

# 基于计算光学系统的信息处理方法研究进展

邵晓鹏, 邓谥霜, 陈雨彤, 张一诺, 王慧慧, 吴腾飞, 魏士杰

(中国科学院西安光学精密机械研究所, 西安 710119)

**摘要:** 像差是制约光学系统成像性能的关键因素, 而计算光学像差校正技术通过融合光学物理建模与信息处理算法, 实现对成像退化的精准补偿。本文围绕计算光学像差校正技术, 首先阐述了基于 Zernike 多项式的波前像差表征方法及像差主导的光场退化模型, 并介绍了维纳滤波、Richardson-Lucy 迭代等经典复原算法。在此基础上, 从主动调节、光学编码和纯计算复原 3 个维度, 分析了自适应光学、波前编码、相位恢复与盲解卷积等主流技术的原理与应用。最后, 重点解释了深度学习驱动的像差校正方法, 包括数据驱动、物理模型嵌入及无监督学习架构, 并讨论了其在生物医学显微成像、无透镜成像和天文遥感等领域的典型应用。

**关键词:** 计算光学成像; 像差校正; 波前编码; 相位恢复; 深度学习

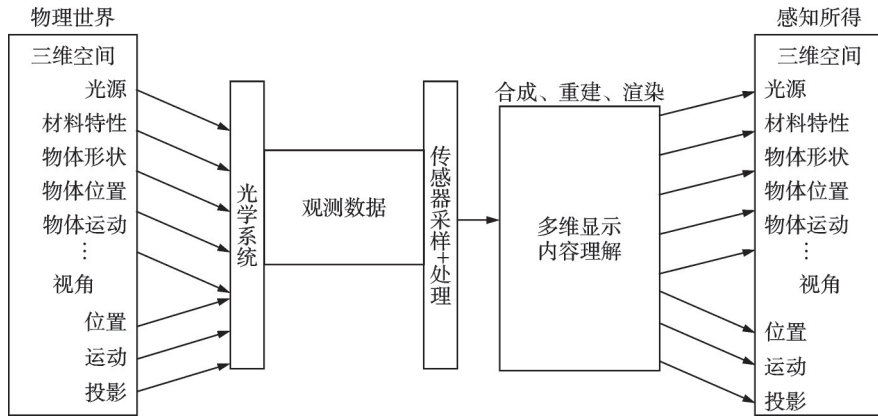
**中图分类号:** TN29 **文献标志码:** A

**引用格式:** 邵晓鹏, 邓谥霜, 陈雨彤, 等. 基于计算光学系统的信息处理方法研究进展[J]. 数据采集与处理, 2026, 41(2): 489-514. SHAO Xiaopeng, DENG Yishuang, CHEN Yutong, et al. Research progress in information processing methods for computational optical systems[J]. Journal of Data Acquisition and Processing, 2026, 41(2): 489-514.

## 引言

近年来, 光学成像技术持续朝着高精度、多维信息获取与系统轻量化方向演进, 传统光学系统“硬件性能决定成像上限”的局限性日益凸显。计算光学成像作为一种新兴技术范式, 通过融合光学硬件设计、图像传感器与后处理算法, 构建了“物理光场调控-数据采集-计算重构”的一体化框架, 实现了对光场信息的主动编码与解码<sup>[1-2]</sup>。如图 1 所示<sup>[2]</sup>, 计算成像系统以物理世界的三维空间信息为输入, 经由光学系统、传感器及处理单元完成多维信息的采集、融合与理解, 最终实现对感知世界的全面认知。基于波动光学与傅里叶光学理论<sup>[3-4]</sup>, 研究者建立了光场传播的精确正向数学模型, 通过求解相应的逆问题, 不仅能够补偿成像缺陷, 还可获取传统技术难以直接测量的相位、光谱和偏振等高维物理信息<sup>[5]</sup>。史浩东等<sup>[6]</sup>通过空间维编码实现了快照式高光谱偏振成像。计算光学系统成像技术体系的核心在于实现物理层光场调制与数字层算法重构的协同优化, 从而突破传统成像系统的性能边界。

像差是光学系统固有的性能制约因素, 也是导致光场信息退化的主要根源之一。像差源于光学器件加工精度不足、系统装配误差以及介质折射率不均匀等问题, 可通过 Zernike 多项式进行系统化数学表征<sup>[7]</sup>。根据其物理特性, 像差可分为球差、彗差、像散、场曲、畸变及色差等多种类型, 导致系统点扩散函数(Point spread function, PSF)退化、空间分辨率下降、图像模糊及对对比度衰减等现象<sup>[3]</sup>。在生物医学显微成像、光学相干断层扫描(Optical coherence tomography, OCT)及天文观测等应用场景中, 像差引发的图像失真严重影响成像的定量分析精度与诊断可靠性<sup>[8-9]</sup>。因此, 发展高效、精准的像差校正技术对于提升计算光学系统的成像性能具有重要意义。

图1 计算成像的任务<sup>[2]</sup>Fig.1 Computational imaging task<sup>[2]</sup>

像差校正技术的发展历程体现了“从硬件补偿到软硬协同、再到智能化”的演进脉络。传统光学系统主要依赖复杂透镜组设计与高精度加工工艺实现像差的被动抑制,但存在成本高昂、难以适应动态场景等局限。自适应光学(Adaptive optics, AO)技术通过波前传感器实时探测波前畸变,并利用变形镜进行主动补偿,在地基天文望远镜<sup>[10-11]</sup>、人眼视网膜成像<sup>[12]</sup>及激光通信<sup>[13]</sup>等领域取得了突破性进展。波前编码与编码孔径技术通过在光学前端引入可控相位调制元件,将复杂像差转化为易于计算校正的退化形式,实现了光学编码与后端算法的协同优化<sup>[14-15]</sup>。相位恢复技术作为纯计算类像差校正方法的代表,无需干涉光路即可从强度测量中反演波前相位信息<sup>[16-18]</sup>。近年来,深度学习技术的兴起为像差校正开辟了新路径:早期研究采用端到端学习框架直接建立退化图像与清晰图像之间的映射关系<sup>[19-20]</sup>;为提升模型的物理一致性与泛化能力,研究者进一步将波动光学模型、PSF等物理约束嵌入网络架构<sup>[21-22]</sup>;无监督学习与少样本学习方法的探索则有效降低了对大规模标注数据的依赖<sup>[23-25]</sup>。上述方法已在生物医学显微成像<sup>[26-29]</sup>、无透镜与全息成像<sup>[30-32]</sup>以及天文与遥感成像<sup>[33-34]</sup>等领域展现出广阔的应用前景。

尽管像差校正技术发展迅速,但仍面临诸多挑战:理论退化模型与真实成像过程之间存在失配;由大气湍流、生物组织散射等因素引起的复杂动态像差的实时高精度校正仍有难度;数据驱动方法的跨场景泛化能力与对标注数据的依赖之间存在矛盾;光学系统简化与成像质量保持之间的平衡尚需深入探索<sup>[35]</sup>。针对计算光学系统像差校正所面临的上述瓶颈及其带来的应用限制,近年来研究者积极发展了多种计算成像技术并取得了显著进展<sup>[36-37]</sup>。本文系统综述了像差校正的理论基础与主流技术方法,涵盖AO、波前编码、相位恢复及深度学习驱动的智能校正方法,分析了各类方法的基本原理、典型应用与当前局限,并探讨了该领域面临的挑战与未来发展趋势,旨在为计算光学成像系统的协同优化设计提供理论参考与技术路径指引。

## 1 计算光学系统中像差校正的理论基础

计算光学系统中的像差校正正是通过光学物理建模与信息处理技术的深度融合,从而对成像链路中由于光学系统像差引起的光场畸变与图像退化进行精准补偿的核心技术。技术的核心思想是将光学成像过程抽象为含像差调制的物理传输系统,通过构建高精度退化模型与优化反演算法,从退化图像中重构出接近衍射极限的理想目标信息,从而突破传统硬件校正对系统复杂度与成本的限制。这一过程的实现依赖于3个关键理论基础:像差主导的光场退化模型、经典计算复原算法以及量化评价体系。

### 1.1 像差主导的光场信息退化模型

在传统光学成像系统中,像差(包括球差、彗差、像散、场曲和畸变等)会导致成像波前畸变,进而引起图像模糊、对比度下降以及分辨率损失等一系列退化现象。计算光学像差校正的前提是建立准确的像差主导退化模型。这一方法的核心理念在于:理解像差如何通过调制系统的PSF来改变光场传播规律,进而成像质量退化。完整的数学建模需从波前像差表征与退化模型构建两方面展开,这一建模过程基于波动光学和傅里叶光学的基本原理。

#### 1.1.1 波前像差的数学表征

波前像差的本质是实际波前相对于理想球面或平面波前的相位偏移,记为 $\Delta\phi(x, y)$ ,其中 $x, y$ 为空间坐标。在单位圆域(光瞳面)内,波前像差可通过Zernike多项式进行正交展开<sup>[7]</sup>。该方法因其物理意义明确(每项对应特定像差类型)、计算便捷且与光学设计紧密关联,被广泛应用于成像过程中像差模型与计算校正<sup>[38-39]</sup>。

Zernike多项式 $Z_n^m(\rho, \theta)$ 在极坐标 $(\rho, \theta)$ 下定义,其中 $\rho$ 为归一化径向坐标( $0 \leq \rho \leq 1$ ), $\theta$ 为方位角。该多项式系满足在单位圆域内的正交性,即

$$\frac{1}{\pi} \int_0^1 \int_0^{2\pi} Z_n^m(\rho, \theta) Z_{n'}^{m'}(\rho, \theta) \rho d\rho d\theta = \delta_{nn'} \delta_{mm'} \quad (1)$$

式中: $n$ 为径向阶数(非负整数), $m$ 为方位频率(整数,满足 $|m| \leq n$ 且 $n - |m|$ 为偶数), $n', m'$ 为另一组Zernike模式指标, $\delta$ 为Kronecker函数。正交归一化Zernike多项式一般形式为

$$Z_n^m(\rho, \theta) = \begin{cases} \sqrt{n+1} R_n^0(\rho) & m=0 \\ \sqrt{2(n+1)} R_n^{|m|}(\rho) \cos(m\theta) & m>0 \\ \sqrt{2(n+1)} R_n^{|m|}(\rho) \sin(|m|\theta) & m<0 \end{cases} \quad (2)$$

其中,径向多项式 $R_n^{|m|}(\rho)$ 定义为

$$R_n^{|m|}(\rho) = \sum_{s=0}^{(n-|m|)/2} \frac{(-1)^s (n-s)!}{s! \left(\frac{n+|m|}{2} - s\right)! \left(\frac{n-|m|}{2} - s\right)!} \rho^{n-2s} \quad (3)$$

该径向多项式满足边界归一化性质 $R_n^{|m|}(1)=1$ 。任意波前像差 $\Delta\phi(\rho, \theta)$ 可表示为Zernike多项式的线性组合<sup>[39-40]</sup>,表达式为

$$\Delta\phi(\rho, \theta) = \sum_{j=1}^N c_j Z_j(\rho, \theta) \quad (4)$$

式中: $j$ 为Noll单索引排序编号, $c_j$ 为第 $j$ 项Zernike系数,表征对应像差的幅值, $Z_j$ 为Noll编号排序后的Zernike多项式, $N$ 为展开项数(通常取前15~37项即可覆盖大部分光学系统像差)。表1列出了部分典型低阶Zernike项及其对应的像差类型。根据具体光学系统的特性,可通过不同Zernike项的组合来表征复杂波前像差。

Zernike多项式的正交性与明确的物理意义使其成为波前像差表征的标准方法,为后续构建像差主导的光场退化模型奠定了数学基础。该方法已在多种光学系统的像差分析与校正中得到广泛应用。在波面干涉测量领域,陈善勇等<sup>[38]</sup>基于Zernike表征构建了可变像差补偿技术;在精密激光加工领域,吕颖等<sup>[39]</sup>与Corsaro等<sup>[41]</sup>针对折射率失配导致的深度依赖像差实现了动态补偿。

需要指出的是,Zernike多项式作为定义在单位圆域上的全局正交基函数,其展开形式本质上属于全局光滑函数的线性组合。因此,在多数低阶像差主导的光学系统中,该方法能够以有限阶展开实现较为准确的波前表征。然而,在某些特殊或极端像差条件下,其表征能力仍存在一定适用边界。例如,

表 1 典型低阶 Zernike 多项式及其对应像差类型 (Noll 排序)

Table 1 Typical low-order Zernike polynomials and corresponding aberration types (Noll ordering)

$j$	$(n, m)$	$Z_n^m(\rho, \theta)$	Aberration
1	(0, 0)	1	Piston
2	(1, 1)	$2\rho \cos \theta$	$x$ -tilt
3	(1, -1)	$2\rho \sin \theta$	$y$ -tilt
4	(2, 0)	$\sqrt{3}(2\rho^2 - 1)$	Defocus
5	(2, -2)	$\sqrt{6}\rho^2 \sin(2\theta)$	45° primary astigmatism
6	(2, 2)	$\sqrt{6}\rho^2 \cos(2\theta)$	0° primary astigmatism
7	(3, 1)	$\sqrt{8}(3\rho^3 - 2\rho) \cos \theta$	Primary $x$ -coma
8	(3, -1)	$\sqrt{8}(3\rho^3 - 2\rho) \sin \theta$	Primary $y$ -coma
11	(4, 0)	$\sqrt{5}(6\rho^4 - 6\rho^2 + 1)$	Primary spherical

当波前存在显著的局部畸变或空间高频相位扰动时,为逼近局部突变结构,往往需要引入较高阶 Zernike 项<sup>[42-43]</sup>,导致模型自由度增加、参数维度上升,并可能带来数值稳定性与过拟合风险。此外,对于分块拼接镜面系统、分段光阑或存在相位不连续边界的波前结构,由于 Zernike 展开基于连续单位圆正交体系,其对非连续或分段定义波前的表达效率相对有限,在有限阶截断情况下可能产生局部振荡现象。因而,在复杂工程应用或强非均匀介质传播条件下,往往需要结合局部基函数、小波分解或数据驱动建模方法,以弥补传统全局正交展开在高频与非连续结构表征方面的不足。

