{bot} 在 10~30 nm 之间以 1 nm 为最小间隔随机取样,且限定 ω_{bot} 小于 ω_{top} 。仿真获取定义的 6400 个含缺陷空白掩模的空间像,采用训练集中的 6144 个含缺陷空白掩模的空间像、对应的缺陷类型因子 f_c 、缺陷的 x 方向位置坐标 x_{pos} 和缺陷的 y 方向位置坐标 y_{pos} 对设计的 CNN 模型进行训练,训练时采用 Adam 优化算法^[28]优化权重,学习率初始值设为 0.002,并每隔 20 代减小 1/2,总迭代次数为 160。训练过程中将损失函数定义为平均绝对误差(MAE),即

$$E_{\text{MA}} = \frac{1}{m} \times \frac{1}{3} \sum_{i=1}^m \left[|f'_c - f_c| + |x'_{\text{pos}_i} - x_{\text{pos}_i}| + |y'_{\text{pos}_i} - y_{\text{pos}_i}| \right], \quad (5)$$

式中: $m=64$ 为批大小; $f_c, x_{\text{pos}_i}, y_{\text{pos}_i}$ 分别为第 i 个缺陷的缺陷类型因子、 x 方向位置坐标和 y 方向位置坐标的标准值; $f'_c, x'_{\text{pos}_i}, y'_{\text{pos}_i}$ 分别为第 i 个缺陷的缺陷类型因子、 x 方向位置坐标和 y 方向位置坐标的检测值。将 128 个含凸起型缺陷和 128 个含凹陷型缺陷的空白掩模的空间像输入训练后的 CNN 模型中,可获取相应的 $f'_c, x'_{\text{pos}}, y'_{\text{pos}}$ 。

测试组中前 128 个缺陷为凸起型缺陷,对应的缺陷类型因子为 0.5,后 128 个缺陷为凹陷型缺陷,对应的缺陷类型因子为 1.0,缺陷类型因子的检测结果如图 6 所示。可以发现,训练后的 CNN 模型可根据含缺陷掩模的空间像准确地分辨出测试集中多层膜相位型缺陷的类型。缺陷位置坐标的检测结果如图 7 所示,其中图 7(a)、(b)分别为凸起型缺陷的 x 方向位置坐标 x_{pos} 和 y 方向位置坐标 y_{pos} 的检测结果,图 7(c)、(d)分别为凹陷型缺陷的 x 方向位置坐标 x_{pos} 和 y 方向位置坐标 y_{pos} 的检测结果。为增强图像易读性,图 7 中 x_{pos} 和 y_{pos} 均按照从小到大的顺序排列,可以发现:检测凸起型缺陷的 x 方向位置坐标 x_{pos} 的 MAE 为 1.06 nm,检测凹陷型缺陷的 x_{pos} 的 MAE 为 1.70 nm;检测凸起型缺陷的 y 方向位置坐标 y_{pos} 的 MAE 为 0.51 nm,检测凹陷型缺陷的 y_{pos} 的 MAE 为 0.97 nm;检测两种缺陷的 x_{pos} 的 MAE 为 1.38 nm,检测两种缺陷的 y_{pos} 的 MAE 为 0.74 nm。综合检测缺陷位置坐标的 MAE 与图 7 可知,训练后的 CNN 模型可精确检测缺陷位置坐标,对 y_{pos} 的检测精度高于 x_{pos} ,对凸起型缺陷位置坐标

