

光学学报

定量相位成像的范式革新:从物理建模到物理驱动
深度学习的智能化演进(特邀)卢林芃^{1,2,3,4}, 黄星雨^{1,2,3}, 周顺^{1,2,3}, 金彦伯^{1,2,3}, 李卓识^{1,2,3}, 孙佳嵩^{1,2,3,4}, 陈钱^{1,2,3,4**}, 左超^{1,2,3,4*}¹智能计算成像实验室, 南京理工大学电子工程与光电技术学院, 江苏 南京 210094;²南京理工大学智能计算成像研究院, 江苏 南京 210019;³江苏省视觉传感与智能感知重点实验室, 江苏 南京 210094;⁴极限环境光电动态测试技术与仪器全国重点实验室, 山西 太原 030051

摘要 通过在输入构造、网络建模与优化目标等关键环节嵌入成像物理机制,实现了从物理建模到深度学习的范式融合。从“物理先验注入层级”的视角出发,构建统一的物理驱动深度学习(PD-DL)方法范式分类框架,系统归纳了当前主流方法在数据构造层、结构建模层与目标约束层的三类融合路径,深入剖析其在监督策略、信息调控机制与系统适应性等方面的内在差异与融合趋势。该框架不仅有助于厘清不同方法之间的理论关联与功能定位,也为面向弱监督学习、跨模态重建与高通量部署等挑战的下一代定量相位成像(QPI)系统设计提供理论基础与技术支撑。本综述旨在系统梳理定量相位成像范式从物理建模向智能化融合演进的关键进展,推动具备物理一致性、泛化鲁棒性与工程可实现性的下一代定量相位成像系统构建。

关键词 计算成像; 定量相位成像; 物理建模; 深度学习; 物理驱动深度学习

中图分类号 O436

文献标志码 A

DOI: 10.3788/AOS251631

1 引言

在光学领域,传统成像技术基于强度成像机理,利用各种成像系统(如显微镜、望远镜等)实现了光学信息的可视化,显著拓展了人眼的视觉范围^[1]。然而,直接成像机制的固有限制使传统光学成像的信息获取受探测器性能、光学系统设计及衍射极限的共同约束,难以获取高维信息(如相位),从而限制了成像系统的分辨率与带宽积^[2]。因此,传统光学成像技术在探测灵敏度、成像维度及时间/空间分辨率等方面存在局限^[3],难以满足对灵敏度、维度与分辨率日益增长的应用需求。此外,传统光学成像依赖于牺牲硬件成本为代价的设计思路,而光探测器的关键参数已逼近物理极限,这一现状进一步限制了其应对当前挑战性需求的能力。

近年来,得益于成像电子学、计算机数据处理能力及光电信息处理技术的快速发展,融合了光学物理器

件、光学系统与信号处理等领域知识的计算成像技术应运而生^[4]。与传统光学成像的强度直接采样形式不同,计算成像技术通过引入光学调控与算法解调实现了更加灵活的间接光强记录方式。该技术基于物理先验知识对正向图像生成过程进行数字化表征,建立了光学调控后的目标光场与测量图像间的物理模型,并通过逆问题求解等数学手段实现了计算反演成像^[5]。与传统光学成像技术相比,计算成像技术巧妙地对物理域的光学编码与计算域的信号处理进行联合设计,基于间接采样的成像机制提升了光学场景捕获与目标信息提取的能力,赋予了传统光学成像技术难以或无法获得的高维目标信息的革命性优势^[6]。通过联合优化光学系统和信号处理,计算成像技术可实现特定的成像功能与特性,例如:提取传统光学成像技术无法获得的目标信息(如相位成像^[7-8]、量子成像^[9]),重构出高维度的物理信息(如光谱成像^[10-11]、三维成像^[12-14]),或是降低合成孔径雷达^[15]、超分辨率成像^[16-18]及自适应光

收稿日期: 2025-08-18; 修回日期: 2025-09-14; 录用日期: 2025-09-16; 网络首发日期: 2025-09-19

基金项目: 国家重点研发计划(2024YFE0101300, 2022YFA1205002, 2024YFF0505603, 2024YFF0505600)、国家自然科学基金(62227818, 62361136588, 62305162, U21B2033, 62505136, 62575139)、江苏省科技计划生物医药竞争类项目(BE2022847)、江苏省科技计划重点国别产业技术研发合作项目(BZ2022039)、中央高校科研专项资助项目(30923010206)、中央高校基础科研业务费专项资金资助项目(2023102001, 2024202002)、等离子体物理全国重点实验室项目(JCKYS2024212804)、江苏省光谱成像与智能感知重点实验室开放基金(JSGP202105, JSGP202201, JSGPCXZNGZ202401)

通信作者: *zuochao@njust.edu.cn; **chenqian@njust.edu.cn

学^[19]等已有应用领域的测量成本。如今,计算成像技术已成为结合几何光学、信息光学、计算光学、计算机视觉和现代信号处理等理论的国际研究热点,并逐渐发展成为光学成像领域的主流技术。计算成像的概念已经渗透进光学显微成像领域^[20-21],并于近几年诞生出新的术语“计算显微成像技术”,该技术几乎与定量相位成像(QPI)^[22-23]技术同时发展。定量相位成像是一种基于波动光学理论对目标光场进行数学表征,并通过图像重建算法进行数字处理,以突破传统光学显微成像的物理限制,获取无法直接测量的微观物体相位信息的技术。

从成像机制角度出发,定量相位成像技术可分为干涉与非干涉两大类(图 1)。干涉定量相位成像法(如数字全息术、相移干涉术等)利用干涉原理将由样品引起的光波前变化调制到全息图中,并通过条纹分析技术解析得到物体完整的复振幅信息(振

幅和相位),具有较高的相位灵敏度、成像速度以及测量精度^[24-26]。然而,该方法对系统稳定与环境扰动控制要求较高,通常需要复杂的光路设计与高精度机械控制,这限制了系统在便携化、微型化、环境非理想条件下的广泛部署。相比之下,非干涉定量相位成像法[如 Gerchberg-Saxton(GS)^[27-28]、光强传输方程(TIE)^[8,29-30]、差分相衬(DPC)^[31-33]和傅里叶叠层显微术(FPM)^[18,34-35]等]通过采集多幅光强图像并结合光场传播模型进行物理反演,可实现样品相位的定量重建。该类方法无需参考光,具有结构简洁、环境鲁棒性高、系统易于集成等优势,适用于宽带照明、通用光路设计、微型成像系统设计和高通量数据采集等实际应用需求。但现有计算显微成像技术的实际效能仍受正向数学模型的准确性与逆向重构算法的可靠性的影响。因此,物理成像过程中的不确定性与高维病态逆问题的求解复杂性构成了该领域发展的关键挑战。