### 1.1.2 像差主导的光场退化模型

基于上述 Zernike 多项式波前像差表征方法,可进一步构建像差主导的光场退化模型,建立像差与成像质量之间的定量关系。理想无像差系统的 PSF 由衍射效应主导。根据傅里叶光学理论,光学系统可视为一个线性系统,其成像特性由系统的光瞳函数决定。对于理想系统,光瞳函数在其孔径内是恒定不变的,即  $P(\xi, \eta) = 1$ , 其中  $(\xi, \eta)$  为归一化瞳面坐标。

对于相干成像系统,像面复振幅分布为物面复振幅与相干传递函数的卷积,系统的相干点扩散函数(振幅 PSF)为光瞳函数的傅里叶变换,有

$$h(x, y) = \mathcal{F}\{P(\xi, \eta)\} = \iint P(\xi, \eta) \exp[-j2\pi(x\xi + y\eta)] d\xi d\eta \quad (5)$$

式中:  $(x, y)$  为归一化像面坐标,  $h(x, y)$  为相干点扩散函数,  $P(\xi, \eta)$  为理想光瞳函数,对于圆形孔径的理想系统,式(5)给出艾里斑分布。

对于非相干成像系统(如荧光显微镜、自然光照明成像),像面强度分布为物面强度与强度 PSF 的卷积。非相干系统的 PSF 为相干 PSF 的模平方,即

$$\text{PSF}_{\text{ideal}}(x, y) = |h(x, y)|^2 = |\mathcal{F}\{P(\xi, \eta)\}|^2 \quad (6)$$

式中  $\text{PSF}_{\text{ideal}}(x, y)$  为理想系统的强度点扩散函数,相应的光学传递函数(Optical transfer function, OTF)为 PSF 的傅里叶变换,也等于光瞳函数的自相关,即

$$\text{OTF}(u, v) = \mathcal{F}\{\text{PSF}(x, y)\} = P(\xi, \eta) \star P(\xi, \eta) \quad (7)$$

式中:“ $\star$ ”表示自相关运算,  $(u, v)$  为空间频率坐标。此时理想成像模型为

$$I_{\text{ideal}}(x, y) = O(x, y) * \text{PSF}_{\text{ideal}}(x, y) \quad (8)$$

式中:“ $*$ ”表示卷积运算,  $O(x, y)$  为目标物体的强度分布,  $I_{\text{ideal}}(x, y)$  为理想成像函数。当存在波前像差

$\Delta\phi(\xi, \eta)$ 时,光瞳函数变为复振幅形式,即

$$P_{\text{aberr}}(\xi, \eta) = P(\xi, \eta) \exp \left[ j \frac{2\pi}{\lambda} \Delta\phi(\xi, \eta) \right] \quad (9)$$

式中: $\lambda$ 为工作波长, $\Delta\phi$ 为波前光程差(长度单位), $P_{\text{aberr}}(\xi, \eta)$ 为含像差光瞳函数。

若采用以波长为单位的波前误差  $W(\xi, \eta) = \Delta\phi(\xi, \eta)/\lambda$ ,则式(9)可简写为

$$P_{\text{aberr}}(\xi, \eta) = P(\xi, \eta) \exp [j2\pi W(\xi, \eta)] \quad (10)$$

此时含像差系统的PSF为

$$\text{PSF}_{\text{aberr}}(x, y) = |\mathcal{F}\{P_{\text{aberr}}(\xi, \eta)\}|^2 \quad (11)$$

对于相干系统,PSF应理解为复振幅响应  $h_{\text{aberr}}(x, y) = \mathcal{F}\{P_{\text{aberr}}(\xi, \eta)\}$ ;对于非相干系统,PSF为其模的平方。含像差系统的OTF相应地变为含像差光瞳函数的自相关。

结合成像过程中的噪声项  $\eta(x, y)$ (包含光子散粒噪声、探测器读出噪声等),最终像差主导的光场退化模型为<sup>[42]</sup>

$$I_{\text{obs}}(x, y) = O(x, y) * \text{PSF}_{\text{aberr}}(x, y) + \eta(x, y) \quad (12)$$

式中: $I_{\text{obs}}(x, y)$ 为观测退化成像, $O(x, y)$ 为目标物体强度分布, $\text{PSF}_{\text{aberr}}(x, y)$ 为含像系统的点扩散函数。该模型明确了像差通过调制PSF劣化成像质量的核心机制:像差幅值越大,PSF<sub>aberr</sub>的旁瓣越多、主瓣展宽越显著,导致图像细节模糊、对比度下降。

理论上,不同类型像差对PSF的调制作用存在显著差异。球差会使PSF的主瓣能量向旁瓣扩散,进而引发图像整体分辨率下降与细节模糊;像散会使PSF沿特定正交方向产生不对称拉伸,形成椭圆形或条纹状模糊斑,降低图像的各向同性分辨率;彗差导致PSF呈现彗星状拖尾,在视场边缘尤为显著;色差则因不同波长光的聚焦位置偏移,在宽谱成像中表现为目标边缘的色晕与光谱串扰。这些特性使得像差主导的成像退化模型需针对具体像差类型进行精细化构建。在深层生物组织成像、OCT等应用中,样品折射率不均与系统校准误差会引入复杂的高阶像差。Makita等<sup>[9]</sup>在OCT研究中建立了含光学像差的图像形成理论模型,提出了基于该理论的计算像差校正(Computational aberration correction, CAC)方法,实现了多深度范围内的像差补偿,显著提升了视网膜成像的分辨率。准确的退化模型需要包含高阶Zernike项(如径向阶 $n=8, n=10$ 的高阶模态)以实现更精确的表征。在衍射光学元件(Diffractive optical element, DOE)成像系统中,色差是主要的像差来源。Liu等<sup>[44]</sup>针对单透镜衍射系统建立了宽带光谱成像的色差退化模型,并设计了深度学习网络实现图像复原与超分辨率重建,验证了基于物理退化模型的计算校正方法可有效补偿DOE的色差问题。综上所述,像差主导的光场退化模型通过将波前像差引入光瞳函数,建立了像差参数与系统PSF之间的定量关系,为后续计算复原算法的设计提供了物理依据。

## 1.2 经典计算复原算法

在像差主导的光场退化模型明确后,经典计算复原算法的核心任务是从退化图像中恢复理想目标信息。这类算法基于光学成像的物理模型与数学先验,不依赖大规模数据训练,是计算像差校正的基础技术体系。经典计算复原算法包括基于逆滤波的线性复原算法和基于正则化的迭代优化算法等。

### 1.2.1 基于逆滤波的线性复原算法

这类算法通过在频域或空域中设计滤波器来逆转像差引起的模糊,其核心思想是对退化模型进行逆操作。常见的算法包括维纳滤波和约束最小二乘滤波等。

#### (1) 维纳滤波

维纳滤波是一种最小均方误差(Mean squared error, MSE)准则下的最优线性滤波器,通过引入信

噪比(Signal-to-noise ratio, SNR)先验,在图像复原与噪声抑制之间寻求平衡,其频域表达式为

$$O(u, v) = \frac{H^*(u, v)}{|H(u, v)|^2 + \frac{P_N(u, v)}{P_O(u, v)}} I(u, v) \quad (13)$$

式中: $H(u, v)$ 为系统的OTF, $H^*(u, v)$ 为其共轭, $I(u, v)$ 为观测图像的频域表示, $O(u, v)$ 为复原图像的频域表示, $P_N(u, v)$ 和 $P_O(u, v)$ 分别为噪声与信号的功率谱密度。维纳滤波的复原性能高度依赖于准确的信噪比估计与像差模型。在实际应用中,当信号功率远大于噪声功率时,维纳滤波趋近于逆滤波;当噪声占主导时,则趋向于恒等变换以抑制噪声放大。

### (2)约束最小二乘滤波

约束最小二乘滤波通过在目标函数中引入平滑正则项,将逆问题转化为带约束的优化问题

$$\min \|I - H*O\|^2 + \beta \|\nabla O\|^2 \quad (14)$$

式中: $\beta$ 为正则化系数, $\nabla$ 为梯度算子, $I$ 为观测成像, $O$ 为待恢复目标图像, $H$ 为系统传递矩阵。该优化问题可通过拉格朗日乘法转化为频域求解

$$O(u, v) = \frac{H^*(u, v)}{|H(u, v)|^2 + \beta |G(u, v)|^2} \cdot I(u, v) \quad (15)$$

式中 $G(u, v)$ 为梯度算子 $\nabla$ 的频域表示(通常为拉普拉斯算子的傅里叶变换)。该方法在弱噪声、低对比度的像差图像复原中表现稳健,能够有效抑制噪声放大并保持图像结构信息,为后续高阶像差校正提供了良好的初始估计。

### 1.2.2 基于正则化的迭代优化算法

对于复杂或强噪声的像差场景,线性滤波方法的复原能力有限。此时,基于正则化的迭代优化算法通过构建包含物理约束的目标函数,在迭代过程中逐步逼近理想图像,成为更有效的解决方案。该类方法主要包括最大似然(Maximum likelihood, ML)/最大后验(Maximum a posteriori, MAP)算法与Richardson-Lucy(RL)算法。

#### (1)最大似然与最大后验算法

最大似然算法基于成像噪声的统计模型构建目标函数。在高斯噪声模型假设下,最大化似然函数等价于最小化观测图像与估计图像之间的均方误差。因此,其目标函数(损失函数)定义为

$$\mathcal{L}_{ML}(O) = [I(x, y) - (O * \text{PSF}_{\text{aberr}})(x, y)]^2 \quad (16)$$

通过梯度下降或共轭梯度法最小化该函数,即可实现图像的逆向复原。而在非相干成像(如荧光显微、天文观测)中,若考虑光子计数的泊松统计特性,则需构建基于Kullback-Leibler(KL)散度的损失函数。

最大后验算法在ML基础上引入图像先验概率信息(如稀疏性、平滑性),形成带正则化的目标函数

$$\mathcal{L}_{MAP}(O) = \mathcal{L}_{ML}(O) + \gamma \mathcal{R}(O) \quad (17)$$

式中: $\mathcal{R}(O)$ 为正则化项, $\gamma$ 为平衡数据保真项与先验约束项的权重系数。例如,选用全变分正则化 $\mathcal{R}(O) = \|\nabla O\|_1$ 时,该方法能有效保持图像边缘锐度并抑制平滑区域噪声累计,在天文湍流像差校正中显著提升了恒星目标的角分辨率与图像对比度。

#### (2)Richardson-Lucy 迭代算法

Richardson-Lucy算法是针对泊松噪声分布推导出的经典迭代反卷积方法,可视为在贝叶斯框架下基于似然函数进行乘性迭代更新的求解过程,其迭代公式为

$$O^{k+1}(x, y) = O^k(x, y) \cdot \left[ \text{PSF}_{\text{aberr}}(-x, -y) * \frac{I(x, y)}{O^k * \text{PSF}_{\text{aberr}}(x, y)} \right] \quad (18)$$

式中: $k$ 为迭代次数,  $\text{PSF}_{\text{aberr}}(-x, -y)$ 代表PSF的空间翻转(即相关运算核)。该算法具有非负性约束,符合光强的物理特性,且无需预先估计噪声功率谱。RL算法常与Zernike像差建模结合,实现“像差表征-PSF更新-图像复原”的闭环迭代策略,在天文成像、显微成像等领域得到广泛应用<sup>[45]</sup>。

基于Zernike像差表征的图像复原流程,本质上是“像差表征-PSF更新-图像复原”的闭环迭代,这一思路已被广泛延伸至各类光学系统的像差处理中。在波面干涉测量领域,陈善勇等<sup>[38]</sup>基于此框架构建了可变像差补偿技术,利用空间光调制器(Spatial light modulator, SLM)与高次非球面透镜的混合方案,成功实现了大范围球差及多模式像差的动态表征与校正。在自由空间光通信领域, Li等<sup>[46]</sup>针对大气湍流引起的波前畸变,对比分析了物理层面的AO与计算层面的Gerchberg-Saxton(GS)迭代算法的相位校正性能,指出GS算法虽在弱湍流条件下具备计算优势,但在强湍流引发的复杂高阶像差面前仍存在收敛瓶颈。值得注意的是,上述闭环迭代思想并不局限于光学成像领域。早在医学超声成像中, Ng等<sup>[47]</sup>便建立了相位像差校正算法的分类框架,系统揭示了不同相关性条件下校正算法的性能差异,其方法论对光学领域的算法选型与性能评估同样具有参考价值。

### 1.3 信息处理的核心目标与量化评价体系

计算像差校正的核心目标是通过精准的信息处理手段,补偿由像差引起的光场信息退化,使校正后的图像逼近无像差条件下的理想成像效果。具体而言,目标可归纳为3个关键维度:(1)提升空间分辨率,恢复因像差而衰减或丢失的高频细节信息,如在天文观测中解析天体的细微特征<sup>[10]</sup>,或在生物医学成像中清晰表征细胞亚结构<sup>[11]</sup>;(2)增强图像对比度与信噪比,抑制像差导致的背景噪声和信号模糊,为定量分析提供可靠依据;(3)实现相位信息的准确恢复,尤其在数字全息显微、定量相位成像等领域,相位信息直接关联样本的折射率分布、三维形貌等物理量,是计算成像从强度向物理场拓展的关键。为客观、系统评价校正效果,需构建多维度的量化评价体系,涵盖光学性能、图像质量与算法效率3大类指标。

#### (1) 光学性能指标

光学性能指标直接反映像差校正对系统光学性能的改善。Strehl比衡量实际PSF峰值强度与理想衍射受限PSF峰值强度的比值,Strehl比 $\geq 0.8$ 通常被视为接近衍射极限, Ginner等<sup>[48]</sup>在线场OCT视网膜成像中通过非迭代数字像差校正实现了细胞级分辨率成像。波前均方根误差量化波前偏离理想平面或球面的程度,是AO系统中的关键评价指标<sup>[10]</sup>。调制传递函数(Modulation transfer function, MTF)表征系统对不同空间频率的传递能力, Hardy<sup>[10]</sup>在天文AO系统中系统阐述了利用MTF评估大气湍流校正后的分辨率恢复情况。