的检测精度高于凹陷型缺陷。

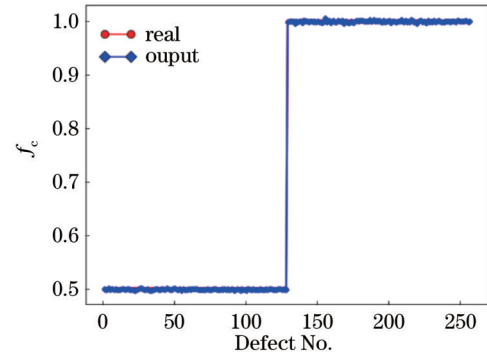


图 6 缺陷类型因子检测结果

Fig. 6 Inspection result of defect type factor

3.3 缺陷表面形貌参数检测

在获取缺陷的类型与位置后,采用图 4 所示的 MLP 模型对凸起型缺陷和凹陷型缺陷分别进行缺陷表面形貌参数检测,检测流程如图 2 所示。采用的 MLP 模型总参数量为 8.72×10^3 ,总浮点运算数量为 $2.136 \times 10^4 \text{ s}^{-1}$ 。将 CNN 训练集中的 6144 个含缺陷的空白掩模的空间像根据缺陷的位置坐标 $(x_{\text{pos}}, y_{\text{pos}})$ 截取空间像上以 $(\hat{x}_{\text{pos}}, \hat{y}_{\text{pos}})$ 为中心、边长为原空间像边长 1/2 的部分。在对图像进行傅里叶变换后获取其低频部分并展平,采用展平后的低通频谱、缺陷的表面高度 h_{top} 和缺陷的表面半峰全宽 ω_{top} 对设计的 MLP 模型进行训练。训练时采用 Adam 优化算法^[28]优化权重,学习率初始设为 0.004,并每隔 80 代减小 1/2,总迭代次数为 480。训练过程中将损失函数定义为均方误差(MSE),即

$$M_{\text{MSE}} = \frac{1}{m} \times \frac{1}{2} \sum_{i=1}^m \left[(h'_{\text{top}_i} - h_{\text{top}_i})^2 + (\omega'_{\text{top}_i} - \omega_{\text{top}_i})^2 \right], \quad (6)$$

式中: h_{top_i} 和 ω_{top_i} 分别为第 i 个缺陷的表面高度和半峰全宽的标准值; h'_{top_i} 和 ω'_{top_i} 分别为第 i 个缺陷的表面高度和半峰全宽的检测值。

测试集中含缺陷的掩模经定位后可根据获取的缺陷位置截取部分空间像图像,对图像进行傅里叶变换后获取其低频部分并展平,将展平后的低通频谱输入训练后的 MLP 模型中检测缺陷表面形貌参数,检测结果如图 8 所示。其中,图 8(a)、(b)分别为凸起型缺陷的表面高度 h_{top} 和表面半峰全宽 ω_{top} 的检测结果,图 8(c)、(d)分别为凹陷型缺陷的表面高度 h_{top} 和表面半峰全宽 ω_{top} 的检测结果。缺陷表面形貌参数检测的绝对误差(AE, M_{AE})分布情况如表 3 所示。对于凸起型缺陷: h_{top} 检测结果的 MAE 为 0.06 nm,128 组数据中的最大 AE 为 0.51 nm,而对于 99.2% 的缺陷, h_{top} 检测结果的 AE 小于 0.50 nm; ω_{top} 检测结果的 MAE 为 0.55 nm,128 组数据中的最大 AE 为 4.18 nm,而对于