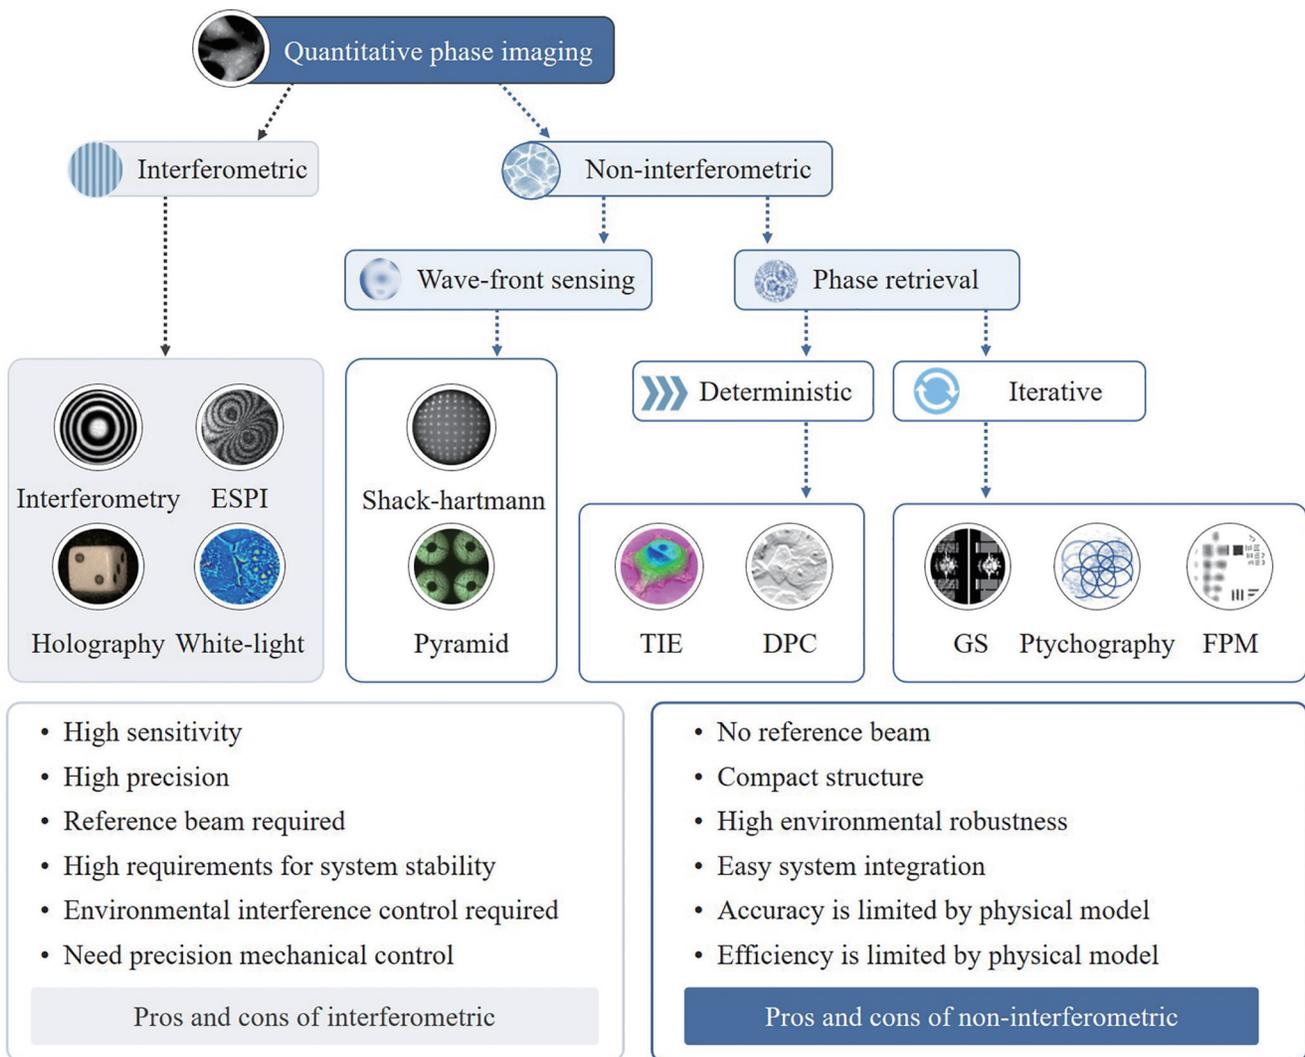


图 1 定量相位成像技术分类与挑战^[8]

Fig. 1 Classification and challenges in quantitative phase imaging^[8]

伴随深度学习技术在计算机视觉与图像反演领域的蓬勃发展,定量相位成像研究范式也逐步从传统的

解析模型与优化算法驱动,向数据驱动建模与神经网络推理演进^[36]。通过“数据驱动”的基于学习的表征范

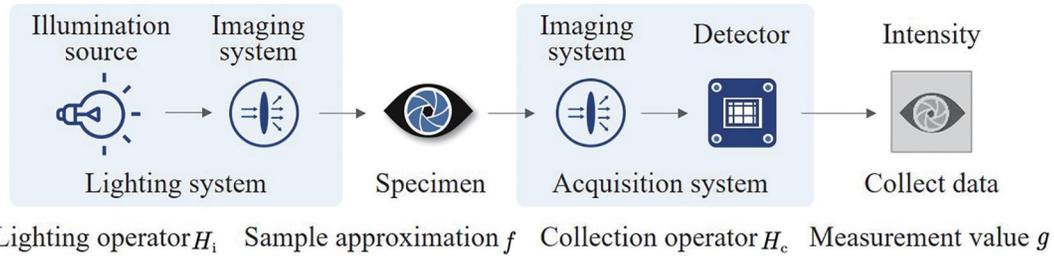
式,深度学习无需物理模型先验知识,仅需要多样化数据训练神经网络,即可提高模型的准确性和通用性。深度学习的“端到端”学习结构允许神经网络一步学习原始图像数据与所需样本参数的直接映射,亦可联合解决多项任务,具有减少计算负担和提高整体性能的协同优势^[37]。此外,深度学习可从数据中自动学习正则化,并利用复杂的网络结构提取高维特征以建立非线性伪逆映射模型,从而有效解决非线性不适定逆问题^[38]。在方法发展早期,数据驱动主要聚焦于干涉成像的复振幅恢复任务。例如,Sinha等^[39]首次基于深度卷积神经网络实现对衍射光强图的端到端相位重建,开启了数据驱动计算成像反演的方向。Riverson等^[40]构建的U-Net型结构能够从单帧全息图直接回归复振幅,为端到端学习提供了有效的基线方案。Wu等^[41]利用随机离焦的衍射图作为网络输入,融合训练相位恢复与自动聚焦,显著扩展了成像景深,并在大景深场景下保持了良好的图像稳定性。这类方法的一个显著特征在于避免对显式物理模型的依赖,利用数据驱动网络以端到端方式逼近前向算子的伪逆,绕过了显式反演。随后,研究重心逐步从干涉向非干涉成像系统拓展。Deng等^[42]提出LS-DNN(Learning to Synthesize Deep Neural Network)框架,该方案将相位分低频、高频两支路进行独立训练后再进行融合,在低光子下仍可保留细节、抑制伪影,无需GAN(Generative Adversarial Network)或感知损失。近年来,基于深度学习的相位恢复技术已涉及如TIE(Transport of Intensity Equation)^[43-44]、DPC(Differential Phase Contrast)^[45-46]、FPM(Fourier Ptychographic Microscopy)^[47-48]等非干涉定量相位成像技术,从而解决减少采集帧数^[48]、提升重构精度^[44]、提升计算效率^[47]、优化硬件装置设计^[49]等过去计算成像领域难以解决的难题,这些技术在信息获取能力、成像功能、核心性能指标上获得了显著提升。因此,基于深度学习的计算成像技术降低了传统成像方法对正向物理模型或逆向重构算法的过度依赖,突破了基于物理模型方法所能达到的性能疆界,为该领域带来了众多开创性成果^[6,50-51]。

尽管深度学习技术在应对正向数学模型不可知性和实现数据驱动的伪逆映射方面展现出巨大潜力,但其在光学领域的应用仍面临多重挑战(图2),主要包括实验训练数据采集成本高、系统定制化导致的跨系统数据难以通用,以及公共基准数据集缺乏等问题^[37,50]。虽然新兴的深度学习方法,如迁移学习和无监督学习,能在一定程度上减少对大量数据的依赖,但其性能仍不及由大量数据支持的监督学习方法。此外,由于实验数据的真值(如相位)难以直接获取,研究中通常依赖仿真图像或传统算法生成的标签构建“准实验”数据集。此类深度学习往往以基于物理模型的计算成像算法为金标准,却期望在性能上超越该

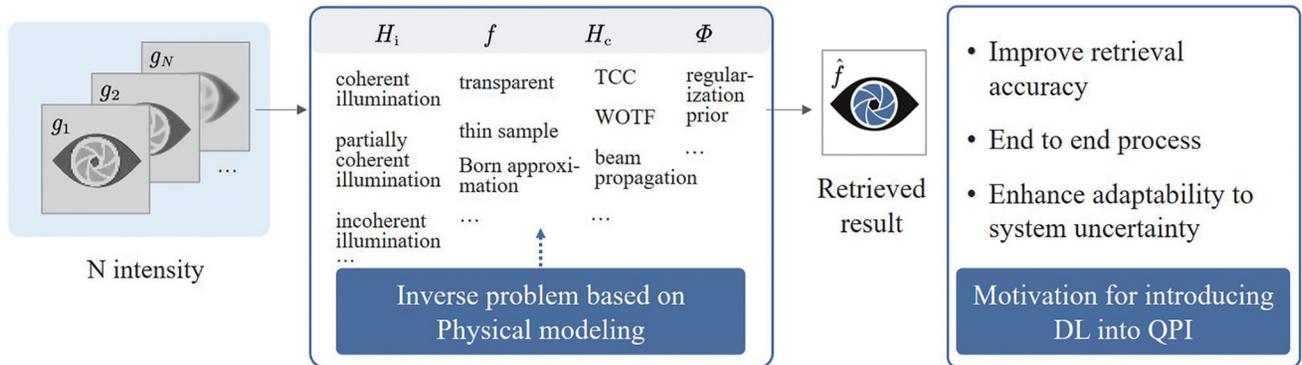
物理模型,这一思路存在不合理性。与此同时,由于缺乏统一的网络架构选择范式,实践中常通过评估不同模型及其超参数来确定网络结构。但模型类型繁多、训练过程繁琐且耗时,亟须有效方法以快速缩小模型范围并降低过拟合风险。此外,深度学习性能高度依赖训练样本的规模与多样性,其同域性特征易导致在未见输入上迅速失效。相比之下,只要正向模型与重建算法可靠,基于物理模型的方法在多种样本类型下均能保持较高的适应性与稳定性。与将领域知识精心嵌入求解流程、依赖显式物理建模的计算成像方法不同,当前多数基于深度学习的成像策略对先验依赖较弱,通常依靠大量训练数据从零学习输入到输出的映射关系。然而,在图像生成过程的控制规律和物理机制已知的前提下,将这些物理定律显式融入深度神经网络,这不仅能够减少训练数据与网络参数在“学习物理”上的资源浪费,还可提升模型的收敛效率与物理一致性。

近年来,随着研究者在计算成像领域对物理模型与深度学习融合机制的不断深入探索,从数据驱动到“物理-数据”双驱动的演化路径逐渐形成。由此可见,融合基于物理模型的计算成像技术与深度学习工具,发挥二者的互补优势,已成为该领域的显著发展趋势^[37]。尽管二者在理论基础和实现路径上存在差异,但并非相互排斥,而是在优势互补的驱动下逐渐走向交叉融合,因此,诞生了将物理模型与深度学习相结合的新术语“物理驱动深度学习”(PD-DL)^[37-38,52]。如图3所示,学者们尝试将物理模型引入深度学习以降低传统基于端到端深度学习的大量数据集需求^[53-57],甚至出现了仅需单帧输入、无需真值且无需预先训练的物理驱动深度学习方法^[58-61]。这类方法通过在网络结构、训练机制或损失函数中引入光学传播规律、成像方程或先验条件,使神经网络模型受到物理机制的引导,在精度、泛化能力与物理一致性之间实现权衡与协同^[50,62-63]。为系统梳理该方向的研究范式,本文从物理先验的注入层级出发,构建基于“注入层面”的分类框架,将现有方法归纳为三类具有代表性的物理模型与深度学习融合路径:基于数据构造的物理辅助监督学习(PASL)、基于结构设计的物理过程嵌入网络(PEIN),以及基于优化目标的物理一致性约束(PRL)方法。该分类方式以“物理建模在深度学习流程中所处的位置与作用机制”为核心依据,强调从输入、建模到训练目标的全链条物理先验融合,具有明确的层次逻辑与方法指导意义。具体而言:物理辅助监督学习方法通过将物理模型用于仿真生成训练数据或引导输入特征构造,从源头上提升样本的结构一致性与物理可解释性,适用于训练数据稀缺或缺乏标注的监督学习场景;物理过程嵌入网络方法通过在网络结构中嵌入光学传播模型、优化迭代算子或成像公式等模块,引导网络在结构归纳偏差层面体现成像物理规律,从而