#### (2) 图像质量指标

图像质量指标关注校正后图像的视觉保真度与结构完整性。峰值信噪比(Peak signal-to-noise ratio, PSNR)和结构相似性指数(Structure similarity index measure, SSIM)是最常用的客观评价指标。Wu等<sup>[36]</sup>在相位全息图生成中采用这些指标评价自适应加权Gerchberg-Saxton算法对伪影的抑制效果。感知损失是基于深度神经网络提取的特征度量图像的感知质量,南亦澜等<sup>[49]</sup>在多光谱融合计算成像中综合均方误差与感知损失实现了对色彩与细节恢复能力的全面评估。

#### (3) 算法性能指标

算法性能指标着眼于信息处理过程的效率与实用性,包括收敛速度、计算复杂度和实时性等,为算法在实际系统中的部署提供依据。Elser等<sup>[50]</sup>构建了相位恢复的基准测试集,通过定义以自相关稀疏度

为核心的难度分级,为标准化的算法评估与对比提供了理论基础。

#### (4) 面向下游任务的评价指标

随着计算光学成像逐渐服务于自动感知与智能分析场景,像差校正的目标已不仅仅局限于提升主观视觉质量或物理光学指标,还需关注其对下游机器视觉任务性能的影响。在目标检测、图像分类与三维重建等应用中,图像通常作为中间表征,其最终价值体现在任务准确率与结构恢复精度的提升。因此,可进一步引入面向任务的评价指标,例如检测任务中的平均精度(mean Average precision, mAP)、分类任务中的准确率或  $F_1$ -score 以及三维重建中的重建误差等,以量化像差校正对系统整体性能的贡献。

近年来,端到端可微计算成像框架逐渐兴起,通过将光学设计、图像复原与下游任务网络联合优化,使成像系统以任务性能最大化为目标函数,实现“光学-算法-任务”的协同设计<sup>[14-15]</sup>。这一评价与优化思路为计算光学系统的发展提供了新的方向。

## 2 计算光学系统中的像差校正方法与应用

上述各类评价指标也为计算光学系统的端到端优化设计提供了可优化的目标函数<sup>[1,14-15]</sup>。Dun 等<sup>[14]</sup>在衍射消色差透镜设计中通过端到端优化范式联合学习光学元件与图像恢复网络,实现了成像质量的显著提升。Zhou 等<sup>[15]</sup>提出的软硬件联合优化框架通过可微分成像仿真系统估计制造偏差,结合主动对准与后处理网络实现了玻璃-塑料混合透镜系统的光学退化校正。这些研究推动了光学硬件与信息处理算法的协同设计与性能突破。像差校正如前所述,光学系统的成像质量受到像差的严重制约,传统方法主要依赖复杂透镜组设计与高精度加工工艺实现像差的被动抑制。然而,仅通过硬件手段实现高精度像差校正面临诸多困难。一方面,精密光学元件的设计与制造成本高昂,难以适应动态变化的像差场景;另一方面,对于大气湍流、生物组织散射及系统动态扰动引起的时变波前畸变,静态硬件补偿方案难以满足实时性与自适应性需求<sup>[10-11]</sup>。

因此,发展计算方法实现像差校正变得至关重要。本节主要讨论3类像差校正技术:以波前传感与变形镜闭环反馈为核心的AO技术,通过光学前端相位调制实现编码与解码协同的波前编码与编码孔径技术,以及无需硬件干预即可从强度测量中反演波前信息的相位恢复与盲解卷积技术。这些方法通过不同的技术路径,旨在突破传统硬件校正的性能瓶颈,实现更高精度的像差补偿,以更好地支持计算光学成像在天文观测、生物医学及精密检测等领域的应用。

### 2.1 自适应光学

AO是一种通过实时测量并补偿光学系统中动态波前误差来提高成像质量的技术<sup>[10-11]</sup>,其核心思想是在成像系统中引入可变形光学元件,通过“波前传感-控制-校正”闭环系统实时感知波前畸变并施加相反校正,从而在动态像差作用下恢复接近衍射极限的成像质量。该技术最早由Babcock<sup>[10]</sup>于1953年针对地基望远镜大气湍流问题提出,Linnik<sup>[12]</sup>于1957年独立提出了类似方案,奠定了AO技术的基本原理框架。经过半个多世纪的发展,AO技术已在天文观测、生物医学成像等领域取得了广泛应用。

在天文观测领域,AO已成为大型地基望远镜实现衍射极限分辨率的核心关键技术<sup>[11]</sup>,显著拓展了对微弱天体和系外行星的探测能力。甚大望远镜(Very large telescope, VLT)上的近红外自适应光学系统NACO(NAOS-CONICA)与使用人造激光导星的凯克望远镜,帮助根策尔和盖兹团队确认了银河系中心超大质量黑洞的存在,该成果获得了2020年诺贝尔物理学奖。此外,多目标AO技术还被应用于近地天体观测,实现了无需激光导星的大视场图像复原<sup>[51]</sup>。

在生物医学成像领域,AO技术同样展现出重要价值。在眼科成像中,AO将成像分辨率提升至单细胞级别<sup>[12]</sup>,集成了AO的眼底OCT、扫描激光检眼镜等设备,可清晰呈现以往因像差模糊而难以观测的微观病变结构,显著提升了临床检查精度。Joseph 等<sup>[52]</sup>基于此实现了活体视网膜内免疫细胞动态的

无标记成像。在显微成像中,传统显微镜因样品内折射率不均匀而难以在大成像深度下实现衍射极限分辨率。结合AO技术的共聚焦显微镜和多光子显微镜克服了这一限制,可观测活体大脑深层神经元的活动,实现了对传统光学方法难以触及的深层神经回路的可视化。Olivier等<sup>[53]</sup>在多谐波显微成像中验证了动态像差校正对于提升深层组织成像信号质量的重要性。

对比以硬件为基础的AO与前文中“纯计算方法”的典型算法——GS算法,针对二者在不同湍流条件下的相位校正性能,Li等<sup>[46]</sup>提供了定量的对比评估结果:弱湍流情况下,GS迭代方案略优于AO,表现出更高的剩余像差抑制能力;强湍流情况下,GS算法因易受测量误差影响而校正性能显著下降,而AO能够以更高的带宽实时跟踪并校正快速变化的相位扰动,显示出更好的校正效果。

上述所说的AO均为遵循“波前传感-控制-校正”结构,使用波前传感器的AO,但使用波前传感器通常要求亮度足够、高信噪比、波前斜率可解析。在无法使用明亮的参考光源或者难以直接获取波前相位信息的情况下,衍生出了无波前传感器AO。无波前传感器AO不仅克服了波前传感器的使用条件限制,还可以避免非公共光路的误差。

随机并行梯度下降(Stochastic parallel gradient descent, SPGD)算法就是一种无波前传感器AO优化策略<sup>[54]</sup>。在生物成像中,活体组织很难引入合适的“导星”来测量波前像差,Zhou等<sup>[54]</sup>提出了一种具有自适应增益系数的SPGD优化策略。如图2所示<sup>[54]</sup>,研究者们将改进的SPGD算法引入激光扫描共聚焦显微镜(Laser scanning confocal microscope, LSCM),动态调整每轮扰动幅度,实现在初始阶段快速接近最优区间,在收敛末期保持微调精度,大幅提升显微镜的分辨率和对比度。在自由空间光通信领域,大气湍流引起的波前畸变会严重降低接收端光纤的耦合效率。江杰等<sup>[13]</sup>将SPGD算法与少模光纤耦合解复用系统相结合,提高了光纤耦合效率与通信系统的稳定性。

尽管AO技术已发展了半个多世纪并在各大望远镜中广泛使用,但其核心原理和基本方法框架并未取得质的突破<sup>[55]</sup>。然而近年来,人工智能尤其是深度学习技术的发展为AO提供了新的研究思路。利用深度学习可以在AO系统的各个环节取得突破<sup>[56]</sup>:针对Shack-Hartmann波前传感器,使用卷积神经网络(Convolutional neural network, CNN)能够提升像斑质心定位精度,且在低信噪比下具有更强抗噪性和非线性适应能力;利用多层感知机(Multi-layer perceptron, MLP)或全连接神经网络实现从“像斑图像”到“波前相位图”的直接映射,可以大幅度减少波前重构的计算时间;使用深度学习构建金字塔波前传感器信号与波前畸变之间的映射模型,能够有效扩展金字塔波前传感器的线性响应范围,提高成像质量。针对无波前传感器AO,在深度学习的赋能下,系统可以跳过传统的波前测量与重构环节,从“图像”中直接获取像差。

Zhang等<sup>[21]</sup>还提出深度学习辅助的区域波前校正方法(Deep learning assisted zonal adaptive correc-




图2 结合AO成像系统的激光扫描共聚焦显微镜实物照片<sup>[54]</sup>

Fig.2 Photograph of the AO imaging system for LSCM<sup>[54]</sup>

tion, DLZAC),如图3所示,该方法将波前调控器划分为多个小区域,通过神经网络单独控制每一小片区域,提升空间自由度与精细度。

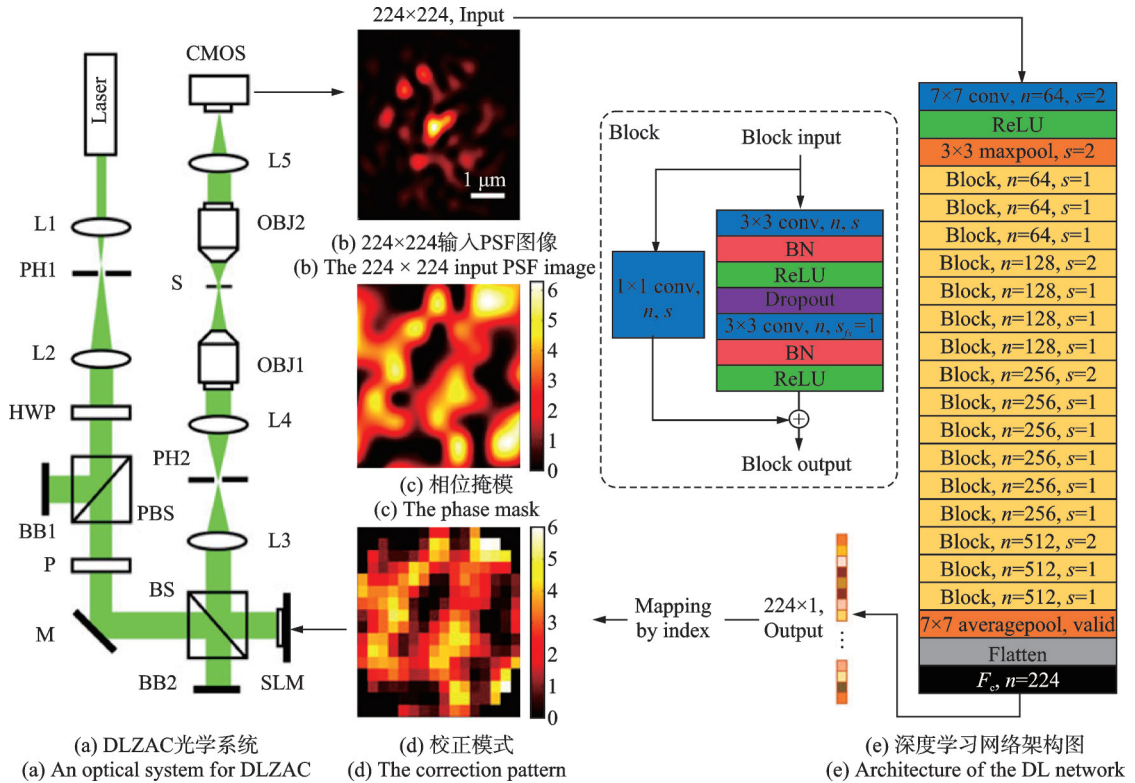


图3 DLZAC原理图<sup>[21]</sup>

Fig.3 Schematic diagram of DLZAC<sup>[21]</sup>

机器学习还被用于处理AO系统中的高维优化问题,例如多镜片多光束的AO<sup>[40]</sup>。深度学习和强化学习方法可以用来近似高维控制律或策略,实现复杂AO系统的协同控制。将深度学习用于湍流感知与校正已成为当前AO研究的前沿热点,深度神经网络驱动的智能湍流处理框架展示出巨大的潜力<sup>[34]</sup>。

## 2.2 波前编码与编码孔径

波前编码和编码孔径是计算成像体系中两类紧密相关但侧重点略有差异的光学编码策略。波前编码是在光学系统的孔径面引入特定设计的相位调制,抑制模糊的不确定性,减少系统对离焦和像差的敏感度,实现更大的景深或更稳定的成像质量。在波前编码方面,结合遗传算法等优化方法,还可实现SLM固有像差的自动校正<sup>[37]</sup>。随着微纳光学的发展,超构表面成为像差校正的新型平台,神经纳米光学成像器<sup>[57]</sup>与色差校正混合超构透镜<sup>[58]</sup>的出现,推动了轻量化系统的高质量成像。此外,波前编码的思想也被拓展至显示端,通过光场显示技术对观看者的视觉像差进行计算校正<sup>[59]</sup>。

如图4所示,衍射消色差透镜的结构参数与图像恢复算法在端到端优化范式下进行联合训练<sup>[14]</sup>。图4中, $I_\lambda$ 表示不同波长 $\lambda$ 下的光谱图像, $RSF_\lambda$ 表示对应波长下旋转对称成像模型的响应函数, $R_c$ 表示RGB传感器的光谱响应曲线, $\eta$ 表示加入的高斯噪声, $h$ 表示衍射消色差透镜的高度剖面参数, $L$ 表示损失函数。在每次前向传播中,具有光谱多样性的场景与具有光谱响应特性的旋转对称参数化衍射消色差透镜的PSF进行卷积。随后,在各通道集成RGB传感器的光谱响应后,向模拟生成的传感器图像中添加高斯噪声。接着采用1个神经网络(例如由两个基础网络单元组成的Res-UNet)作为图像恢复单