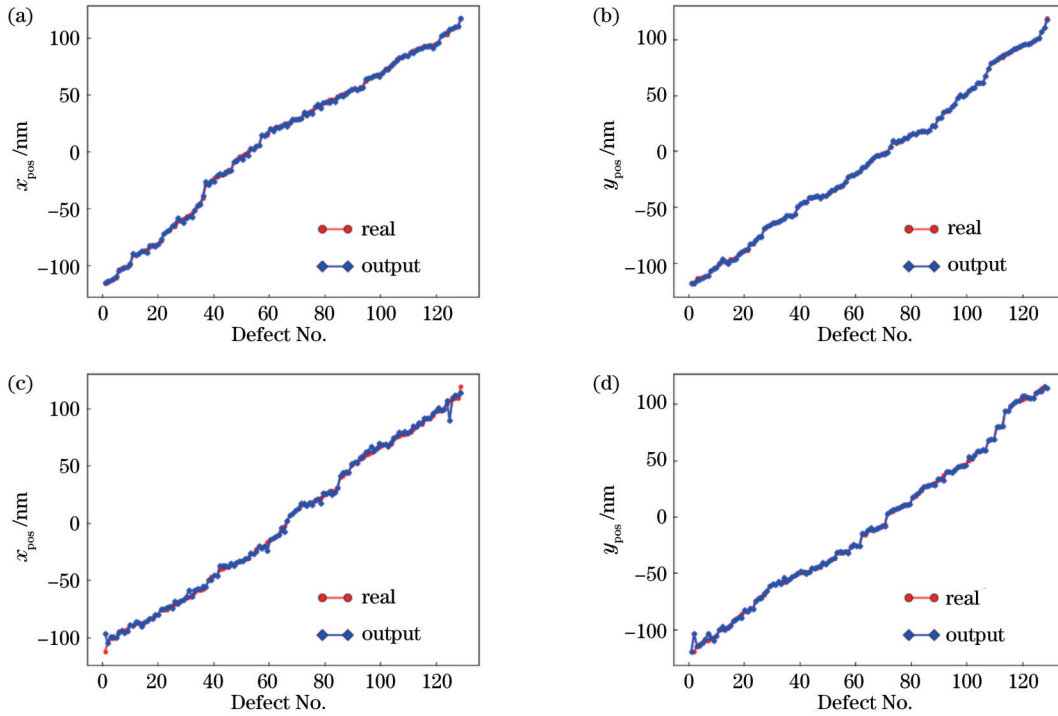


图 7 缺陷位置坐标检测结果。(a)凸起型缺陷 x 方向坐标;(b)凸起型缺陷 y 方向坐标;(c)凹陷型缺陷 x 方向坐标;(d)凹陷型缺陷 y 方向坐标

Fig. 7 Inspection results of defect position coordinates. (a) x -direction coordinates of bump defects; (b) y -direction coordinates of bump defects; (c) x -direction coordinates of pit defects; (d) y -direction coordinates of pit defects

97.7% 的缺陷, ω_{top} 检测结果的 AE 小于 3.00 nm。对于凹陷型缺陷: h_{top} 检测结果的 MAE 为 0.12 nm, 128 组数据中的最大 AE 为 0.59 nm, 而对于 98.4% 的缺陷, h_{top} 检测结果的 AE 小于 0.50 nm; ω_{top} 检测结果的 MAE 为 0.57 nm, 128 组数据中的最大 AE 为 2.99 nm, 而对于 100.0% 的缺陷, ω_{top} 检测结果的 AE 小于 3.00 nm。

从表 3 和图 8 可知, MLP 模型可较精确地检测缺陷的表面形貌, 由于当缺陷表面形貌参数相同时, 缺陷的底部形貌的不同会使得空间像发生变化, 故该模型对部分缺陷, 尤其是高度大于 3 nm 的缺陷, 检测误差较大。从测试数据可知, 所有 h_{top} 检测结果的 AE 均小于 0.60 nm, 所有 ω_{top} 检测结果的 AE 均小于 5.00 nm。

表 3 缺陷表面形貌参数检测结果的绝对误差分布

Table 3 Absolute error distribution of inspection results of defect surface profile parameters

Defect type	h_{top}			ω_{top}		
	$M_{AE} \leq 0.10 \text{ nm}$	$M_{AE} \leq 0.30 \text{ nm}$	$M_{AE} \leq 0.50 \text{ nm}$	$M_{AE} \leq 1.00 \text{ nm}$	$M_{AE} \leq 3.00 \text{ nm}$	$M_{AE} \leq 5.00 \text{ nm}$
Bump defect	85.9%	97.7%	99.2%	85.9%	97.7%	100.0%
Pit defect	56.3%	90.6%	98.4%	85.2%	100.0%	100.0%

3.4 噪声对缺陷检测模型准确性的影响

在实际情况下, 获取的含缺陷掩模的空间像中会因采用 CCD 器件接收图像等原因存在噪声。为检验噪声对用于相位型缺陷检测的训练后的 CNN 模型和 MLP 模型的准确性的影响, 给测试集中的空间像添加噪声。由于空间像成像系统中光瞳函数可等效于低通滤波器, 故空间像的大部分有效信息集中在低频部分。对含噪声的空间像进行低通滤波后作为 CNN 模型测试集中的空间像。添加的泊松噪声的分布与图像的强度分布相关, 添加泊松噪声后空间像的信噪比 (SNR) 为 52.9 dB。另外, 向测试集中的空间像添加不同强度的高斯噪声, 使得添加高斯噪声后的空间像的 SNR