(a) Forward image formation model



(b) Schematic diagram of computational imaging principle based on physical model



(c) Schematic diagram of computational imaging principle based on deep learning

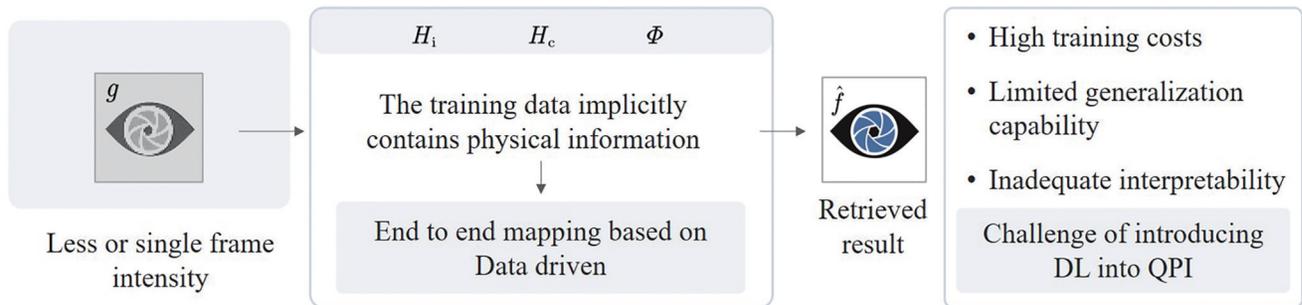


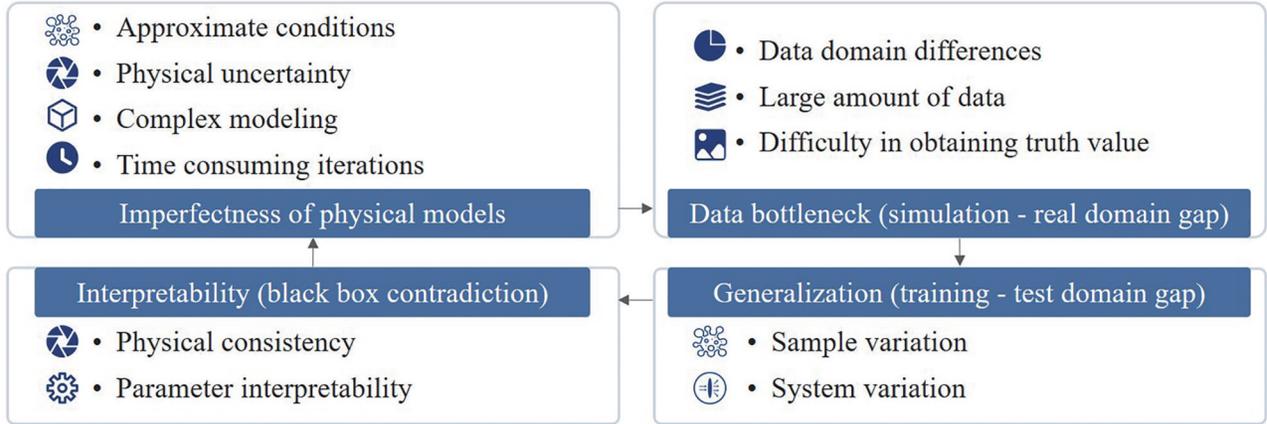
图 2 将深度学习引入定量相位成像的动因与挑战。(a)计算成像正向图像生成模型;(b)基于物理模型的计算成像原理示意图;(c)基于深度学习的计算成像原理示意图

Fig. 2 Motivation and challenges of introducing deep learning into quantitative phase imaging. (a) Computational imaging forward image generation model; (b) schematic diagram of computational imaging principle based on physical model; (c) schematic diagram of computational imaging principle based on deep learning

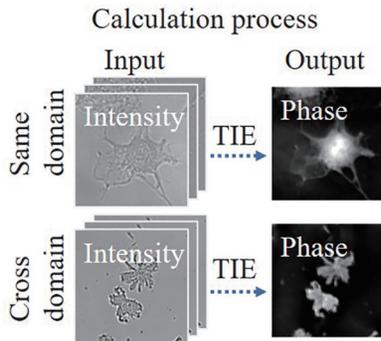
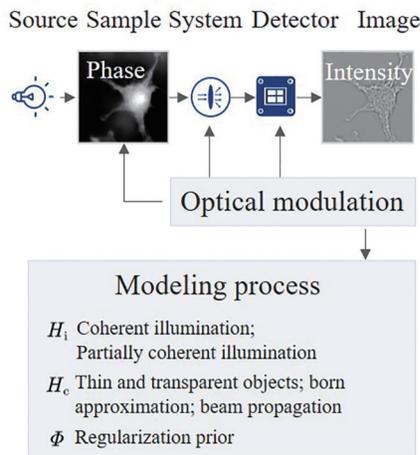
增强模型的适应性与稳健性;物理一致性约束方法则在损失函数中引入传播残差或控制方程约束等物理一致性项,能够在无标签或弱监督条件下,保证网络输出结果的物理合理性与稳定性。相较于已有综述多以任务类别(如相位重建、三维成像)或网络结构形式(如物理信息神经网络、物理引导图神经网络)作为划分依据,本文构建的分类框架更侧重于解析物理知识在深度学习流程中的嵌入机制与作用路径,从而在数据层-结构层-目标层的层级化融合视角下,统一刻画不同模型范式的共性特征与关键差异。该框架不仅揭示了三类方法间的互补关系与融合潜力,也表明物理建模正逐步成为深度学习成像系统不可或缺的核心组成,并日益发展为驱动网络建模与性能优化的重要先验来源。

基于上述背景,本文围绕定量相位成像中的PD-DL方法开展系统综述,旨在全面梳理该领域从传统物理建模向智能化融合范式演进的技术脉络,构建具备理论深度与工程适应性的分析框架。不同于以网络结构或算法类型为主线的既有综述,本文以成像系统中的物理机制为出发点,聚焦物理建模在深度学习流程中的注入方式及其与网络推理过程的协同机制,力图从更具本质性与结构化的视角揭示PD-DL方法的共性规律与演化趋势。为此,本文引入“物理先验注入层级”作为方法分类的核心维度,系统梳理当前研究中在数据构造、结构建模与目标约束等不同层级融合物理建模机制的典型路径,并深入剖析各类方法在监督策略、信息调控与系统适应性等方面的内在差异与互补特征。该分类框架有助于统一描述物理知

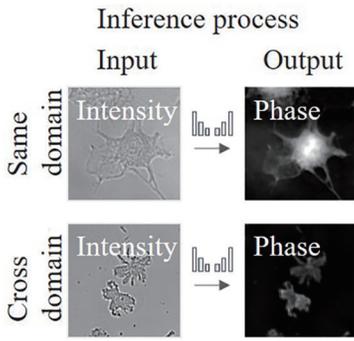
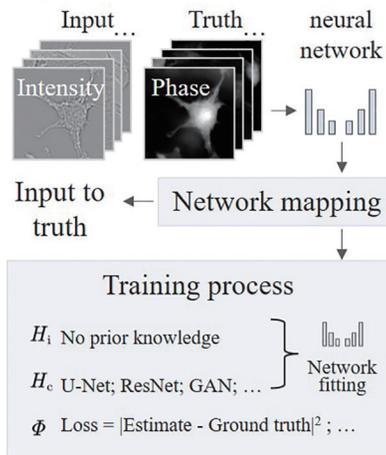
(a) Trade-off between physical priors and data-driven approaches



(b) Based on physical models



(c) Based on DL



(d) Based on PD-DL

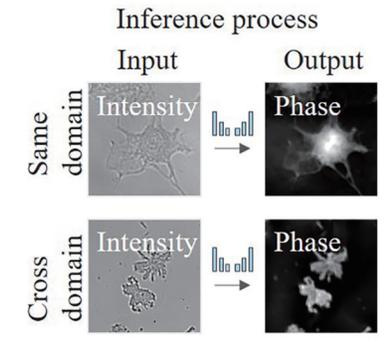
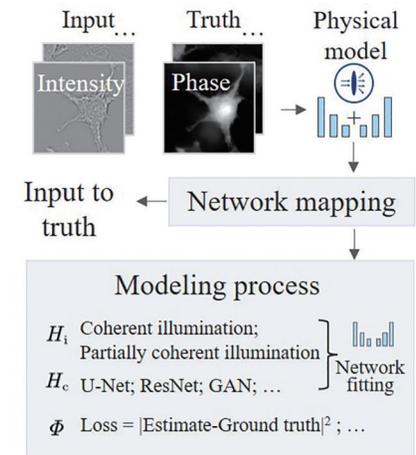


图 3 基于物理模型、深度学习、物理驱动深度学习的方法性能对比示意图。(a)物理先验和数据驱动方法之间的权衡;(b)基于物理模型的QPI示意图;(c)基于深度学习的QPI示意图;(d)基于物理驱动深度学习的QPI示意图(仅展示潜力,实际性能依赖具体方法选择)