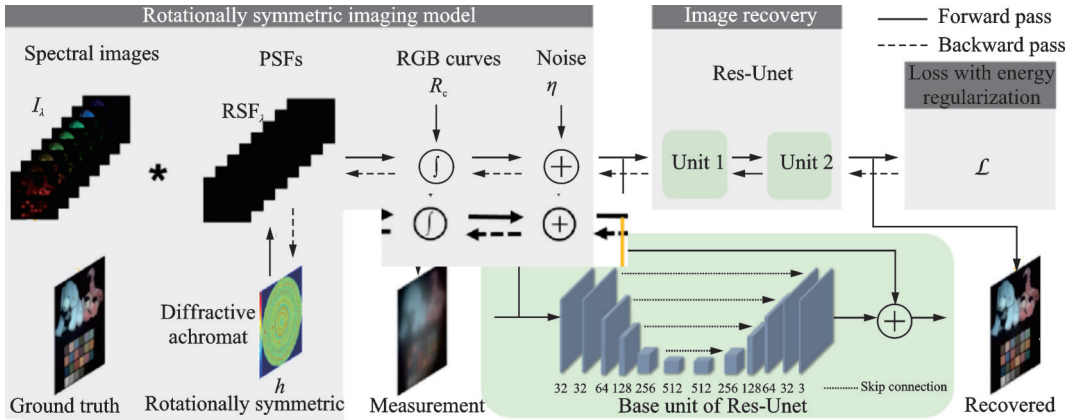



图4 端到端学习框架概览<sup>[14]</sup>

Fig.4 Overview of proposed end-to-end learning<sup>[14]</sup>

元,以重建高保真彩色图像。最后,针对恢复图像定义1个可微损失函数(如与真实值图像之间的均方误差)。此外,还引入了额外的能量正则化项,以强制光线汇聚在指定的传感器区域内。在反向传播过程中,误差将回传至图像恢复网络的可学习参数以及衍射消色差透镜的高度剖面参数中<sup>[14]</sup>。

编码孔径通过对光学系统的入射孔径进行特定空间结构的遮挡或重排,使成像系统获得具有独特编码特性的模糊核,增加观测信息维度并提升系统矩阵可逆性,进而反演原始场景的空间分布。编码孔径因具备对波长高度敏感、可编程控制色散以及适配宽光谱调制等优势,常被用于校正色差。Dun等<sup>[14]</sup>提出了一种基于深度学习优化的旋转对称衍射元件用于全光谱成像的方法。研究者们采用同轴同心环状的衍射结构,并通过端到端训练优化该元件的相位分布及配套重建网络,使系统在429~699 nm可见光范围内均能精确成像。这一方案实现了以单片超薄元件替代传统多片镜头组,达成了全色成像的效果,并为构建轻量化的全光谱相机奠定了基础。

Li等<sup>[60]</sup>在2025年提出了光学注意力机制,这是一种创新的编码孔径设计思想。该机制能够选择性地关注对高频信息传输有利的光学区域,针对性的光学编码使得系统在有限的孔径和体积下仍能高效传递图像的细节分量,有效提升了在宽视场或简化光学中的高频响应能力。Liu等<sup>[44]</sup>于2022年在校正色差的同时,还在重建过程中融入了深度学习的超分辨算法。他们设计的深度致密分区多路径残差网络(Deep dense zoned multipath residual, DDZMR)可以对衍射镜头成像的退化图像同时执行去卷积复原和超分辨重建,改善系统的有效分辨能力。DDZMR网络的图像重建能力如图5所示<sup>[44]</sup>。



(a) 探测器直接捕获的图像  
(a) The image captured directly by the detector  
(b) DDZMR网络重建的图像  
(b) The image reconstructed by the DDZMR network

图5 单透镜谐波衍射计算成像系统的分辨率靶标测试<sup>[44]</sup>

Fig.5 Resolution target imaging test of the single-lens harmonic diffraction computational imaging system<sup>[44]</sup>

### 2.3 相位恢复与盲解卷积

相位恢复和盲解卷积是现代计算成像领域中的两个重要逆问题。前者旨在从仅有幅值(强度)的观测中重建出信号或图像的相位信息;后者则需在未知 PSF 的情况下,从卷积模糊的观测中同时估计出原始图像和成像系统的模糊核<sup>[50]</sup>。相位恢复与盲解卷积问题普遍具有病态、非线性的特点,需要借助先验约束和算法迭代来获得解。

相位恢复的研究可追溯至1963年对唯一性问题的理论探讨<sup>[61]</sup>。早期迭代算法如误差缩减算法和混合输入输出算法(Hybrid input-output algorithm, HIO)奠定了从傅里叶模量重建对象的基础<sup>[3-4]</sup>,并在晶体学与光学领域间实现了方法融合<sup>[62]</sup>。与传统相移干涉测量技术<sup>[63]</sup>相比,相位恢复无需复杂的干涉光路。为克服非凸优化的困难,研究者发展了基于凸松弛的PhaseLift框架<sup>[18]</sup>以及基于帧理论的无相位重构方法<sup>[64]</sup>,并通过引入稀疏约束等先验提升了OCT等应用的重建质量<sup>[65]</sup>。

Balan等<sup>[66]</sup>在2009年进一步提出了快速的无相位重建算法,利用帧理论设计特殊观测模式,实现信号的直接重建。该方法在特殊的测量设计下可以降低算法的运算量,但对一般情况的适用性有限。为了在不显著增加计算复杂度的前提下获得更多有用信息,Alexeev等<sup>[67]</sup>于2014年提出了基于偏振的相位恢复方法,将干涉测量思想与图论相结合,通过在不同偏振状态下获取若干幅强度图,从中提取出原始信号的更多线性测量关系,然后使用高效算法重建相位。该方法通过适当的光学设计降低了相位恢复问题的病态成程度。

Ye等<sup>[31]</sup>在2022年将深度学习引入相位恢复与盲解卷积问题,提出了单帧端到端相位恢复网络(Single-shot phase retrieval network, SiSPRNet)。如图6所示,SiSPRNet通过精心设计的网络结构,将输入的傅里叶强度直接映射到目标相位<sup>[31]</sup>,其创新之处在于引入MLP作为前端特征提取模块,以利用观测的整体谱信息;MLP全局连接的架构使网络能够学习全局相位特征,同时抑制噪声干扰。此外,网络在上采样重建模块中融入自注意力机制,加强重建图像的全局相关性,并采用残差学习框架以避免深层网络训练中的梯度消失。该方法展示了以“大数据+大模型”方式解决复杂成像逆问题的能力。

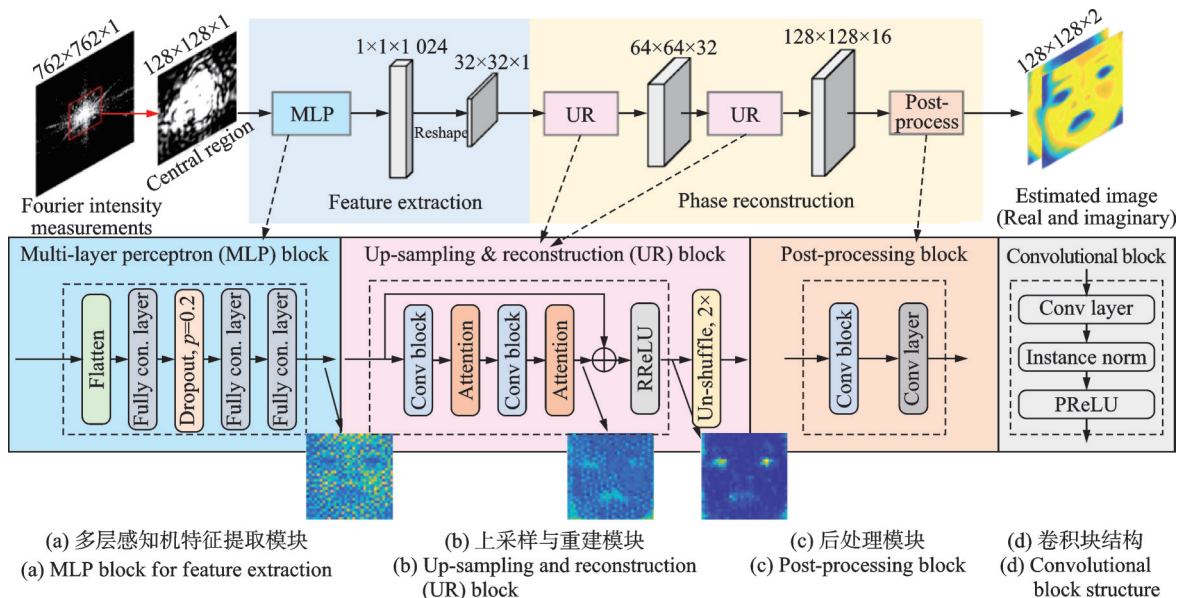


图6 SiSPRNet网络结构示意图<sup>[31]</sup>

Fig.6 Architecture of SiSPRNet<sup>[31]</sup>

上述方法在高效的同时,无法保证相应的重建精度。针对这一情况,Cao等<sup>[68]</sup>在2024年提出了一种闭式的复场重建方法(Angular ptychographic imaging with closed-form, APIC),如图7所示。该方法实现了在傅里叶迭代显微成像中以解析解形式重建复振幅场。首先依次点亮照明角度与物镜数值孔径(NA)相匹配的LED,以获取NA匹配测量数据;随后依次点亮照明角度大于物镜接收角的LED,以获取暗场测量数据<sup>[68]</sup>。APIC能够在无额外硬件辅助手段的条件下同时解析出成像系统的复杂像差分布,即实现对未知系统相位畸变的解析校正。通过避免迭代,APIC无需人工设定收敛判据,在数学解析上避免了传统迭代算法易陷入局部最优的问题。这项工作突破了传统纯计算方法的局限,证明高效与高精度并非不可兼得。

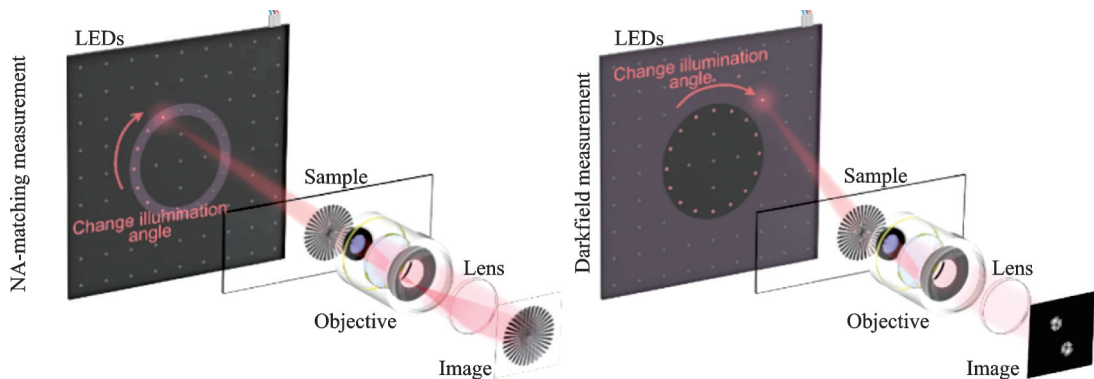


图7 角向叠层衍射成像闭式解析法的装置设置示意图<sup>[68]</sup>

Fig.7 Setup and illumination acquisition strategy of APIC<sup>[68]</sup>

在数字全息显微领域,传统的数字全息显微术(Digital holographic microscopy, DHM)在应用上需要在视场中留出无样本区域用于背景校正,或借助已知参考相位版来校准像差。为避免这些额外要求,Goud等<sup>[69]</sup>在2021年提出了一种离焦全息补偿方法,成功将纯计算相位复原应用到复杂的病理显微成像系统中。该方法在1台商用病理显微镜上集成了离轴数字全息成像,通过获取两幅干涉图(样本分别位于聚焦平面和略离焦的位置)来补偿球差像差。实验表明,该方法简单有效,使集成了DHM的显微系统能够获得无像差、高清晰度的三维相位成像结果,为无标签病理检查提供了可能。为了公平、有效地评估不同方法的性能,Elser等<sup>[50]</sup>率先建立了相位恢复算法的标准化基准测试体系。他们构建了1组专注于晶体学相位问题的分级相位恢复测试问题集,并提出了1个简单明确的判定标准,即根据晶体学实际需求定义重建成功或失败的客观指标,从而避免过去模棱两可的主观评价。

### 3 深度学习驱动的像差校正方法

随着计算成像技术的飞速发展,宽视场、高分辨率和轻量化光学系统的需求不断增长,这对光学系统像差的校正提出了新的要求。传统的像差校正主要依赖于基于复杂硬件的AO系统,或是基于物理模型的数值反演和盲反卷积方法,虽然在特定场景已经取得显著效果,但往往需要复杂昂贵的波前传感与校正器件,或依赖精确的成像模型与多轮迭代求解,对实时性和鲁棒性提出较高要求。为突破传统电子计算在处理高维光场数据时的速率与能耗瓶颈<sup>[70]</sup>,新兴的片上光计算架构已展现出纳秒级端到端处理的潜力。与此同时,算法层面也迎来了深度学习在图像恢复与重建领域的迅速发展,越来越多工作开始尝试采用数据驱动的像差校正策略,通过从大量退化/标注数据中自动学习退化特性和补偿规律,为复杂光学系统中的像差校正提供了新的技术路径。