分别为 47.9 dB、52.9 dB 和 57.9 dB。当测试集中的空间像含噪声和不含噪声时, 对相位型缺陷类型、位置和表面形貌参数的检测结果如表 4 所示。由表 4 可知: 用于缺陷类型和位置检测的 CNN 模型对噪声的鲁棒性更强, 在含噪声的情况下可对缺陷类型和位置进行精确检测; 用于缺陷表面形貌参数检测的 MLP 模型受噪声的影响更大; 当含噪声的空间像的 SNR 为 57.9 dB 时, 缺陷的类型、位置和表面形貌参数检测结果的精度仍较高, 受噪声的影响较小; 当噪声逐渐增大时, 缺陷表面形貌参数 h_{top} 和 ω_{top} 检测结果的 MAE 也在逐渐增大。

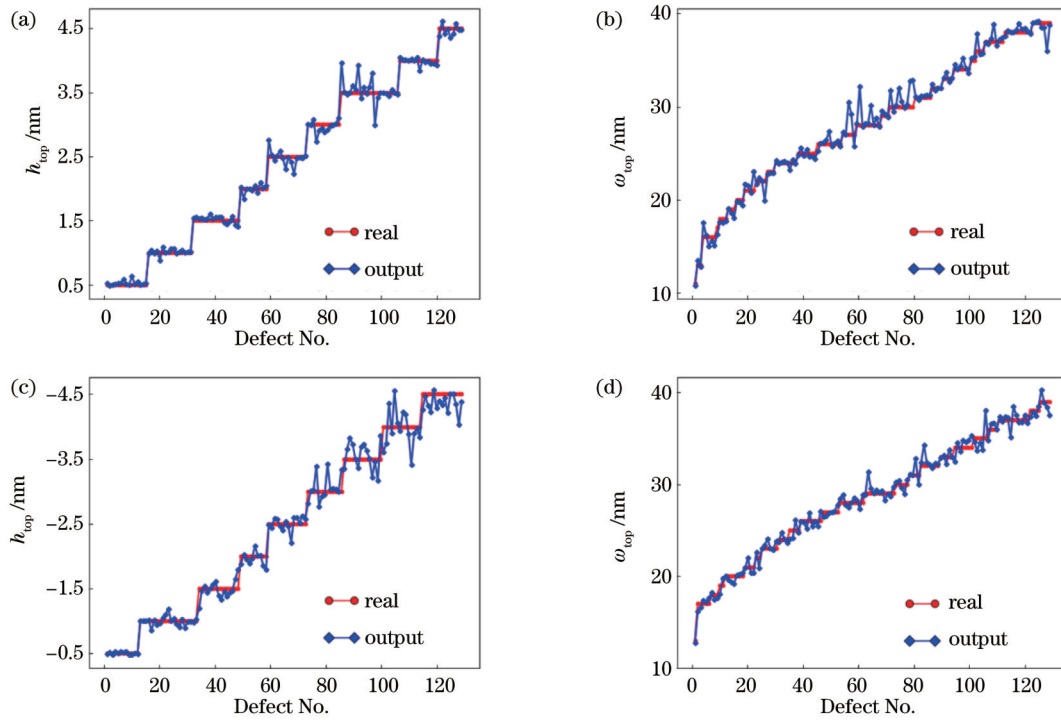


图 8 缺陷表面形貌参数检测结果。(a)凸起型缺陷表面高度;(b)凸起型缺陷表面 FWHM;(c)凹陷型缺陷表面高度;(d)凹陷型缺陷表面 FWHM

Fig. 8 Inspection results of defect top profile parameters. (a) Surface height of bump defect; (b) surface FWHM of bump defect; (c) surface height of pit defect; (d) surface FWHM of pit defect