Fig. 3 Performance comparison diagram of methods based on physical models, deep learning, and physics-driven deep learning. (a) Trade-off between physical priors and data-driven methods; (b) schematic diagram of QPI based on physical models; (c) schematic diagram of QPI based on deep learning; (d) schematic diagram of QPI based on physics-driven deep learning (potential shown, performance depends on method chosen)

识嵌入的多样化方式,增强对PD-DL方法融合模式与机制特征的整体认知,亦为后续面向弱监督学习、跨模态重建与高通量部署等任务场景中的模型设计提供方法指导。

全文结构安排如下:第一部分概述QPI的基本原理与物理建模方法,为方法融合提供理论基础;第二部

分梳理数据驱动深度学习在QPI中的发展现状与代表性进展,剖析其在缺乏物理约束条件下的核心瓶颈,为后续物理建模的引入奠定动因背景;第三部分从“数据构造-结构设计-损失约束”三个层级出发,系统归纳物理驱动深度学习的三类代表性融合路径,构建统一的范式分类框架,并分析其在信息调控、监督策略与系统

适应性等方面的关键特征;第四部分结合当前应用需求与研究挑战,探讨PD-DL方法在高维建模、弱标签训练、系统部署等实际任务中的发展潜力与技术瓶颈。最后,文章对该方向未来的发展趋势进行总结与展望,重点关注其在系统级优化、数字孪生建模与跨模态融合等前沿方向的拓展能力。综上,本文旨在为定量相位成像中物理建模与深度学习的融合研究提供系统化的方法总结与结构化的技术框架,推动PD-DL方法在高精度重建、跨平台适配与高通量成像等方面构建具备物理一致性、泛化能力与工程可实现性的下一代智能成像系统,为其在生物医学、材料分析与智能感知等应用场景中的推广落地提供理论支撑与范式指导。

2 定量相位成像的物理模型基础

2.1 干涉与非干涉:光路差异与适用边界

在定量相位成像中,成像物理模型的构建高度依赖于光学成像系统对光场信息的调控方式^[8,23,64]。广义而言,该方法可分为干涉法与非干涉法两大类^[59-60],其根本区别在于是否显式引入参考光束对待测光场的相位信息进行干涉调制^[65-66]。以图4为例,在干涉路径中,系统通过引入参考光与物光干涉,直接将相位信息编码至干涉条纹中,进而借助傅里叶变换等手段实现复振幅重建^[24,67-68]。此类方法具有相位恢复精度高、解析模型明确等优点,但对光学系统稳定性与参考光质量要求较高,这限制了其在动态、生物样本成像中的应用拓展^[25,68-70]。相对而言,非干涉定量相位成像则通过调控物光在空间或频域中的传播行为(如明场离焦^[30,71-72]、偏振调制^[73-74]、多模态照明^[33,75-76]等),在无需参考光的条件下建立光强与相位之间的映射关系,强调从多个光强图中重构出目标相位分布^[8,20,77]。该方法在系统结构简化、环境鲁棒性及高通量兼容性方面具有突出优势,但相应地面临更强的反演不稳定性与成像精度约束。因此,本节将基于正向图像生成模型与重构简要介绍干涉法、非干涉法的物理建模基础,以便于后续对基于物理驱动深度学习的定量相位成像的方法分类提供物理依据。

2.2 干涉定量相位成像的正向图像生成模型与典型求解方法

在干涉定量相位成像法中,系统通过引入一束经过精密设计的参考光,使其与携带有样本信息的物光发生干涉,形成空间调制的干涉条纹图案^[24]。这些条纹以余弦或正弦形式将复振幅信息编码到二维平面中。正是依靠这一条纹结构,系统得以在数学上遵循经典干涉原理,将物光与参考光的复振幅分布统一写入光强表达式:

$$I_h(x, y) = |O|^2 + |R|^2 + |R|O \exp(-ik \sin \theta x) + |R|O^* \exp(ik \sin \theta x) \quad (1)$$

式中: R 和 O 分别表示参考光与物光; $*$ 表示复共轭; k 为波数; θ 是参考光相对光轴在 x 方向的倾角。对全息图进行傅里叶变换时,两个相位因子 $\exp(\pm ik \sin \theta x)$ 的影响可理解为将与 ± 1 级谱相关的空间频率从傅里叶平面中心平移到更高频率区域。零级或直流分量的空间频率位于傅里叶平面中心,形成背景分布;而干涉项的空间频率位于不同的载频处,相对于傅里叶平面中心对称分布: $-k \sin \theta x$ 对应 $+1$ 级像, $k \sin \theta x$ 对应 -1 级像。

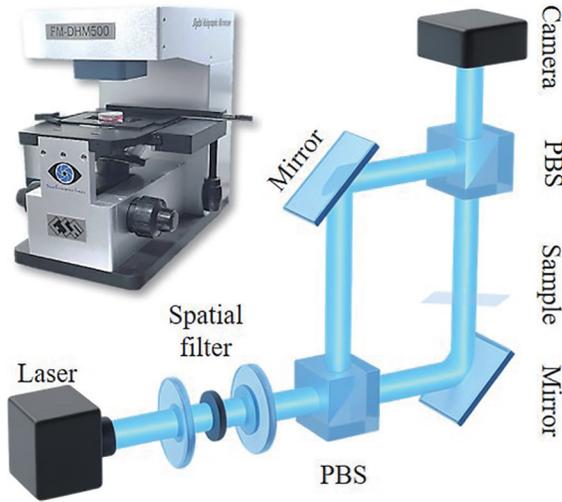
根据干涉方式与建模策略的不同,现有主流方法主要可分为频域解调法^[67]与多帧反演法^[78]两类。频域解调法常用于离轴干涉系统中,通过在物光与参考光之间引入干涉夹角以提高条纹载频,从而使得携带物体信息的正负一级谱从傅里叶域的中心区域移动到高频区域,再通过带通滤波以及傅里叶逆变换重建物体的完整复振幅。1986年,Kreis^[67]提出频域滤波方法,经过近40年的发展,该方法已广泛应用于诸多高载频干涉条纹解调应用中。尽管此类方法的重建速度快、解析性强,但对条纹载频要求较高,因此难以应用于频谱重叠和系统非理想等场景。多帧反演法则通过引入多个相互独立的干涉图,构建复振幅与强度之间的方程组,从而提升抗噪性和系统鲁棒性。其中最具代表性的是移相干涉法(PSI),通过在已知相位偏移条件下采集三帧或以上干涉图,并利用解析表达或最小二乘法求解复场。该方法可用于同轴干涉系统,具有较高的相位分辨率与稳定性。Creath^[78]提出的五步移相算法已成为精密表面计量和组织厚度测量中的经典方案。

近年来,随着计算能力的提升与测量环境的复杂化,更高阶、多帧移相算法也不断被提出,以抑制非理想相移误差与机械振动带来的相位噪声^[79]。此外,作为多帧策略的一种扩展形式,多波长干涉法通过采集多个波长下的干涉图进行合成重建,不仅可拓展相位测量的非模糊范围,还能构建高轴向分辨率或大动态范围的复场模型。值得注意的是,上述方法的解调相位会受到包裹问题影响,使其重建相位值在 $(-\pi, \pi]$ 范围。为获取物理连续的相位分布,需要进一步引入相位解包裹过程^[80]。虽然该过程不属于相位恢复的成像建模范畴,但作为必要的后处理步骤,其对结果的物理可解释性具有重要影响。总体而言,基于干涉的定量相位成像方法依托精确的光学建模与干涉控制策略,在成像精度与理论完备性方面具有显著优势,但其对系统稳定性和干涉条纹质量的依赖较强,难以适应复杂环境与动态样本,这成为制约其工程化应用的主要因素之一。

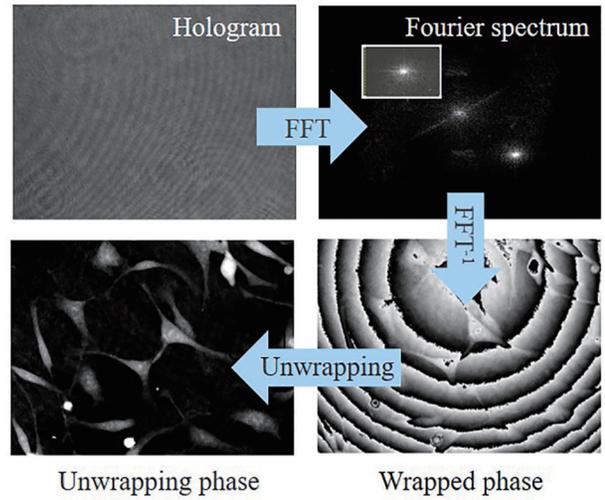
2.3 非干涉定量相位成像正向图像生成模型与典型求解方法

相较之下,非干涉定量相位成像凭借简洁的系统

(a) Interferometric: digital holographic microscope

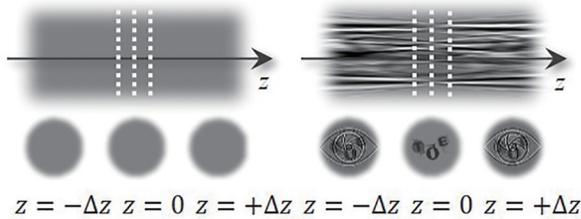


Principles of digital recording and digital reconstruction



(b) Non-interferometric deterministic method

Transport of intensity effect: the effect of phase on beam propagation



Transport of intensity equation (TIE)