### 3.1 数据驱动的像差校正方法

在计算成像框架下,数据驱动的像差校正通常不再从解析光学模型出发构建显式退化算子,而是借助深度学习在退化图像与目标图像之间直接学习映射关系。总体来看该方法可分为两类。一类是以波前或 PSF 的估计为核心,通过网络输入带像差的点源/星像图、散斑图案或其他辅助测量信号,预测连续波前分布或其 Zernike 多项式基底上的有限维系数。根据得到的像差信息,可以在数值重建阶段构造光学系统对应的 PSF/传递函数并执行反卷积,或通过驱动变形镜或可调相位元件在 AO 环路中实施补偿,从而在物理层面实现可解释的像差校正。另一类则将像差估计与图像复原合并为端到端任务,直接把退化图像映射为高质量重建结果,此时网络通常通过中间特征层来表征与像差相关的结构退化模式与细节信息,并在解码阶段实现联合补偿。在端到端网络架构设计方面,多阶段渐进式复原策略被证明能够有效应对像差导致的复杂退化:通过级联子网络逐步恢复图像的空间细节与上下文信息,在不同阶段分别处理大尺度模糊、高频细节和噪声伪影等子任务<sup>[71]</sup>,为像差校正提供了可借鉴的网络设计范式。总体而言,数据驱动方法对训练分布内的复杂多源退化往往表现出较强鲁棒性,但跨系统/跨分布泛化仍受数据覆盖与标定差异限制,相关问题将在后续进一步讨论<sup>[5,19]</sup>。

Wang 等<sup>[24]</sup>针对大气湍流成像中传统 Shack-Hartmann 波前传感依赖传感器、测量成本高且标定严格等问题,提出了一种基于深度学习的波前感知与像差校正方法,如图 8(a)所示。该方法的基本思想是利用卷积神经网络学习畸变强度分布——波前像差相位的映射关系,从而在不使用任何波前传感器的情况下重建湍流引入的像差相位分布,并进一步驱动变形镜或 SLM 进行补偿。为此,文献[24]构建了两条并行的网络分支,如图 8(b)所示:一条(CNN1)直接从畸变图像回归像差相位;另一条(CNN2)先预测有限阶 Zernike 系数再由此计算相位分布,两者的结构均借鉴 U-Net、残差块与 Inception 模块的多尺度特征提取机制,在保持网络深度的同时控制参数量并增强对不同尺度畸变特征的代表能力,成功验证了该方法在湍流池中的校正效果以及在实际大气湍流环境中的可行性。

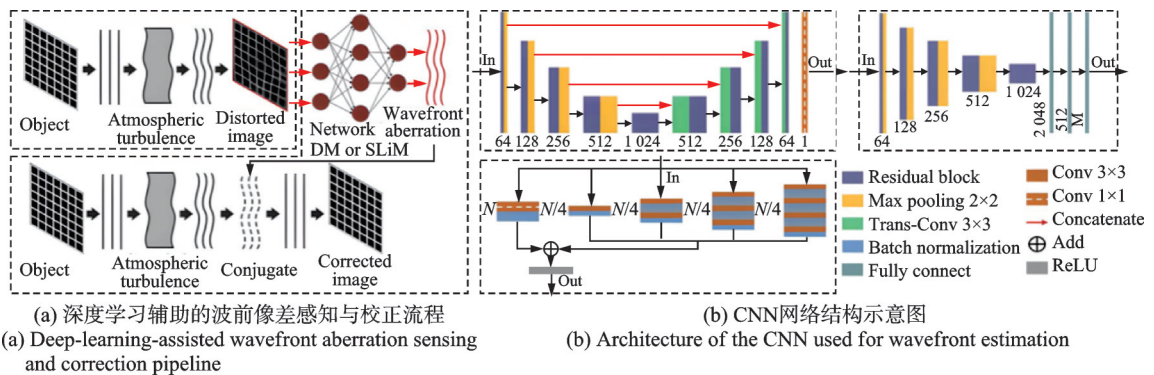


图 8 基于深度学习的大气湍流波前像差感知与校正框架及 CNN 网络结构示意图<sup>[24]</sup>

Fig.8 Deep-learning-based framework for wavefront aberration sensing and correction under atmospheric turbulence and architecture of the CNN for wavefront estimation<sup>[24]</sup>

Li 等<sup>[72]</sup>面向卫星-地面激光通信终端的 AO 实时需求,在单帧离焦光斑输入的深度学习波前传感(Deep learning wavefront sensing, DLWFS)框架下,基于 EfficientNet-B0 原型和 MBConv+SE 模块设计了轻量化波前传感网络 WFSNet,并通过多目标神经结构搜索在验证损失与每秒浮点运算次数(Floating-point operations per second, FLOPS)之间寻求折中。Efficient-WFSNet 架构如图 9(a)所示<sup>[72]</sup>,其中 Stem、MBConv 和 Head 分别表示网络的输入主干层、移动倒残差卷积模块和输出头,Out-

puts 表示网络输出的波前感知结果。图 9 (b) 的仿真与测试集评估表明<sup>[72]</sup>, 相对于改造后的 EfficientNet-B0 基线, Efficient-WFSNet 在前 35 阶 Zernike 模式的波前感知精度提升约 22%, 而计算量和推理时间分别降低约 80% 和 95%, 在“验证损失-FLOPs”平面上位于性能-开销的 Pareto 前沿, 展示了数据驱动波前传感在实时、低成本 AO 系统中的可行性。

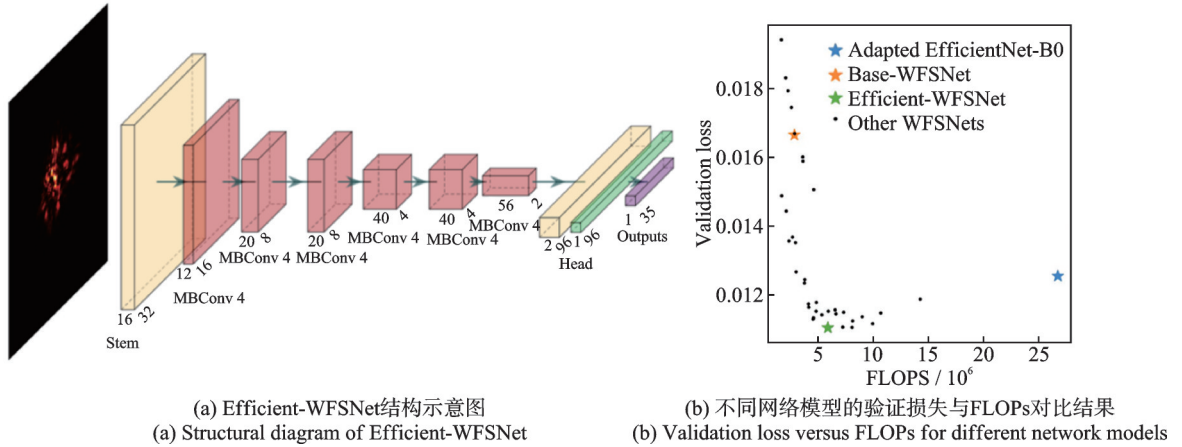


图 9 Efficient-WFSNet 的网络结构与性能-开销对比<sup>[72]</sup>  
Fig.9 Efficient-WFSNet architecture and performance-cost comparison<sup>[72]</sup>

Guo 等<sup>[73]</sup>提出了一种基于深度学习的像差补偿方法 (Deep learning-based aberration compensation, DeAbe), 用于在不增加额外硬件与成像时间的前提下提升荧光显微成像的对比度与分辨率, 如图 10 所示。该方法通过 Zernike 基函数构造与深度相关的合成像差来生成训练数据, 使网络学习从像差退化图像到高质量图像的映射, 从而实现对样本像差的逆向补偿。图 10 (b) 给出了 DeAbe 与传统去卷积方法的定量对比结果, DeAbe 在 SSIM 与 PSNR 上均表现更优, 表明其能够在复杂生物样本 (如 C.elegans 胚胎、小鼠胚胎及组织等) 的厚样本成像场景中有效改善成像质量, 并体现出对深层组织成像的优势。

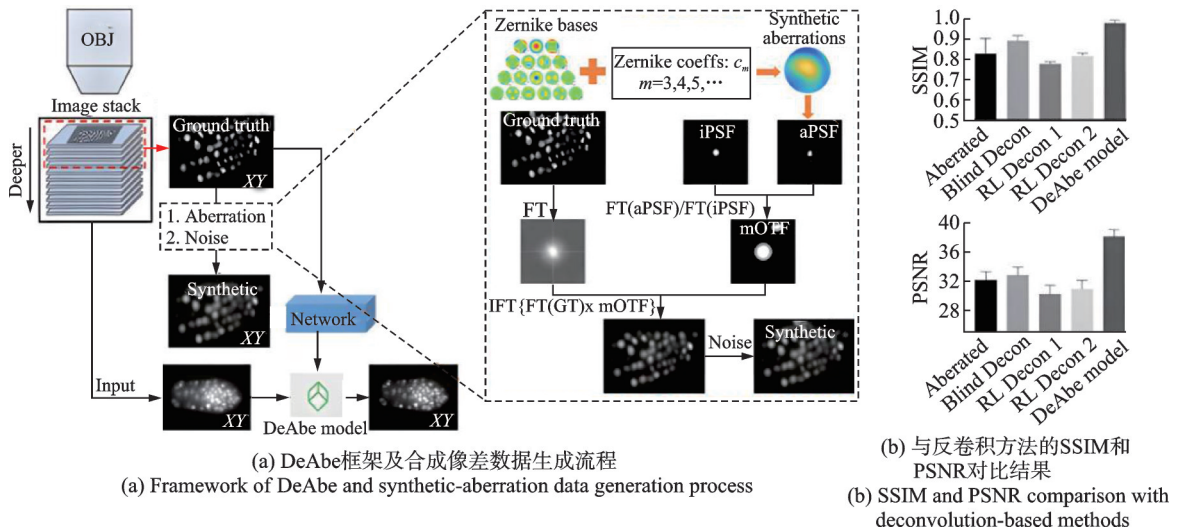


图 10 基于深度学习的荧光显微镜像差补偿方法 DeAbe 示意图<sup>[73]</sup>  
Fig.10 DeAbe for fluorescence microscopy aberration compensation<sup>[73]</sup>

尽管数据驱动方法在图像复原与像差补偿中取得显著进展,但仍存在3类共性瓶颈:(1)高质量训练数据依赖度高,一些特殊场景下真实数据难以获取,而通过合成得到的数据往往与真实数据之间存在差距,一定程度上也会影响深度神经网络的性能表现;另一方面,深度学习网络的训练通常依赖大规模的训练数据与正确标签,这无疑大量增加了模型的训练成本;(2)跨系统与跨分布泛化能力弱,当成像条件、目标特征或退化机理偏离训练覆盖范围时,模型输出的正确性可能会显著下降,为此在保证训练效率的情况下尽可能拓展训练数据的丰富性和规模可在一定程度上提高网络泛化能力;(3)物理可解释性差,深度学习网络是怎样抓取数据特征并构建数据输入与输出之间的映射关系,这个问题有待解决,此外解释性不足也不利于误差归因与工程应用方面的迁移。基于上述问题,近年来逐渐形成“物理模型嵌入+学习补偿”的混合范式,通过在训练数据、网络结构或损失设计中引入成像物理约束,以提升一致性、稳定性与可迁移性。

### 3.2 物理模型嵌入的深度学习

物理模型嵌入的深度学习本质上是一类兼具“数据先验”和“物理先验”的混合范式:一方面仍然利用神经网络的高维表征能力,在隐式特征空间中学习复杂的退化规律;另一方面,通过光学成像物理模型对网络的训练过程施加约束。具体而言,常见的做法是在数据构建和预处理阶段引入物理模型,用物理仿真或解析计算得到对应的退化图像,使训练样本在生成环节就携带一定物理特性;同时在网络设计中适当引入具有明确物理意义的量(例如表征像差或系统状态的参数),将其作为附加输入或用于构造损失函数,让神经网络在基本物理约束下负责难以解析建模的非线性残差补偿。

从成像的物理角度看,光学系统可用“光瞳函数对复振幅的调制+衍射传播”描述得到像面复场。在非相干强度成像条件下,系统常可等效为物体与强度PSF的卷积并叠加噪声。传统数值反演通常在成像算子已知或可参数化的前提下构建目标函数,通过迭代优化求解物体或像差参数;而在物理模型嵌入的深度学习框架中,成像物理模型既可以用于“网络外”的数据合成、监督信号与加权因子构造,也能以可微形式写入网络(如可微传播、可微卷积/OTF约束或可学习的波前编码),与神经网络联合训练以补偿物理模型难以覆盖的非线性残差与高频细节。相较于纯数据驱动方法,这种“物理约束+学习补偿”的协同方式不再要求网络从零开始估计退化核,而是先由光学物理模型对退化的基本形态进行限定,再由神经网络集中补偿模型误差和细节,有利于降低对标注数据规模的依赖,并提升跨系统、跨场景的泛化能力。

Zhou等<sup>[43]</sup>提出了一种基于像差建模的视图-通道-深度网络(Aberration-modeling view-channel-depth, AM-VCD)用于解决光场显微镜(Light field microscopy, LFM)中折射率不匹配导致的严重球差问题,如图11所示。该方法通过在光瞳面利用Zernike多项式对球差PSF建模,并据此生成带像差的LFM训练样本,将像差物理先验融入VCD深度网络的体重建框架。图11中, $s_1$ 和 $s_2$ 表示样品空间点在横向的坐标分量, $z$ 表示轴向深度坐标, $x_1$ 和 $x_2$ 表示相机平面上的横向坐标;①表示样品空间点与原始物镜像平面中图样之间的关系,②和③分别表示微透镜阵列(Microlens array, MLA)前后的PSF,其中②为理想衍射极限PSF,③为含球差的PSF。该方法通过实测PSF与理论PSF的SSIM进行比对来估计实际球差大小,在保持网络实时重建能力的同时,实现了在 $-0.9\lambda$ 等大球差条件下均匀分辨率的体成像,显著优于传统RL反卷积和原始VCD。但其像差建模目前主要集中于单一球差类型,尚未同时处理多种高阶像差和复杂折射率分布,后续可进一步向多像差联合建模和端到端软硬件协同优化扩展。