表 4 含噪声和不含噪声时相位型缺陷的类型、位置和表面形貌参数检测结果

Table 4 Inspection results for type, location and surface profile parameters of phase defects with and without noise

Defect type	Noise type	SNR /dB	Classification accuracy / %	MAE of x_{pos} /nm	MAE of y_{pos} /nm	MAE of h_{top} /nm	MAE of ω_{top} /nm
Bump defect	Without noise		100	1.06	0.51	0.06	0.55
Bump defect	Gaussian	57.9	100	1.06	0.53	0.09	0.82
Bump defect	Gaussian	52.9	100	1.06	0.55	0.18	1.37
Bump defect	Gaussian	47.9	100	1.20	0.59	0.24	2.07
Bump defect	Poisson	52.9	100	1.07	0.55	0.14	1.42
Pit defect	Without noise		100	1.70	0.97	0.12	0.57
Pit defect	Gaussian	57.9	100	1.71	1.01	0.13	0.64
Pit defect	Gaussian	52.9	100	1.75	1.01	0.18	0.94
Pit defect	Gaussian	47.9	100	1.73	1.20	0.27	1.51
Pit defect	Poisson	52.9	100	1.71	1.07	0.17	0.85

4 结 论

提出了一种基于空间像的 EUV 光刻掩模多层膜相位型缺陷检测方法,仿真结果表明该方法可准确检测多层膜相位型缺陷的类型、位置和表面形貌参数。采用 CNN 模型构建了缺陷类型和位置与含缺陷空白掩模的空间像间的关系,建立了可对相位型缺陷类型和位置进行检测的 CNN 模型。基于 CNN 模型获取的缺陷位置坐标对空间像进行截取,采用 MLP 模型构建了缺陷表面形貌参数和截取空间像的低通频谱信息之

间的关系,建立了可对缺陷表面形貌参数进行检测的 MLP 模型。用于缺陷类型和位置检测的 CNN 模型对噪声具有较高的鲁棒性,用于缺陷表面形貌参数检测的 MLP 模型受噪声的影响较大。在后续工作中:为进一步提升缺陷表面形貌参数的检测精度,可对训练集进行扩充;为适应实际检测情况,可采用实际空间像测量数据对深度学习模型进行训练。