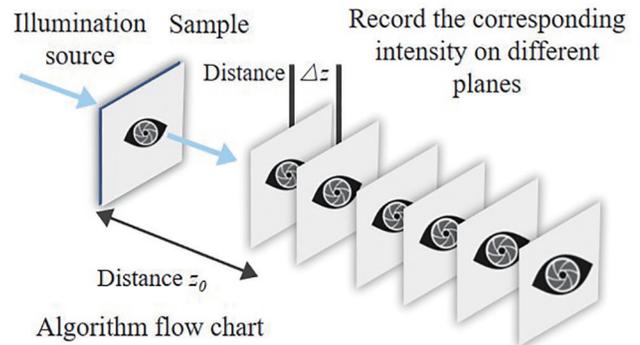
$$-k \frac{\partial I(x, y)}{\partial z} = \nabla \cdot [I(x, y) \nabla \phi(x, y)]$$

Axial intensity derivative
 $\approx \frac{I_{+\Delta z}(x, y) - I_{-\Delta z}(x, y)}{2\Delta z}$
 Finite difference

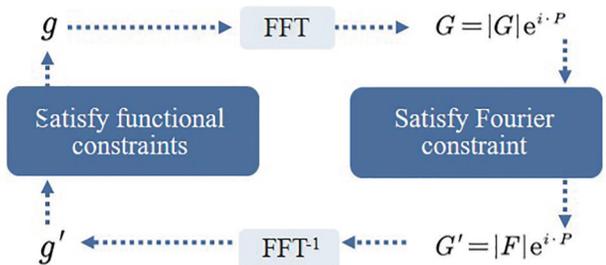
Transverse energy
 $\nabla I(x, y) \nabla \phi(x, y) + I(x, y) \nabla^2 \phi(x, y)$

$I(x, y)$: Intensity $I_{+\Delta z}(x, y)$: Positive defocus intensity
 $\nabla \phi(x, y)$: Phase gradient $I_{-\Delta z}(x, y)$: Negative defocus intensity

(c) Non-interferometric iterative method



Algorithm flow chart



g Complex-amplitude estimate in the spatial domain
 G Complex spectrum of g in the Fourier domain

图 4 干涉与非干涉成像路径对比。(a)干涉法:具有马赫-曾德尔结构的数字全息显微镜及数字记录与数字重建的基本原理示意图;
 (b)非干涉直接法:算法原理示意图;(c)非干涉迭代法:算法原理示意图

Fig. 4 Comparison of interferometric and non-interferometric imaging paths. (a) Interferometry: digital holographic microscope with Mach-Zehnder structure and the basic principle diagram of digital recording and digital reconstruction; (b) non-interferometric direct method: schematic diagram of algorithm principle; (c) non-interferometric iterative method: schematic diagram of algorithm principle

结构和对环境扰动的高度鲁棒性,在实际应用中展现出更强的灵活性。如图 5 所示,该方法的正向图像生成模型由光源、样品、成像系统及探测器构成。在不同光学调控条件下,包含待测样品信息的光线被探测器采集为已编码相位信息的光强图;随后,基于已建立的物理模型进行数字解码,即可重构样品的相位分布,图

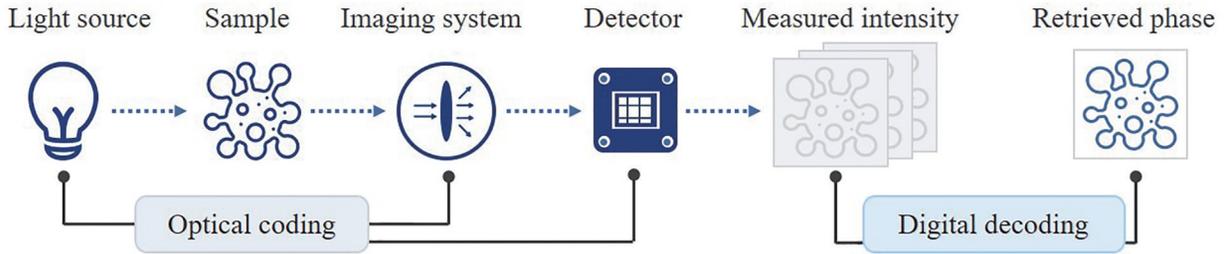
中 h_n 表示第 n 层高度。TIE^[8,30] 作为经典的非干涉相位恢复方法,尤其适用于相干照明条件下的缓变相位样本。该方法基于能流守恒原理,通过测量轴向光强导数 $\partial I / \partial z$, 建立其与横向相位梯度 $\nabla_{\perp} \phi$ 间的定量关系:

$$-\frac{2\pi}{\lambda} \frac{\partial I(x, y, z)}{\partial z} = \nabla_{\perp} \cdot [I(x, y, z) \nabla_{\perp} \phi(x, y)] \quad (2)$$

式中： z 为离焦距离； λ 为波长； ∇_{\perp} 为梯度算子。该偏微分模型在满足弱散射、连续相位分布与小离焦条件下，构成了一个可解析求解的线性反演框架，适用于通过两幅或多幅离焦图像重建定量相位。TIE具有实现简便、反演效率高的优势，尤其在标准明场显微系统中易于集

成。然而，其有效性建立在傍轴传播与缓变相位近似前提下，在处理部分相干照明、高数值孔径、大相位样本或复杂边界条件时将面临模型不适应性增强、边界伪影增大、分辨率受限等挑战，尤其在低信噪比条件下，TIE对轴向强度导数的估计易受噪声放大的影响^[81-82]。

(a) Forward image formation model and back-end image processing process QPI



(b) Front-end optical control example

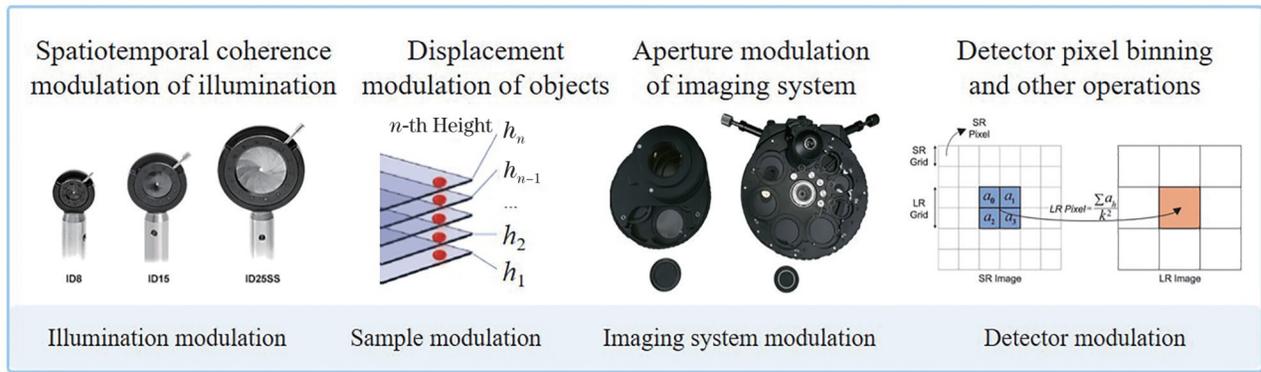


图5 物理建模核心步骤。(a)定量相位成像的正向图像生成模型与后端图像处理过程示意图；(b)前端光学调控举例

Fig. 5 Core steps of physical modeling. (a) Forward image generation model of quantitative phase imaging and schematic diagram of back-end image processing process; (b) front end optical control example

在上述背景下，研究部分相干照明下的非干涉定量相位成像的物理模型有利于提高系统灵活性与成像性能。Fan等^[5]在文中指出，部分相干光源（如LED阵列、宽谱环形照明）能够有效抑制散斑噪声，同时扩大系统在频域中的带宽响应，从而实现超过相干衍射极限的成像分辨率。在此类照明条件下，图像生成过程可描述为相干照明下光强图的非相干叠加，其正向模型不再符合复振幅的线性传播假设，而表现为样品复透射函数频谱间的空间相关性卷积关系，具体可由传输交叉系数(TCC)表达为

$$I(\mathbf{x}) = \iint T(\mathbf{u}_1) T^*(\mathbf{u}_2) T_{CC}(\mathbf{u}_1, \mathbf{u}_2) e^{i2\pi\mathbf{x}(\mathbf{u}_1 - \mathbf{u}_2)} d\mathbf{u}_1 d\mathbf{u}_2 \quad (3)$$

式中： $(\mathbf{u}_1, \mathbf{u}_2)$ 为空间频率坐标； \mathbf{x} 为横向坐标； $T(\mathbf{u})$ 为样品复透过率的傅里叶变换； $T^*(\mathbf{u}_2)$ 为样品复透过率傅里叶变换的共轭； $T_{CC}(\mathbf{u}_1, \mathbf{u}_2)$ 为传输交叉系数。为简化该双线性模型并适用于工程实现，通常在弱物体近似下引入弱物体传递函数(WOTF)^[83-84]，将系统响应线性化，使得成像强度变化与样品相位谱之间建立频域卷积关系：

$$I(\mathbf{u}) \approx I_0(\mathbf{u}) + \text{Im}[WOTF(\mathbf{u})] \cdot \phi(\mathbf{u}) \quad (4)$$

式中： $I(\mathbf{u})$ 为采集光强的傅里叶变换； $I_0(\mathbf{u})$ 为聚焦面上平均光强的贡献； $\phi(\mathbf{u})$ 为样品相位的傅里叶变换。