Zhang等<sup>[22]</sup>在厚组织单分子定位显微术(Single-molecule localization microscopy, SMLM)中提出了深度学习驱动自适应光学(Deep learning-driven adaptive optics, DL-AO)框架,如图12所示。图中 $p$ 、 $q$ 、 $N$ 和 $s$ 分别表示卷积核尺寸、特征通道数、特征图尺寸和下采样因子。其核心思路是在“波前物理模型

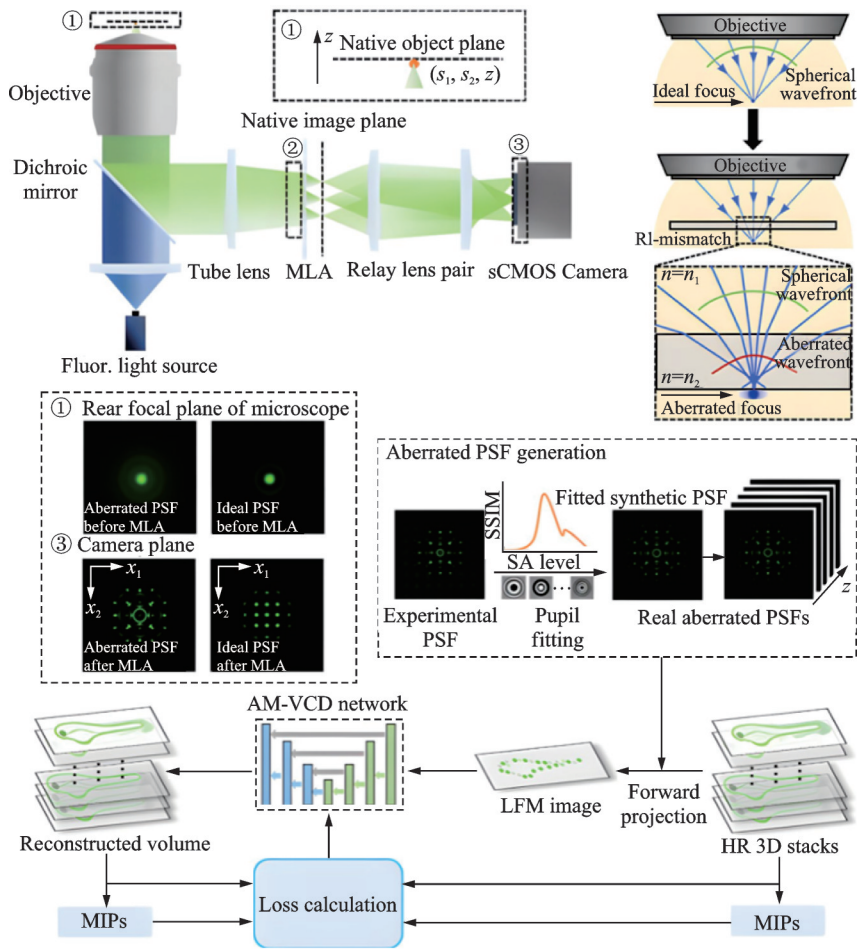


图 11 AM-VCD 网络及其球差建模与三维重建流程示意图<sup>[43]</sup>

Fig.11 AM-VCD framework for spherical aberration modeling and volumetric reconstruction<sup>[43]</sup>

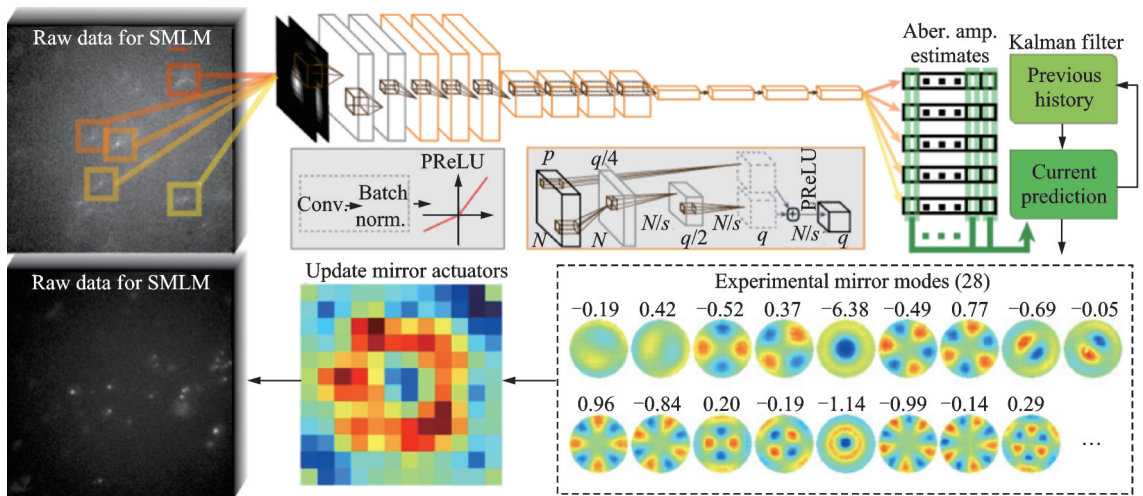


图 12 DL-AO 用于单分子定位显微的像差估计与校正流程<sup>[22]</sup>

Fig.12 DL-AO based aberration estimation and correction workflow for single-molecule localization microscopy<sup>[22]</sup>

+AO 硬件”之间插入一个深度网络:以单分子 PSF 图像为输入,通过卷积神经网络回归变形镜本征模的振幅系数。通过数值叠加不同本征模得到一系列畸变波前,并计算其对应的 PSF,将“镜面模态系数向量-单分子 PSF 图像”成对作为训练数据,使网络在有限个镜面模态空间内学习逆映射,与直接在图像域做“黑盒”复原不同,DL-AO 将像差表示为硬件本征模系数,深度网络只负责从退化 PSF 中估计这些系数,进而驱动 AO 镜面完成校正。类似的物理驱动策略在多种显微模态中均有应用:左嘉乐等<sup>[30]</sup>针对无透镜全息成像,提出了双输入物理驱动网络以消除孪生像干扰;Zhang 等<sup>[74]</sup>结合可微光学设计与深度重建,实现了紧凑型显微镜的大景深成像;Aakhte 等<sup>[29]</sup>在光片显微镜中实现了各向同性的像差校正;Gong 等<sup>[75]</sup>则提出了 TACO 方法,解决了结构光照明显微镜(Structured illumination microscopy, SIM)中空间变化像差的校正难题。

Swanson 等<sup>[33]</sup>针对地基望远镜在 AO 校正后仍受残余像差和图像欠采样限制的问题,将变形镜视作可编程波前编码器:在实时补偿大气湍流的同时叠加幅度受限的小相位扰动,生成多帧具有不同 PSF 和亚像素位移的观测序列,并通过改造的增强型深度超分辨率网络(Enhanced deep super-resolution, EDSR)进行多帧联合重建,在端到端框架下同时学习相位编码序列与超分网络权重。以数值仿真的 USAF 分辨率板为例(图 13)<sup>[33]</sup>,相比仅训练 CNN 而不优化相位的基线方法,引入小相位的联合优化方案在细线条分辨、边缘锐度和伪影抑制方面均更接近高分辨“真值”,对应的均方根误差(Root mean squared error, RMSE)也更低,在不增加额外硬件的前提下,通过 AO 与深度学习协同可以实现“残余像差校正+采样增强”的一体化天文成像。

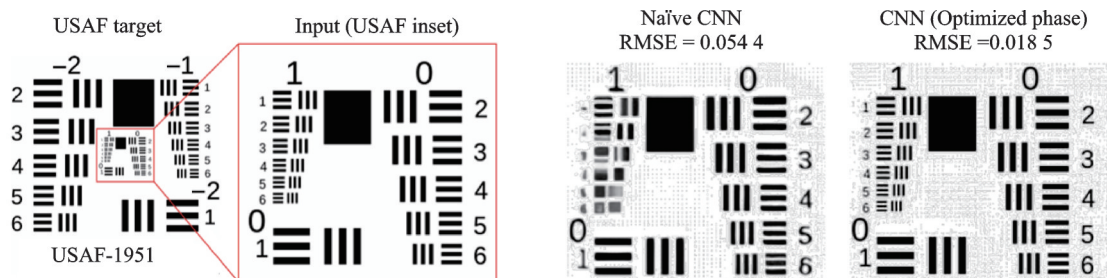


图 13 模拟 USAF 分辨率靶标上相位-CNN 联合优化的超分辨重建结果<sup>[33]</sup>

Fig.13 Super-resolution reconstruction results on a simulated USAF resolution target with jointly optimized phase and CNN<sup>[33]</sup>

### 3.3 无监督/少样本学习架构

与前两节中依托配准样本、实测 PSF 或像差参数等强监督/间接监督信号的学习框架不同,本节聚焦于标注极其有限甚至完全缺失条件下的像差校正问题。前述工作在其设定的实验条件下,已经充分证明了有监督下像差补偿与成像质量提升的有效性。然而当这类方法面对厚组织显微、无透镜极简成像以及工程镜头批量检测等更复杂的应用场景时,大规模获取与真实条件高度匹配的数据往往需要付出较高的实验和标定成本,给有监督方法的直接应用带来一定挑战。为缓解这一类“缺数据、缺标签”问题,近年来逐渐兴起了无监督/少样本学习架构,通过自监督约束或预训练通用复原模型以实现像差校正与成像质量提升。

Sharifzadeh 等<sup>[25]</sup>提出了一种基于像差对像差策略的像差诱导噪声抑制框架(Mitigating aberration-induced noise-aberration-to-aberration approach, MAIN-AAA),用于平面波超声成像中的相位像差校正,如图 14 所示。该方法基于近场相位屏物理模型,在仿真与实验系统中向发射和接收通路显式注入随机时间延迟,为同一散射体生成多组带像差射频(Radio frequency, RF)数据;随后以 U-Net

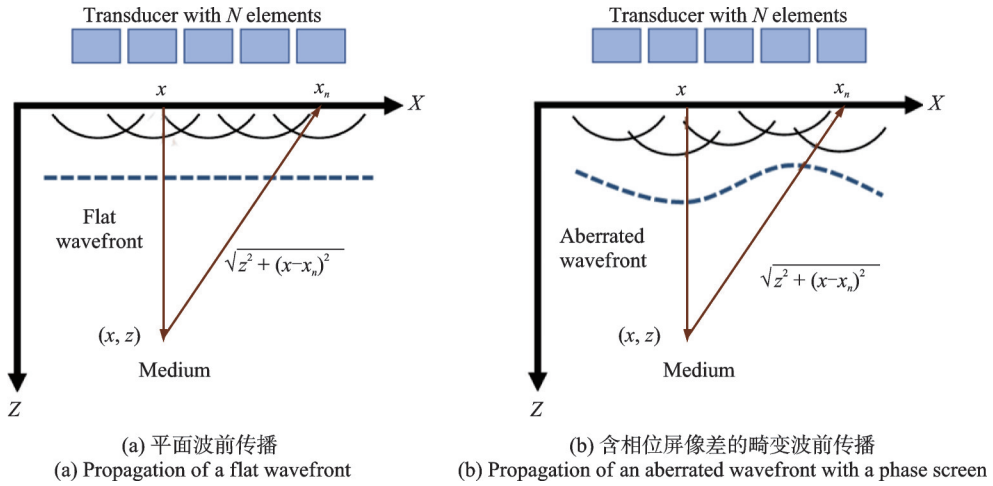


图 14 MAIN-AAA 近场相位屏像差模型示意图<sup>[25]</sup>

Fig.14 Near-field phase-screen aberration model in MAIN-AAA<sup>[25]</sup>

在不同随机像差版本之间学习映射,在不使用无像差参考图像的前提下,通过类似 Noise2Noise 的自监督训练统计性地抑制相位像差诱导噪声。结合由 B 模式损失逐步过渡到 RF 损失的自适应混合目标函数,MAIN-AAA 在仿真、体模和体内数据上显著提升了对比度和边界锐利度,体现了“物理可控扰动+自监督学习”在缺乏干净参考和精确波前标签条件下进行像差校正的潜力。

Alshaabi 等<sup>[28]</sup> 针对 AO 晶格光片显微成像 (Adaptive optical lattice light sheet microscopy, AO-LLSM) 中组织诱导像差导致分辨率和对比度显著退化的问题,提出了一种基于傅里叶域三维多阶段 Transformer 的 AO 视觉傅里叶 Transformer (Adaptive optical vision Fourier Transformer, AOViFT) 框架,如图 15 所示。该方法基于检测通道点散射物理模型与光片 PSF,用 11 个 Zernike 模对光瞳相位进行参数化,在仿真端生成约 200 万个覆盖不同像差模式、信噪比和点源分布的三维体数据,并从嵌入 OTF 先验的傅里叶幅度/相位平面中学习体数据与 Zernike 系数之间的映射,从而实现快速波前估计与