参 考 文 献

[1] Ronse K, Jonckheere R, Gallagher E, et al. EUVL is being

- inserted in manufacturing in 2019: what are the mask related challenges remaining? [J]. Proceedings of SPIE, 2019, 11177: 111770A.
- [2] Verhoeven E, Schuurhuis R, Mastenbroek M, et al. 0.33 NA EUV systems for high volume manufacturing[J]. Proceedings of SPIE, 2020, 11517: 1151703.
- [3] Capelli R, Dietzel M, Hellweg D, et al. Actinic metrology platform for defect review and mask qualification: flexibility and performance[J]. Proceedings of SPIE, 2019, 10957: 109570X.
- [4] 张恒, 李思坤, 王向朝. 基于改进型结构分解的极紫外光刻掩模衍射谱快速仿真方法[J]. 光学学报, 2018, 38(1): 0105001.
Zhang H, Li S K, Wang X Z. A rapid simulation method for diffraction spectra of EUV lithography mask based on improved structural decomposition[J]. Acta Optica Sinica, 2018, 38(1): 0105001.
- [5] Barty A, Mirkarimi P B, Stearns D G, et al. EUVL mask blank repair[J]. Proceedings of SPIE, 2002, 4688: 385-394.
- [6] Bakshi V. EUV lithography[M]. 2nd ed. Washington: SPIE Press, 2018.
- [7] 刘晓雷, 李思坤, 王向朝. 极紫外光刻含缺陷多层膜衍射谱仿真简化模型[J]. 光学学报, 2014, 34(9): 0905002.
Liu X L, Li S K, Wang X Z. Simplified model for defective multilayer diffraction spectrum simulation in extreme ultraviolet lithography[J]. Acta Optica Sinica, 2014, 34(9): 0905002.
- [8] Hashimoto T, Yamanashi H, Sugawara M, et al. Lithographic characterization of EUVL mask blank defects[J]. Proceedings of SPIE, 2004, 5374: 740-750.
- [9] Zhang H, Li S K, Wang X Z, et al. Optimization of defect compensation for extreme ultraviolet lithography mask by covariance-matrix-adaption evolution strategy[J]. Journal of Micro/Nanolithography, MEMS, and MOEMS, 2018, 17(4): 043505.
- [10] Jonckheere R, Yamane T, Morikawa Y, et al. Blank defect coverage budget for 16 nm half-pitch single EUV exposure[J]. Proceedings of SPIE, 2018, 10807: 108070H.
- [11] Liu X L, Li S K, Wang X Z, et al. Optimal shift of pattern shifting for mitigation of mask defects in extreme ultraviolet lithography[J]. Journal of Vacuum Science & Technology B, 2015, 33(5): 051603.
- [12] Miyai H, Suzuki T, Takehisa K, et al. The capability of high magnification review function for EUV actinic blank inspection tool[J]. Proceedings of SPIE, 2013, 8701: 870118.
- [13] Suzuki T, Miyai H, Takehisa K, et al. Defect analysis on actinic blank inspection tool[J]. Proceedings of SPIE, 2014, 9256: 92560O.
- [14] Yamane T, Amano T, Takagi N, et al. Advances in the detection capability on actinic blank inspection[J]. Proceedings of SPIE, 2016, 9776: 97761G.
- [15] Amano T, Watanabe H, Abe T. Phase defect detection signal analysis: dependence of defect size variation[J]. Journal of Micro/Nanolithography, MEMS, and MOEMS, 2015, 14(1): 013502.
- [16] Xu D B, Evanschitzky P, Erdmann A. Extreme ultraviolet multilayer defect analysis and geometry reconstruction[J]. Journal of Micro/Nanolithography, MEMS, and MOEMS, 2016, 15(1): 014002.
- [17] Chen Y, Lin Y B, Chen R, et al. EUV multilayer defect characterization via cycle-consistent learning[J]. Optics Express, 2020, 28(12): 18493-18506.
- [18] Cheng W, Li S K, Wang X Z, et al. Extreme ultraviolet phase defect characterization based on complex amplitudes of the aerial images[J]. Applied Optics, 2021, 60(17): 5208-5219.
- [19] Gu J X, Wang Z H, Kuen J, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition, 2018, 77: 354-377.
- [20] Gardner M W, Dorling S R. Artificial neural networks (the multilayer perceptron): a review of applications in the atmospheric sciences[J]. Atmospheric Environment, 1998, 32(14/15): 2627-2636.
- [21] Upadhyaya M, Jindal V, Basavalingappa A, et al. Evaluating printability of buried native EUV mask phase defects through a modeling and simulation approach[J]. Proceedings of SPIE, 2015, 9422: 94220Q.
- [22] Zhang H, Li S K, Wang X Z, et al. Fast optimization of defect compensation and optical proximity correction for extreme ultraviolet lithography mask[J]. Optics Communications, 2019, 452: 169-180.
- [23] Rumpf R C. Improved formulation of scattering matrices for semi-analytical methods that is consistent with convention[J]. Progress in Electromagnetics Research B, 2011, 35: 241-261.
- [24] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]// ICML'15: Proceedings of the 32nd International Conference on International Conference on Machine Learning-Volume 37, July 6-11, 2015, Lille, France. New York: ACM Press, 2015: 448-456.
- [25] Capelli R, Hellweg D, Dietzel M, et al. Aerial image based metrology of EUV masks: recent achievements, status, and outlook for the AIMS EUV platform[J]. Proceedings of SPIE, 2018, 10583: 1058311.
- [26] Paszke A, Gross S, Massa F, et al. PyTorch: an imperative style, high-performance deep learning library[EB/OL]. (2019-12-03)[2021-02-04]. <https://arxiv.org/abs/1912.01703>.
- [27] Harris-Jones J, Jindal V, Kearney P, et al. Smoothing of substrate pits using ion beam deposition for EUV lithography[J]. Proceedings of SPIE, 2012, 8322: 83221S.
- [28] Kingma D P, Ba J. Adam: a method for stochastic optimization [EB/OL]. (2014-12-22) [2021-02-04]. <https://arxiv.org/abs/1412.6980>.