WOTF的虚部体现了系统对相位调制的响应特性，而其实现部反映系统对吸收调制的响应。在对称照明下，WOTF的相位响应为奇函数，适用于双离焦图像差分恢复相位。Zuo等^[85]提出的AI-TIE(Annular Illumination based TIE)方法利用环形照明增强WOTF带宽与频率响应均匀性，显著提升了低频恢复能力与边界鲁棒性，在三幅图像条件下实现接近非相干衍射极限(约 $2NA$)的高分辨率成像，该方法代表了当前部分相干定量相位成像建模中的重要进展。尽管WOTF为部分相干定量相位成像提供了简洁的线性建模手段，并在弱散射条件下实现了快速且高效的相位恢复，但其本质仍基于一阶线性近似，难以准确刻画复杂样本的光波传播行为。此外，TCC推导与系统响应高度依赖于照明与成像几何的精确建模，实际系统中的像差、照明偏心或光源不稳定均可能破坏模型预测的准确性，这进一步限制了反演的稳定性与普适性^[86]。

随着应用对成像精度与通用性的要求不断提升,研究者开始发展更具表达能力的迭代相位恢复算法^[77,87-88],以绕过弱物体近似的限制,从更真实的物理建模出发对复杂样本进行高保真重建。例如,在部分相干照明条件下,成像过程呈现双线性或非线性特征,图像强度不再与复透射函数线性相关,而是包含其空间频率耦合项,通常以相干模态分解的形式加以描述^[89]。因此,为实现从强度反演相位的稳定求解,迭代方法通常构建损失函数以度量预测图像与实际观测图像之间的误差,并基于波前传播约束逐步更新复振幅或相位估计,从而实现对非线性成像模型的近似求解。这类方法不再依赖于频域反卷积与傅里叶反演,而是利用多图像配对、结构先验或调制优化策略提高重建精度。特别是在处理高数值孔径、大折射率调制或强边界跃变样本时,迭代方法展现出远优于线性方法的反演能力,有效缓解了低频损失与边缘伪影等问题。

然而,这类基于精确物理传播模型的迭代反演算法,尽管理论上具备更高的建模保真度和物理一致性,但在实际应用中仍面临显著的计算瓶颈与求解不适应性。首先,由于正向传播算子需要针对不同照明模态分别进行建模,并涉及高维卷积与积分运算,每次迭代均需要完成全波段的波前传播与场重构,计算复杂度高,难以满足高通量采集或实时成像的时延要求。其次,当成像过程中存在系统像差、照明非均匀性或边界条件未知等非理想因素时,反演优化易出现陷入局部极值甚至数值发散问题,显著降低收敛稳定性。此外,为抑制噪声放大与模糊累积,通常需要在目标函数中引入先验正则化项(如总变分、稀疏性约束或非负性约束),但其类型选择与权重调节高度依赖经验,缺乏自适应调控机制,从而增加了模型的应用复杂度与调参负担。综上,尽管部分相干照明可在一定程度上拓展系统频域带宽、提升成像分辨率,但其正向建模的高度复杂性与反演求解的高维非线性本质,仍构成当前定量相位成像发展亟待突破的核心瓶颈之一。

3 基于数据驱动深度学习的定量相位成像

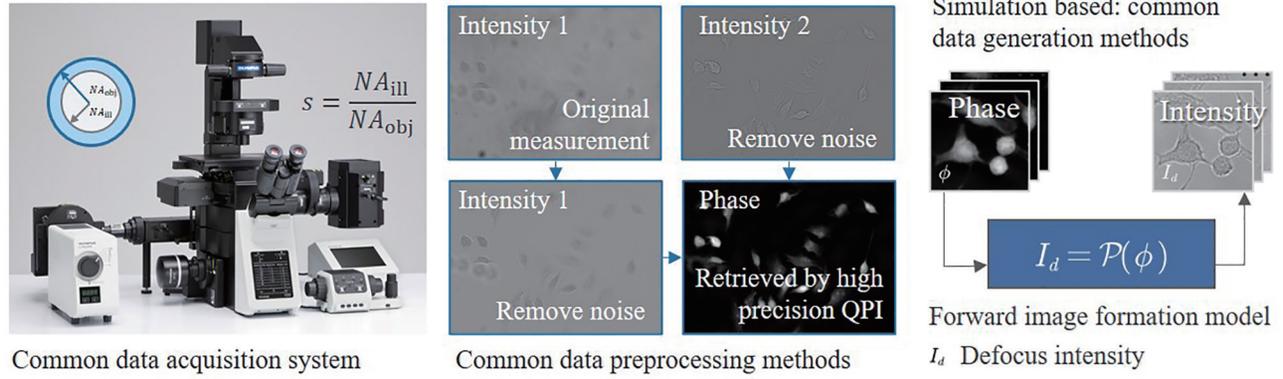
近年来,物理建模与优化算法在成像精度和模型表达能力方面持续取得进展,但在复杂真实场景中依然存在计算复杂度高、物理先验依赖强和系统适应性差等突出问题^[21,37,90-91]。这些局限性主要源于定量相位成像固有的高度不稳定性及解的非唯一性^[4,66,77]。在整个成像链条中,光学系统本质上是一个信息损失与退化过程:由于探测器无法直接获取相位信息,必然引入“相位缺失”这一核心问题;有限数值孔径导致边界截断,而点扩散函数的空间模糊效应又进一步削弱图像细节。此外,系统像差、非均匀照明、散射介质等

非理想因素普遍存在于实际成像过程中,使得误差易于在高阶传播模型中被显著放大,这严重影响成像稳定性。传统物理模型通常通过引入多帧测量、严格边界假设或精确系统建模来增强求解约束,这在提高计算和实验复杂度的同时,也显著限制了方法的通用性与高通量适应能力。

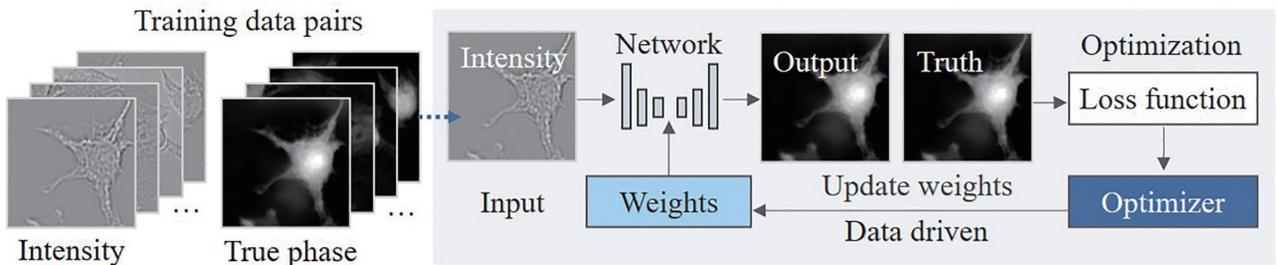
在传统模型面临高复杂度、低适应性与强先验依赖的背景下,数据驱动的深度学习方法正逐步成为定量相位成像领域应对高维复杂反演任务的重要途径^[38,63,90]。如图6所示,此类方法通常采用端到端神经网络,从单帧或多帧的光强图、衍射图或全息图中直接回归定量相位图,跳过显式传播模型建模与反演求解过程,从而实现物理建模到数据拟合的范式转移。抽象而言,该类方法可统一表示为 $\mathcal{N}_\theta(I) \rightarrow \hat{\phi}$ [其中 \mathcal{N}_θ 表示具有可学习参数 θ 的网络模型, I 为输入图像(如实验采集的明场图、衍射图或全息图), $\hat{\phi}$ 为重建得到的定量相位图],其本质是一种依赖数据分布的非线性映射学习过程,侧重通过大规模训练样本拟合输入图像与输出相位之间的隐式关系。该范式具备结构灵活、推理高效、部署简便等优势,适用于成像模型难以显式表达或系统参数未知的复杂条件。为便于系统梳理与比较,本文将基于数据驱动深度学习的定量相位成像方法界定为:推理阶段不显式调用传播模型^[91]或光学参数等解析物理表达,而依赖深度网络直接学习映射关系,其训练标签可来自实验测量或传统物理模型的反演结果。若训练样本由正向物理模型仿真生成,则应归入物理驱动深度学习体系中的物理辅助监督学习,因其在数据层已显式引入物理建模。二者的本质区别在于前者物理模型仅在标签计算中间接出现,后者则直接依赖正向物理建模生成样本。

当前代表性研究涵盖多种网络结构设计与任务类型,形成了较为清晰的发展脉络。从结构设计上看,模型已从传统的浅层卷积神经网络(CNN)向融合胶囊网络^[92]、递归结构^[93]、生成对抗网络^[94]等方向演进,以增强对多尺度特征和空间上下文的表征能力(图7)。例如,2017年,Sinha等^[39]首次证实了基于实验数据训练的深度神经网络(DNN)具备实现相位恢复的能力。2018年,Nguyen等^[47]提出一种基于条件生成对抗网络的CNN架构,并结合图像域与加权傅里叶域的混合损失函数,有效强化了网络在高频细节重建方面的性能表现。2020年,Zeng等^[92]引入残差编码-解码胶囊网络,通过结合残差模块与胶囊机制,显著提升了特征保留能力,克服了传统CNN中因池化与低维表达导致的信息丢失问题。2021年,Huang等^[93]首次将递归神经网络引入全息成像与相位重建任务,提出了同时实现相位恢复与自动对焦的联合优化策略,在显著提升推理速度的同时,有效扩展了成像景深。2023年,Wang等^[95]仅用单幅离焦明场图,通过U-Net端到端学习虚