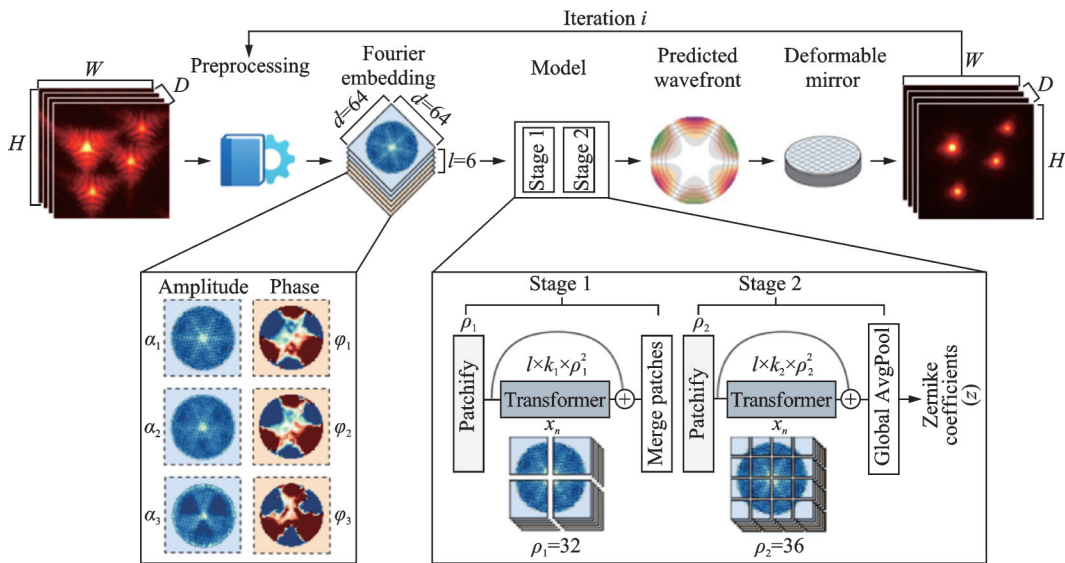


图 15 AOViFT 框架用于 AO-LLSM 的像差估计与校正<sup>[28]</sup>

Fig.15 AOViFT for AO-LLSM aberration estimation and correction<sup>[28]</sup>

校正。与 MAIN-AAA 依赖自监督约束不同, AOVIFT 主要通过大规模物理仿真构建合成监督数据进行一次性预训练, 从而降低真实标注与系统标定成本, 并为后续少量实测数据适配提供基础。

深度学习的引入推动了像差校正范式从传统的“物理驱动迭代反演”向“数据驱动智能推理”的根本性变革<sup>[19-20]</sup>。尤其是融合物理先验与自监督机制(如 MAIN-AAA)的策略<sup>[25]</sup>, 有效规避了传统方法对大规模成对真值数据的依赖, 并在处理高阶非线性像差时展现出卓越的计算效率与鲁棒性, 显著提升了在无波前传感场景下的实时校正能力。

计算光学像差校正体系的核心机制在于通过物理层光场调制与数字层信息解算的协同优化, 突破了传统成像系统在分辨率、视场与系统复杂度之间的固有权衡。传统的 AO 技术虽能凭借硬件闭环实现接近衍射极限的动态校正<sup>[10-12]</sup>, 但高昂的系统成本与复杂的波前传感链路限制了其普适性; 波前编码<sup>[14, 60]</sup>与相位恢复<sup>[16, 50]</sup>技术则分别通过相位掩模编码与强度传输反演, 在允许一定信噪比损耗或时间分辨率牺牲的前提下, 实现了成像景深的延展与系统架构的极简。而深度学习作为一种新兴的计算范式, 为克服上述确定性方法中的计算瓶颈与模型失配问题提供了关键的解决方案<sup>[22, 70]</sup>。表 2 归纳了自适应光学、波前编码、相位恢复与盲解卷积以及深度学习等主要计算光学信息处理技术的核心原理、优势与局限性, 另外还引入了处理耗时这一比较维度, 突出了不同技术路径在算法实现层面的差异<sup>[16, 17, 42]</sup>。该维度直接反映了各类方法的数据处理规模与算法效率, 为实际数据采集与处理系统中的方法选择提供参考。

表 2 主要计算光学信息处理技术对比

Table 2 Comparison of main computational optical information processing techniques

方法名称	核心原理	优势	局限性	处理耗时
自适应光学	闭环反馈, 硬件控制	可实现物理层实时动态校正, 精度高	系统复杂, 依赖波前传感器, 硬件成本高	实时控制, 单次处理延迟较低
波前编码与编码孔径	光学编码结合数字解码	扩展景深, 系统紧凑	依赖后处理算法, 信噪比损失	需后端数字重建, 处理时间中等
相位恢复与盲解卷积	基于迭代优化的非线性逆问题求解	无需额外硬件, 可处理未知退化模型	属于病态问题, 收敛依赖初值与正则化	需多轮迭代优化, 处理时间较长
深度学习(数据驱动)	神经网络非线性映射	推理速度快, 端到端处理复杂高阶像差	泛化能力受训练分布限制	训练阶段耗时较高, 推理阶段较快

## 4 结束语

本文围绕计算光学系统中的像差校正技术, 对理论基础、主流方法及深度学习应用进行了系统介绍。像差校正的理论基础主要围绕波前像差的数学表征与光场退化建模展开, 基于 Zernike 多项式的波前展开方法为像差的定量描述提供了正交完备的基函数体系, 像差主导的 PSF 退化模型则建立了波前畸变与成像质量之间的定量关系。在经典复原算法中, 维纳滤波、约束最小二乘滤波等线性方法通过频域逆滤波实现像差补偿, Richardson-Lucy 迭代、最大后验估计等非线性方法则通过引入先验约束逐步逼近理想图像。像差校正的主流技术可从主动调节、光学编码与纯计算复原 3 个维度进行分析: AO 技术依赖波前传感器对波前误差的实时监测, 通过变形镜的闭环反馈实现动态像差补偿, 进而重建出接近衍射极限的高分辨率图像; 波前编码与编码孔径技术通过在光学前端引入特定设计的相位调制元件, 将复杂像差转化为具有编码特性的退化形式, 结合后端解卷积算法实现图像复原; 相位恢复与盲解卷积技术则无需硬件干预, 仅通过算法从强度测量中反演波前相位或未知模糊核。深度学习技术的引

人推动了像差校正从纯物理模型反演向数据驱动与物理融合的双驱动范式转变,数据驱动方法通过端到端学习直接建立退化图像与清晰图像之间的映射,物理模型嵌入方法将光学成像约束融入网络架构以增强可解释性与泛化能力,无监督学习方法则有效降低了对大规模标注数据的依赖。上述技术不仅限于补偿成像缺陷,更可在给定硬件条件下突破传统光学系统的成像极限,实现对光场信息的精细调控与高质量重建。

像差校正技术已在天文观测、生物医学成像及无透镜成像等诸多领域取得成功,但仍存在一系列问题有待解决:(1)经典复原算法求解的是一个严重的病态逆问题,退化图像中丢失的高频信息难以完全恢复,重建结果对噪声敏感;(2)根据物理过程简化得到的像差退化模型与真实成像过程仍有差距,如何结合光学系统、探测器特性及环境扰动整体建模,发展更加精确的退化描述是一个难点;(3)AO系统结构复杂、成本高昂,且对波前传感条件要求严格,在缺乏导星或参考光源的场景下应用受限,亟需发展轻量化结构或无波前传感的替代方案,以拓展其应用边界;(4)数据驱动方法的泛化能力受训练数据分布限制,当成像系统参数、环境条件或目标特征偏离训练覆盖范围时,模型性能可能显著下降。针对这一问题,当前研究逐渐从单一数据拟合转向“跨域适配”思路:一方面,通过域适应策略缩小不同系统间的数据分布差异,提高模型在跨设备、跨成像条件下的稳定性;另一方面,借助迁移学习在大规模仿真或通用数据上进行预训练,再针对具体系统进行轻量化再训练或参数微调,以降低对目标系统大规模标注数据的依赖;此外,结合少样本微调或在线快速校准机制,使模型能够利用少量标定样本实现快速适配,也为复杂场景中的实际部署提供了可行路径;(5)光学系统简化与成像质量保持之间的平衡仍需深入探索,如何在紧凑型或轻量化系统中通过可微分光学模型与端到端软硬件协同优化策略,实现“硬件减负、计算增强”的协同设计,是未来计算光学发展的重要趋势。

#### 参考文献:

- [1] 邵晓鹏, 刘飞, 李伟, 等. 计算成像技术及应用最新进展[J]. 激光与光电子学进展, 2020, 57(2): 020001.  
SHAO Xiaopeng, LIU Fei, LI Wei, et al. Latest progress in computational imaging technology and application[J]. Laser & Optoelectronics Progress, 2020, 57(2): 020001.
- [2] 顿雄, 付强, 李浩天, 等. 计算成像前沿进展[J]. 中国图象图形学报, 2022, 27(6): 1840-1876.  
DUN Xiong, FU Qiang, LI Haotian, et al. Frontier advances in computational imaging[J]. Journal of Image and Graphics, 2022, 27(6): 1840-1876.
- [3] BORN M, WOLF E, BHATIA A B. Principles of optics: Electromagnetic theory of propagation, interference and diffraction of light[M]. Cambridge: Cambridge University Press, 1999.
- [4] GOODMAN J W. Introduction to Fourier optics[M]. New York: McGraw-Hill Book Company, 1968.
- [5] 左超, 冯世杰, 张翔宇, 等. 深度学习下的计算成像: 现状, 挑战与未来[J]. 光学学报, 2020, 40(1): 0111003.  
ZUO Chao, FENG Shijie, ZHANG Xiangyu, et al. Computational imaging with deep learning: Status, challenges and future [J]. Acta Optica Sinica, 2020, 40(1): 0111003.
- [6] 史浩东, 范瑞晗, 王稼禹, 等. 快照式高光谱偏振变焦成像光学系统设计[J]. 光学学报, 2025, 45(1): 0122001.  
SHI Haodong, FAN Ruihan, WANG Jiayu, et al. Optical system design of a snapshot hyperspectral polarization zoom imaging system[J]. Acta Optica Sinica, 2025, 45(1): 0122001.
- [7] MAHAJAN V N. Zernike polynomial and wavefront fitting[C]//Proceedings of Optical Shop Testing. Bellingham: SPIE, 2007: 498-546.
- [8] 孟章, 丁浩, 聂守平, 等. 深度学习在数字全息显微成像中的应用[J]. 激光与光电子学进展, 2021, 58(18): 1811006.  
MENG Zhang, DING Hao, NIE Shouping, et al. Applications of deep learning in digital holographic microscopy imaging[J]. Laser & Optoelectronics Progress, 2021, 58(18): 1811006.
- [9] MAKITA S, FUKUTAKE N, ZHU L, et al. Image formation theory of optical coherence tomography with optical aberrations and its application to computational aberration correction[J]. Biomedical Optics Express, 2025, 16: 4662-4688.

- [10] HARDY J W. Adaptive optics for astronomical telescopes[M]. Oxford: Oxford University Press, 1998.
- [11] HAMPSON K M, TURCOTTE R, MILLER D T, et al. Adaptive optics for high resolution imaging[J]. *Nature Reviews Methods Primers*, 2021, 1: 68.
- [12] 姜文汉. 自适应光学发展综述[J]. *光电工程*, 2018, 45(3): 170489.  
JIANG Wenhan. A review of adaptive optics development[J]. *Opto-Electronic Engineering*, 2018, 45(3): 170489.
- [13] 江杰, 郭宏翔, 边奕铭, 等. 基于 SPGD 算法的少模光纤耦合解复用系统动态湍流补偿仿真[J]. *光学学报*, 2021, 41(19): 1901001.  
JIANG Jie, GUO Hongxiang, BIAN Yiming, et al. Simulation of dynamic turbulence compensation for a few-mode fiber coupling demultiplexing system based on the SPGD algorithm[J]. *Acta Optica Sinica*, 2021, 41(19): 1901001.
- [14] DUN X, IKOMA H, WETZSTEIN G, et al. Learned rotationally symmetric diffractive achromat for full spectrum computational imaging[J]. *Optica*, 2020, 7: 913-922.
- [15] ZHOU J, CHEN B, YAN J, et al. Optical degradation correction of manufacturing perturbed glass plastic hybrid lens systems via a joint hardware software optimization framework[J]. *Optics Express*, 2024, 32: 25866-25882.
- [16] FIENUP J R. Reconstruction of an object from the modulus of its Fourier transform[J]. *Optics Letters*, 1978, 3: 27-29.
- [17] FIENUP J R. Phase retrieval algorithms: A comparison[J]. *Applied Optics*, 1982, 21: 2758-2769.
- [18] CANDÈS E J, ELDAR Y C, STROHMER T, et al. Phase retrieval via matrix completion[J]. *SIAM Review*, 2015, 57: 225-251.
- [19] 王一同, 周宏强, 闫景道, 等. 基于深度学习算法的计算光学研究进展[J]. *中国激光*, 2021, 48(19): 1918004.  
WANG Yitong, ZHOU Hongqiang, YAN Jingxiao, et al. Progress in computational optics based on deep learning algorithms [J]. *Chinese Journal of Lasers*, 2021, 48(19): 1918004.
- [20] 王长淼, 李晖, 张水平, 等. 基于深度学习的光场显微像差校正[J]. *光学学报*, 2024, 44(14): 1408001.  
WANG Zhangmiao, LI Hui, ZHANG Shuiping, et al. Deep learning-based light-field microscopy aberration correction[J]. *Acta Optica Sinica*, 2024, 44(14): 1408001.
- [21] ZHANG B, ZHU J, SI K, et al. Deep learning assisted zonal adaptive aberration correction[J]. *Frontiers in Physics*, 2021, 8: 621966.
- [22] ZHANG P, MA D, CHENG X, et al. Deep learning driven adaptive optics for single molecule localization microscopy[J]. *Biophysical Journal*, 2023, 122(3): 430a.
- [23] WANG K, LAM EY. Deep learning phase recovery: data driven, physics driven, or a combination of both? [J]. *Advanced Photonics Nexus*, 2024, 3: 056006.
- [24] WANG K, ZHANG M, TANG J, et al. Deep learning wavefront sensing and aberration correction in atmospheric turbulence [J]. *Photonix*, 2021, 2: 8.
- [25] SHARIFZADEH M, GOUDARZI S, TANG A, et al. Mitigating aberration induced noise: A deep learning based aberration to aberration approach[J]. *IEEE Transactions on Medical Imaging*, 2024, 43: 4380-4392.
- [26] QIAO C, CHEN H, WANG R, et al. Deep learning based optical aberration estimation enables offline digital adaptive optics and super resolution imaging[J]. *Photonics Research*, 2024, 12: 474-484.
- [27] GUO H, XU Y, LI Q, et al. Improved machine learning approach for wavefront sensing[J]. *Sensors*, 2019, 19: 3533.
- [28] ALSHAABI T, MILKIE D E, LIU G, et al. Fourier based three dimensional multistage transformer for aberration correction in multicellular specimens[J]. *Nature Methods*, 2025, 22(10): 2171-2179.
- [29] AAKHTE M, MÜLLER G F, ROOS L, et al. Isotropic, aberration corrected light sheet microscopy for rapid high resolution imaging of cleared tissue[J]. *Nature Biotechnology*, 2025. DOI:10.1038/s41587-025-02882-8.
- [30] 左嘉乐, 张蒙蒙, 唐唯, 等. 基于物理模型驱动无监督学习的无透镜成像质量增强方法[J]. *光学学报*, 2024, 44(16): 1611001.  
ZUO Jiale, ZHANG Mengmeng, TANG Ju, et al. Lensless imaging quality enhancement method driven by physical model and unsupervised learning[J]. *Acta Optica Sinica*, 2024, 44(16): 1611001.
- [31] YE Q, WANG L W, LUN D P. SiSPRNet: End to end learning for single shot phase retrieval[J]. *Optics Express*, 2022, 30: 31937-31958.