Method for Inspection of Phase Defects in Extreme Ultraviolet Lithography Mask

Cheng Wei^{1,2}, Li Sikun^{1,2*}, Wang Xiangzhao^{1,2**}

¹*Laboratory of Information Optics and Optoelectronic Technology, Shanghai Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Shanghai 201800, China;*

²*Center of Materials Science and Optoelectronics Engineering, University of Chinese Academy of Sciences, Beijing 100049, China*

Abstract

Objective Extreme ultraviolet (EUV) lithography has been introduced into high-volume manufacturing (HVM) of chips with a technology node of 7 nm and below. As the technology nodes of chips decrease, the structure of the EUV mask is becoming more and more complex. The defects in EUV masks degrade the mask imaging quality, which is one of the most critical problems affecting the yield of EUV lithography. Phase defects refer to the deformation of the EUV mask multilayer caused by the defects situated at the bottom of the multilayer. Phase defects of nanometer size can lead to a distinct phase shift of the reflected field and seriously degrade the aerial images. Defect compensation methods can be adopted to indirectly compensate for the degradation of imaging quality caused by the phase defects. Accurate inspection of the type, location, and profile of phase defects is the prerequisite for effective defect compensation. A method to inspect the type, position, and surface profile of phase defects in EUV masks on the basis of aerial images is proposed in this paper. The accuracy of the proposed method is verified by simulations.

Methods Deep learning models are adopted to construct the mapping between aerial images of defective mask blanks and defect information. After that, the type, location, and profile of phase defects can be obtained from the aerial images of defective mask blanks by the trained models. The inspection model for the type and location of defects is built by the construction of the relationship between the type and location of defects and the aerial images of defective mask blanks with the convolutional neural network (CNN) model. On this basis, the aerial images are intercepted according to the obtained location of defects. The inspection model for the surface profile parameters of defects is constructed with the spectrum information of the intercepted aerial images and the multilayer perceptron (MLP) model.

Results and Discussions A test group containing 256 defective mask blanks is utilized to verify the accuracy of the proposed method. The phase defects in the multilayer can be accurately classified into bump defects and pit defects by the trained CNN models (Fig. 6). The mean absolute error (MAE) of the x coordinates of the phase defects is 1.38 nm, and the MAE of the y coordinates is 0.74 nm, which indicates that the inspection accuracy of the y coordinates is higher than that of the x coordinates. The simulations show that the inspection accuracy of the location of bump defects is higher than that of pit defects (Fig. 7). For bump defects, the MAE of the surface height is 0.06 nm, and the MAE of the surface full width at half maximum (FWHM) is 0.55 nm. For pit defects, the MAE of the surface height is 0.12 nm, and the MAE of the surface FWHM is 0.57 nm (Fig. 8). Noise is added to the aerial images in the test group to examine the robustness of the trained models. The results reveal that noise lowers the accuracy of the trained models, and the inspection model for the type and location of defects is more robust to the noise than the inspection model for the surface profile parameters of defects.

Conclusions In this paper, a method based on aerial images is proposed to inspect the type, location, and surface profile parameters of phase defects in the EUV mask multilayer. CNNs are adopted to construct the relationship between the type and location of defects and the aerial images of defective mask blanks. In this way, the CNN-based inspection model is constructed to inspect the type and location of defects. The aerial images are intercepted according to the obtained location of defects. MLP is adopted to construct the relationship between the surface profile parameters of defects and the spectrum information of the intercepted aerial images. In this way, the MLP-based model is built to inspect the surface profile parameters of defects. The simulations show that the inspection results of the proposed method are accurate. The CNN-based model used to inspect the type and location of defects is robust to the noise, and the MLP-based model used to inspect the surface profile parameters of defects is sensitive to the noise.

Key words measurement; lithography; extreme ultraviolet lithography; mask defect inspection; aerial image; deep learning