(a) Training data acquisition method



(b) Schematic diagram of deep learning training process



(c) Typical network structure diagram

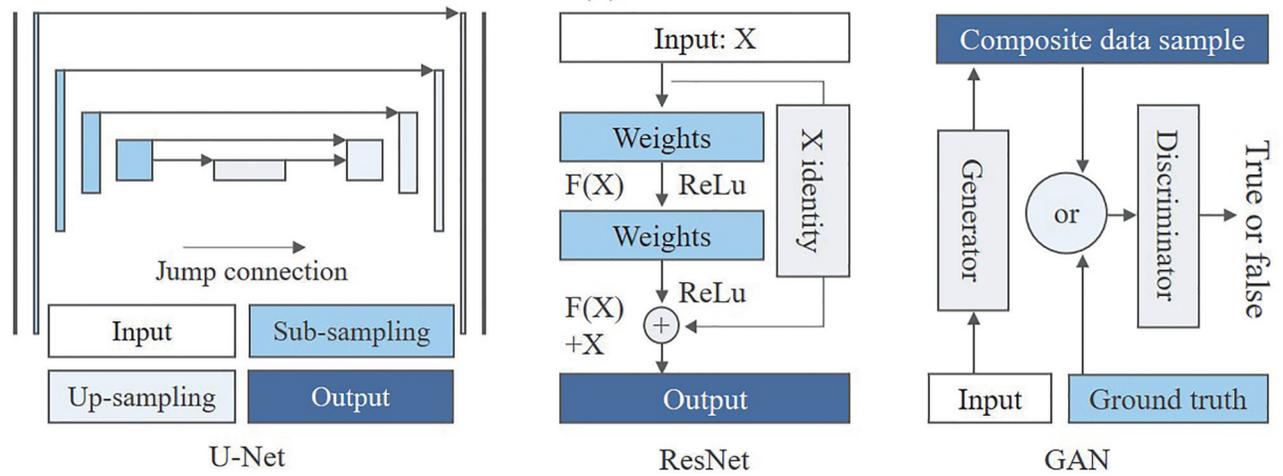


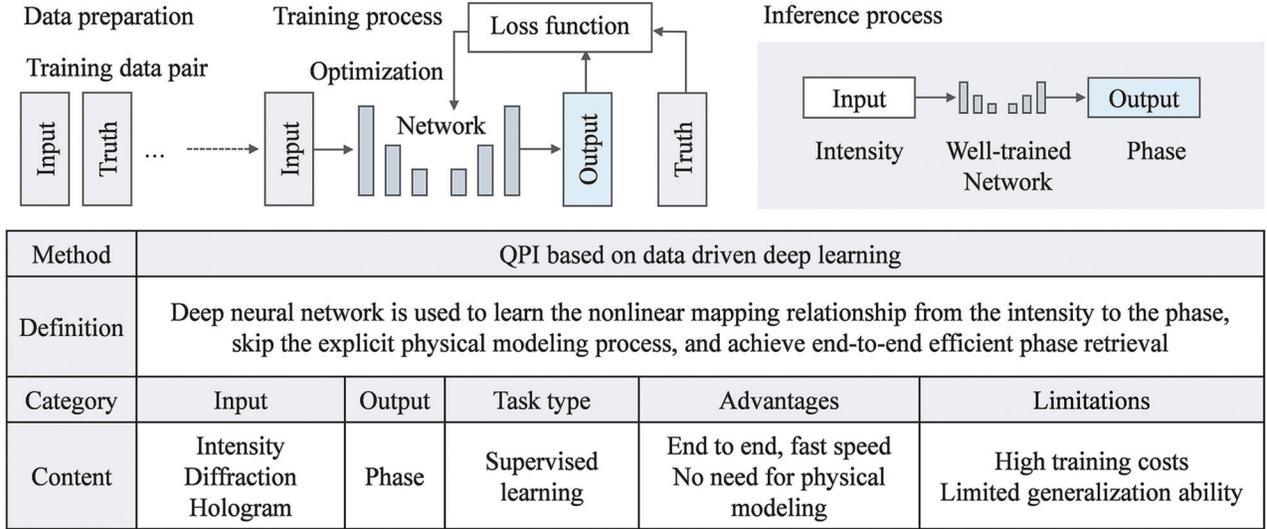
图 6 深度学习的训练数据获取方法、训练过程与典型网络结构图。(a)基于深度学习的定量相位成像方法中常见的训练数据获取方法；(b)基于深度学习的定量相位成像方法的训练过程示意图；(c)典型网络结构示意图(U-Net、ResNet、GAN)

Fig. 6 Training data acquisition method, training process and typical network structure diagram of deep learning. (a) Common training data acquisition methods in quantitative phase imaging based on deep learning; (b) training process diagram of quantitative phase imaging method based on deep learning; (c) typical network structure diagram (U-Net, ResNet, and GAN)

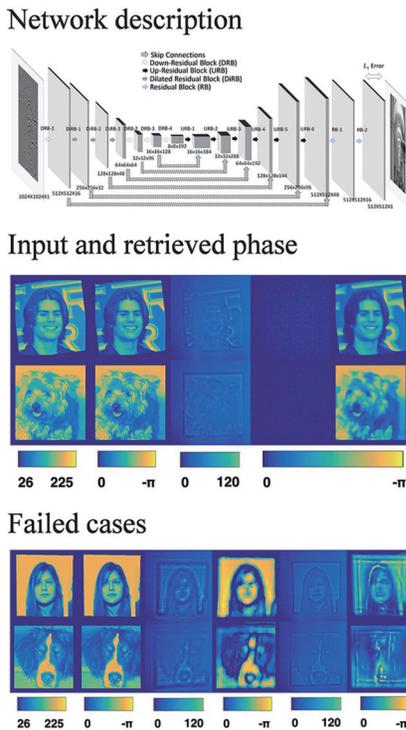
拟全息数据,实现无标记、毫秒级高精度相位恢复。尽管网络结构形式各异,但这些方法在本质上均试图以深度学习的方式模拟光学传播过程中的频率响应与空间耦合机制,体现出“数据建模替代物理建模”的隐式近似思想。从输入形式与重建目标的演化来看,数据驱动方法也展现出从二维图像向多模态、多维度任务拓展的趋势。例如,2022年Ding等^[94]提出的ContransGAN通过生成对抗网络与Transformer模块

实现了低倍率明场图到高分辨率相位图的跨模态映射,提升了低成本系统的成像分辨率。2024年Zhou等^[96]通过开展DL-SRQPI(Deep Learning-based Pixel-Super-Resolved Quantitative Phase Imaging)方法突破传统输入限制,实现了从单帧光强图重建超像素分辨率相位图的功能扩展。上述演进不仅拓宽了该方法在任务维度的适应边界,也推动其从传统图像恢复器向面向任务目标的成像解码器范式转型。

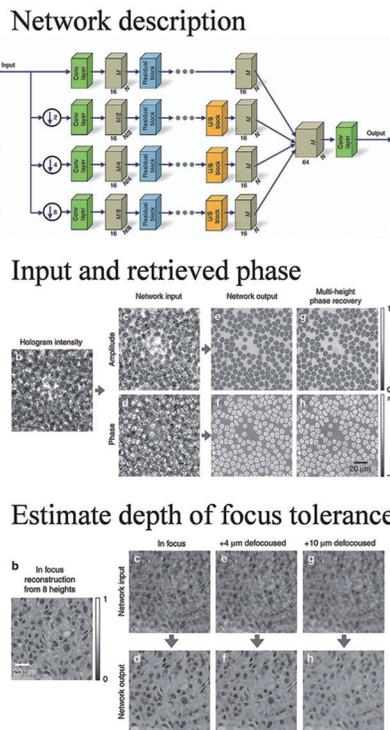
(a) Schematic diagram of training process / inference process



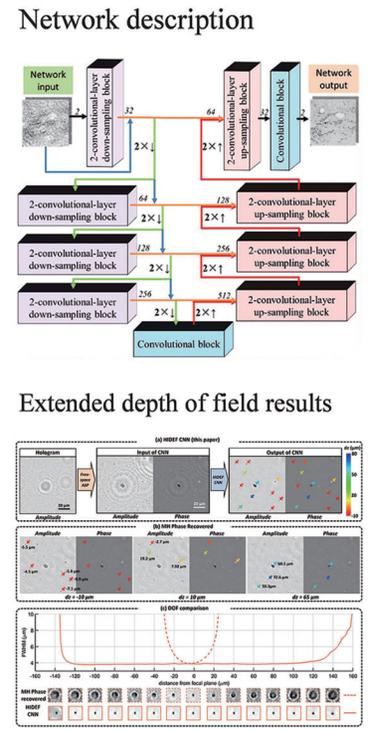
(b) DNN



(c) CNN



(d) HIDEF CNN



Methods	Input	Training data	Training time	Inferential efficiency
DNN	Single intensity	10,000 pairs	20 h	Millisecond level
CNN	Single hologram	150 pairs	14.5 h ~ 22 h	Second level
HIDEF CNN	Single hologram	57,000 pairs	40 h	Millisecond level

图 7 基于数据驱动深度学习的定量相位成像的代表性方法。(a)训练/推理过程示意图及方法小结；(b)基于DNN的方法^[39]；(c)基于CNN的代表性方法^[47]；(d)基于HIDEF的方法^[93]

Fig. 7 Representative methods for QPI based on data-driven deep learning. (a) Schematic diagram and summary of the training/ inference process; (b) method based on DNN^[39]; (c) method based on CNN^[47]; (d) method based on HIDEF^[93]