- [32] WU J, BOOMINATHAN V, VEERARAGHAVAN A, et al. Real time, deep learning aided lensless microscope[J]. *Biomedical Optics Express*, 2023, 14: 4037-4051.
- [33] SWANSON R, LIN E Y H, LAMB M, et al. Super resolved imaging with adaptive optics[C]//*Proceedings of the IEEE/CVF International Conference on Computer Vision*. New York: IEEE, 2025: 29142-29152.
- [34] LIU Q, DI Y, ZHANG M, et al. Research progress on atmospheric turbulence perception and correction based on adaptive optics and deep learning[J]. *Advanced Photonics Research*, 2025, 6: 2400204.
- [35] WU J, GUO Y, DENG C, et al. An integrated imaging sensor for aberration corrected 3D photography[J]. *Nature*, 2022, 612: 62-71.
- [36] WU Y, WANG J, CHEN C, et al. Adaptive weighted Gerchberg-Saxton algorithm for generation of phase only hologram with artifacts suppression[J]. *Optics Express*, 2021, 29: 1412-1427.
- [37] ROIVAINEN M. Aberration correction of a spatial light modulator with a genetic algorithm[D]. Tampere: Tampere University, 2024.
- [38] 陈善勇, 卢劲丰, 薛帅. 波面干涉测量中的可变像差补偿技术[J]. *激光与光电子学进展*, 2017, 54(4): 040004.  
CHEN Shanyong, LU Jinfeng, XUE shuai. Variable aberration compensation technique in wavefront interferometric measurement[J]. *Laser & Optoelectronics Progress*, 2017, 54(4): 040004.
- [39] 吕颖, 张轶楠. 激光加工中折射率失配像差的动态补偿研究[J]. *物理化学进展*, 2025, 14(2): 353-362.  
LYU Ying, ZHANG Yinan. Dynamic compensation of refractive-index mismatch aberration in laser processing[J]. *Journal of Advances in Physical Chemistry*, 2025, 14(2): 353-362.
- [40] WANG Y, JIANG F, JU G, et al. Deep learning wavefront sensing for fine phasing of segmented mirrors[J]. *Optics Express*, 2021, 29: 25960-25978.
- [41] CORSARO C, PELLERITI P, CRUPI V, et al. Adaptive aberration correction for laser processes improvement[J]. *Journal of Manufacturing and Materials Processing*, 2025, 9: 105.
- [42] SHECHTMAN Y, ELДАР Y C, COHEN O, et al. Phase retrieval with application to optical imaging[J]. *IEEE Signal Processing Magazine*, 2015, 32: 87-109.
- [43] ZHOU Y, JIN Z, ZHAO Q, et al. Aberration modeling in deep learning for volumetric reconstruction of light-field microscopy [J]. *Laser & Photonics Reviews*, 2023, 17: 2300154.
- [44] LIU K, YU X, XU Y, et al. Computational imaging for simultaneous image restoration and super resolution image reconstruction of single lens diffractive optical system[J]. *Applied Sciences*, 2022, 12(9): 4753.
- [45] FIENUP J R. Phase retrieval algorithms: A personal tour[J]. *Applied Optics*, 2012, 52: 45-56.
- [46] LI M. Phase corrections with adaptive optics and Gerchberg-Saxton iteration: A comparison[J]. *IEEE Access*, 2019, 7: 147534-147541.
- [47] NG G C, WORRELL S S, FREIBURGER P D, et al. A comparative evaluation of several algorithms for phase aberration correction[J]. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 1994, 41: 631-643.
- [48] GINNER L, KUMAR A, FECHTIG D, et al. Noniterative digital aberration correction for cellular resolution retinal optical coherence tomography in vivo[J]. *Optica*, 2017, 4: 924-931.
- [49] 南亦澜, 申俊飞, 张启灿. 基于多光谱融合的端到端计算成像[J]. *激光与光电子学进展*, 2022, 59(20): 2011010.  
NAN Yilan, SHEN Junfei, ZHANG Qican. End-to-end computational imaging based on multispectral fusion[J]. *Laser & Optoelectronics Progress*, 2022, 59(20): 2011010.
- [50] ELSER V, LAN T Y, BENDORY T. Benchmark problems for phase retrieval[J]. *SIAM Journal on Imaging Sciences*, 2018, 11: 2429-2455.
- [51] WEDDELL S, CLARE R, LAMBERT A. Near earth object image restoration with multi-object adaptive optics[C]//*Proceedings of the 1st NEO and Debris Detection Conference*. Darmstadt, Germany: ESA Space Safety Programme Office, 2019: 22-24.
- [52] JOSEPH A, CHU C J, FENG G, et al. Label free imaging of immune cell dynamics in the living retina using adaptive optics [J]. *Elife*, 2020, 9: e60547.
- [53] OLIVIER N, DÉBARRE D, BEAUREPAIRE E. Dynamic aberration correction for multiharmonic microscopy[J]. *Optics*

Letters, 2009, 34: 3145-3147.

- [54] ZHOU K, WU Z, ZHANG T, et al. Active aberration correction with adaptive coefficient SPGD algorithm for laser scanning confocal microscope[J]. *Sensors*, 2022, 22: 3755.
- [55] GUO Y, ZHONG L, MIN L, et al. Adaptive optics based on machine learning: A review[J]. *Opto-Electronic Advances*, 2022, 5(7): 200082-1.
- [56] 胡逸雯, 刘鑫, 匡翠方, 等. 基于深度学习的自适应光学技术研究进展及展望[J]. *中国激光*, 2023, 50(11): 1101009.  
HU Yiwen, LIU Xin, KUANG Cui Fang, et al. Review and outlook of deep learning-based adaptive optics technology research [J]. *Chinese Journal of Lasers*, 2023, 50(11): 1101009.
- [57] TSENG E, COLBURN S, WHITEHEAD J, et al. Neural nano optics for high quality thin lens imaging[J]. *Nature Communications*, 2021, 12: 6493.
- [58] HU T, WEN L, LI H, et al. Aberration corrected hybrid metalens for longwave infrared thermal imaging[J]. *Nanophotonics*, 2024, 13: 3059-3066.
- [59] QIU Y, ZHAO Z, YANG J, et al. Light field displays with computational vision correction for astigmatism and high order aberrations with real time implementation[J]. *Optics Express*, 2023, 31(4): 6262-6280.
- [60] LI Z, TAN F, ZHANG R, et al. Optical attention mechanism for high resolution computational imaging[J]. *Optica*, 2025, 12 (10): 1647-1656.
- [61] WALTHER A. The question of phase retrieval in optics[J]. *Optica Acta: International Journal of Optics*, 1963, 10: 41-49.
- [62] MILLANE R P. Phase retrieval in crystallography and optics[J]. *Journal of the Optical Society of America A*, 1990, 7: 394-411.
- [63] CREATH K. Phase measurement interferometry techniques[J]. *Progress in Optics*, 1988, 26: 348-393.
- [64] BALAN R, CASAZZA P, EDIDIN D. On signal reconstruction without phase[J]. *Applied and Computational Harmonic Analysis*, 2006, 20: 345-356.
- [65] MUKHERJEE S, SEELAMANTULA C S. An iterative algorithm for phase retrieval with sparsity constraints: Application to frequency domain optical coherence tomography[C]//*Proceedings of 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Kyoto, Japan: IEEE, 2012: 553-556.
- [66] BALAN R, BODMANN BG, CASAZZA PG, et al. Painless reconstruction from magnitudes of frame coefficients[J]. *Journal of Fourier Analysis and Applications*, 2009, 15: 488-501.
- [67] ALEXEEV B, BANDEIRA AS, FICKUS M, et al. Phase retrieval with polarization[J]. *SIAM Journal on Imaging Sciences*, 2014, 7: 35-66.
- [68] CAO R, SHEN C, YANG C. High resolution, large field of view label free imaging via aberration corrected, closed form complex field reconstruction[J]. *Nature Communications*, 2024, 15: 4713.
- [69] GOUD B K, RAJU S J, RAO K D. Novel defocus hologram aberration compensation method in digital holography integrated pathology microscope for label-free 3D imaging[J]. *Optics and Lasers in Engineering*, 2021, 140: 106514.
- [70] WU W, ZHOU T, FANG L. Parallel photonic chip for nanosecond end to end image processing, transmission, and reconstruction[J]. *Optica*, 2024, 11: 831-837.
- [71] ZAMIR S W, ARORA A, KHAN S, et al. Multi-stage progressive image restoration[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. New York: IEEE, 2021: 14821-14831.
- [72] LI J, LIU Q, TAN L, et al. Enhanced neural architecture for real-time deep learning wavefront sensing[J]. *Sensors*, 2025, 25: 480.
- [73] GUO M, WU Y, HOBSON C M, et al. Deep learning-based aberration compensation improves contrast and resolution in fluorescence microscopy[J]. *Nature Communications*, 2025, 16: 313.
- [74] ZHANG Y, SONG X, XIE J, et al. Large depth of field ultra compact microscope by progressive optimization and deep learning[J]. *Nature Communications*, 2023, 14: 4118.
- [75] GONG D, SCHERER N F. Tandem aberration correction optics (TACO) in wide field structured illumination microscopy[J]. *Biomedical Optics Express*, 2023, 14: 6381.

作者简介:



邵晓鹏(1973-),男,教授,博士生导师,研究方向:计算光学成像技术、光电图像处理与模式识别、光电仪器研制与测试。



邓谕霜(2002-),女,博士研究生,研究方向:计算光学成像算法。



陈雨彤(2002-),男,博士研究生,研究方向:计算成像。



张一诺(2003-),男,硕士研究生,研究方向:计算成像。



王慧慧(2003-),女,助理研究员,研究方向:计算成像。



吴腾飞(1990-),男,研究员,博士生导师,研究方向:计算成像、光场探测、新型波前传感器设计。



魏士杰(1994-),通信作者,男,助理研究员,研究方向:计算光学成像,E-mail: weishijie@opt.ac.cn。

(编辑:刘彦东)

## Research Progress in Information Processing Methods for Computational Optical Systems

SHAO Xiaopeng, DENG Yishuang, CHEN Yutong, ZHANG Yinuo, WANG Huihui, WU Tengfei, WEI Shijie\*

(Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences, Xi'an 710119, China)

**Abstract:** Aberration is a crucial factor that restricts the imaging performance of optical systems, leading to degraded imaging effects such as blurred details and reduced resolution. Computational optical aberration correction technology breaks through the limitations of traditional hardware-based correction by integrating optical physical modeling with advanced information processing algorithms, achieving accurate and flexible compensation for imaging degradation caused by various aberrations. This paper systematically reviews the research progress of information processing methods for aberration correction based on computational optical systems. First, it expounds the theoretical foundation of aberration correction, including the wavefront aberration characterization method based on Zernike polynomials, which provides a rigorous mathematical basis for quantifying different types of aberrations, and the aberration-dominated light field degradation model that establishes the quantitative correlation between wavefront distortion and point spread function (PSF) degradation. It also introduces classical restoration algorithms such as Wiener filtering and Richardson-Lucy iteration, which lay a technical foundation for solving the imaging degradation inverse problem. On this basis, the paper analyzes the principles and practical applications of three mainstream aberration correction technologies from the perspectives of active adjustment, optical coding and pure computational restoration: Adaptive optics (AO) realizes real-time dynamic compensation of dynamic wavefront distortion through a closed-loop system of wavefront sensing and deformable mirror adjustment; wavefront coding and coded aperture technology transform complex aberrations into computable degradation forms via artificial phase modulation in the optical front-end, realizing collaborative optimization of optical coding and back-end digital decoding; phase retrieval and blind deconvolution techniques invert wavefront phase information and estimate unknown PSF only through algorithm iteration without additional hardware intervention. Finally, the paper focuses on deep learning-driven aberration correction methods, including data-driven end-to-end learning frameworks, physical model-embedded hybrid architectures and unsupervised/few-shot learning methods, and discusses their typical applications in biomedical microscopic imaging, lensless imaging, astronomical remote sensing and other frontier fields. This study clarifies the technical characteristics, advantages and limitations of various methods, and provides important theoretical reference and technical path guidance for the collaborative optimization design and practical application of computational optical imaging systems.

### Highlights:

1. Summarize the theoretical foundation of computational optical aberration correction, including Zernike polynomial-based wavefront characterization, aberration-driven light field degradation modeling and classical image restoration algorithms.
2. Analyze three mainstream aberration correction technologies from the perspectives of active adjustment, optical coding and pure computational restoration, clarifying their technical characteristics, application scope and performance trade-offs.
3. Elaborate on deep learning-driven aberration correction methods and their typical applications, and discusses the current challenges and future development trends of the field.

**Key words:** computational optical imaging; aberration correction; wavefront coding; phase retrieval; deep learning

---

**Foundation item:** Technology Innovation Leading Program of Shaanxi (No.2024QY-SZX-16).

**Received:** 2026-01-15; **Revised:** 2026-02-10

\*Corresponding author, E-mail: weishijie@opt.ac.cn.