然而,纯数据驱动方法在缺乏物理约束的前提下,普遍存在可解释性差、泛化能力弱、重建可信度有限等问题^[6,90,97]。一方面,训练依赖高质量光强-相位标签

对,且获取成本高,尤其在非干涉、层析、多帧系统中,这些问题更为显著;另一方面,网络对训练数据分布高度敏感,易因受系统漂移、样本变化及模态迁移影响而

出现性能下降的问题,这限制了其在跨平台、跨任务中的适用性^[98]。此外,端到端模型通常以“黑箱方式”近似复杂的光学传播过程,缺乏物理一致性约束,难以满足高可靠性应用需求^[97]。在缺乏物理先验约束时,纯数据驱动方法难以有效抑制解空间冗余,高维输入易导致映射关系过宽,从而引发对训练样本的过拟合并限制泛化能力^[37]。

实质上,端到端过程可视为一种输入输出关系的统计压缩过程,其性能上限在一定程度上受限于训练数据与目标之间的互信息量与输入信号的有效熵分布^[99]。相比之下,物理模型可作为结构化的先验压缩机制,通过限定信息流路径与可调参数空间,在减少模型自由度的同时提升关键特征的表达效率与高熵输入下的鲁棒性^[52]。因此,为克服上述局限,近年来的研究开始从数据驱动映射向物理数据协同建模演进^[90],逐步融合物理模型的约束与深度网络的表达能力,构建具备物理可解释性与结构透明性的混合范式。一类典型路径是引入弱物理先验,如BNN-QPI(Bayesian Convolutional Neural Network-QPI)利用DPC/FPM原理指导照明模式设计以优化训练样本分布^[100],DL-FPM则通过联合学习照明编码与重建网络实现系统级优化^[47]。这一范式转变不仅体现了对光学成像模型的结构性吸收,更在网络结构、损失函数与优化策略等多层面嵌入物理机制,形成了兼具可解释性与适应性的“半透明建模”体系。从更广义的建模视角看,物理驱动深度学习正逐步打破传统数据驱动与物理驱动方法之间的割裂,通过在数据层、结构层和损失层多维引入物理先验,实现面向复杂实际场景的高性能定量相位成像求解框架。在此基础上,本文将围绕物理融合深度学习的层级与机制,系统梳理当前三种主流路径,并结合建模精度、数据依赖与适用场景等维度进行比较,同时为后续的趋势与挑战分析奠定框架基础。

4 基于注入层级的三类物理驱动深度学习融合范式

数据驱动深度学习在各类科学计算任务中已取得突破性进展,但其方法论内核仍根植于独立同分布假设之下的大规模数据拟合范式。该范式在模型外推性、可解释性及物理一致性等关键维度上暴露出根本性局限,其具体表征可归纳为如下三点:第一,深度神经网络具有高度非线性和高容量的建模能力,易于对训练分布产生过拟合,从而在分布外出现违背物理规律的非物理解,影响其泛化性能^[101];第二,神经网络作为典型的“黑箱”模型,缺乏对变量间因果关系的显式建模,难以确保其预测结果符合守恒律、对称性、不变性等基本物理约束^[97];第三,在数据获取困难或观测存在噪声的场景中,纯粹依赖数据驱动的学习方法难以准确捕捉系统的内在动力学过程,导致结果的不稳定性与不可靠性^[37]。上述问题的深层根源在于传统统计

学习框架对因果结构的忽视。典型的神经网络以条件概率模型 $p(y|x)$ 构建输入与输出之间的映射关系,然而这一过程未能体现由物理定律所定义的结构性因果模型(SCM)^[102]。相较之下,物理规律通常以微分方程、积分形式、变分原理或守恒定律等方式刻画系统中变量间的因果机制与不变性,从理论上为反事实推理与分布外泛化提供了保障^[103]。因此,将物理先验知识以因果约束形式嵌入深度学习模型,不仅有助于提升模型的泛化能力与物理一致性,还赋予模型对“干预(Intervention)”与“反事实(Counterfactual)”问题的处理能力,拓展了深度学习在科学计算中的应用边界。以Karniadakis等^[52]提出的物理信息神经网络(PINN)为代表的研究已证明通过将偏微分方程作为正则项嵌入神经网络的训练目标,可显著提升模型在稀疏数据条件下的收敛性与物理一致性。在此基础上,Ongie等^[38,50,52]进一步系统梳理了相关方法,指出当前物理知识嵌入路径可归纳为三类典型策略:物理级联网络(PcN)、网络嵌入物理方法(NiP)以及嵌入式物理网络(PiN)。三者虽有重叠,但在嵌入机制与作用路径上各具特点,这体现了从输入数据到网络结构再到目标函数的多层级物理干预思路。为进一步整合上述理论基础与模型实践,如图8所示,本文从物理先验在深度学习流程中注入位置的层级差异出发,构建了一个统一且具备方法指导意义的三分法分类框架。

该框架强调根据物理知识嵌入深度模型的主要作用层面,将现有方法系统划分为以下三类融合路径:1)基于数据构造的PASL:主要通过物理模型生成训练数据或引导输入特征构造,从而提升样本的物理一致性与表达合理性,该方法适用于训练标签不足或真实样本难以获取的监督学习场景;2)基于结构设计的PEIN:在网络内部显式集成光学传播模型、优化求解结构或物理算子模块,使网络结构在归纳偏差层面贴合成像物理规律,增强模型的泛化性能与稳健性;3)基于优化目标的PRL:通过在损失函数中引入正向模型等物理正则项,提升模型在无监督或弱监督条件下对物理约束的自洽满足。不同于以任务类型或网络结构为主的表层划分,本文提出的注入层级分类框架基于物理先验在深度学习流程中的嵌入路径,能够揭示各类方法背后的因果干预逻辑与物理机制嵌入方式。该框架不仅有助于统一整理当前研究范式,更为理解物理驱动方法的建模原理与演化趋势提供了理论支撑,具备一定的方法论适应性与解释力。

4.1 数据层注入:物理辅助监督学习

传统监督学习方法通常依赖大量高质量光强-相位标签对,而相位信息不可直接测量,高精度标签获取往往依赖复杂系统,这严重制约了深度学习在真实场景中的应用。为突破该瓶颈,研究者提出了PASL方法,通过在训练数据构建阶段引入物理传播模型或先

验约束,将成像过程中的物理机制显式嵌入样本生成或训练反馈流程中,从而从源头提升样本的物理一致性与任务相关性。该策略不仅有效缓解了标签获取难题,还增强了物理解释性,逐步形成了融合物理建模与深度学习的系统范式。整体来看,PASL方法已从最初的物理仿真驱动,拓展至近似估计监督与结构反馈协同的多维融合模式,其发展脉络反映出从数据层向结构层、从静态建模向闭环优化的范式演进趋势。具体而言,PASL大致可归纳为三类典型路径:1)基于物理建模生成训练样本对。该策略以物理传播模型 $\mathcal{P}(\cdot)$ 为基础,从仿真相位图 ϕ_{sim} 出发,生成对应的光强图 $I_{\text{sim}} = \mathcal{P}(\phi_{\text{sim}})$,构建出训练样本对 $\{I_{\text{sim}}, \phi_{\text{sim}}\}$,用于监督神经网络 \mathcal{N}_θ 的训练过程,从而在合成数据闭环中实现对物理响应规律的学习。2)基于物理近似标签的迁移学习。针对真实采集图像 I_{meas} ,通过经典物理模型 $\mathcal{F}_{\text{phys}}$ 得到粗略估计的相位 $\hat{\phi}_{\text{inv}} = \mathcal{F}_{\text{phys}}(I_{\text{meas}})$,作为网络的输入初值、监督标签或正则引导项(或将测量值 I_{meas} 一并输入网络),引导神经网络从近似解出发收敛至更精确的重建结果,即优化过程可表述为: $\hat{\phi} = \mathcal{N}_\theta(I_{\text{meas}}, \hat{\phi}_{\text{inv}})$ 。3)基于网络输出反哺物理模型更新。该策略强调“以学促物”的前处理思想,即首先通过神经网络 \mathcal{N}_θ 对原始光强图 I_{meas} 进行去噪或增强处理,得到预处理后的图像 $\hat{I} = \mathcal{N}_\theta(I_{\text{meas}})$,再将其作为输入传递至经典物理模型 $\mathcal{F}_{\text{phys}}$,以实现高精度相位估计: $\hat{\phi} = \mathcal{F}_{\text{phys}}(\hat{I}) = \mathcal{F}_{\text{phys}}[\mathcal{N}_\theta(I)]$ 。该方法在保持物理建模主导地位的同时,利用深度网络提升输入质量或提取更具判别力的结构特征,常用于弱信号、强噪声或复杂场景下的重建任务,体现了神经网络与物理模型在输入空间的互补融合。这三类路径从纯物理驱动的样本合成逐步演化至学习主导的物理反馈,构成了PASL法从数据层融合向模型层融合的演进图景,为解决训练数据获取困难等问题提供了多样化的实现路径与工程支撑。

4.1.1 物理建模生成训练样本对

在实际应用中,仿真数据构建法是PASL法最早期、主流的实现形式,其发展可追溯至2018年前后。如图9所示,2019年Zhang等^[104]基于傅里叶叠层显微成像的正向物理模型,构建多角度图像堆栈仿真数据,并结合多尺度残差网络进行复振幅重建,首次展示了仿真数据结合神经网络进行相位恢复的可行性。随后,2019年,Li等^[105]在非干涉成像场景下提出了双光强图输入与cGAN相结合的无监督重建框架,通过构造光强域配对样本,实现了在缺乏真实标签条件下的端到端相位恢复。2024年,Wang等^[106]将局部条件神经场引入计算成像,以连续域神经表征突破像素限制,结合仿真数据与实验数据混合训练机制,实现了傅里叶叠层相位恢复的超分辨、无伪影、跨域泛化。2025

年,Narayan等^[107]利用Zernike多项式构建高阶相位场,从而提升神经网络对高阶导数的建模能力,并扩展仿真相位分布的表示空间。这一阶段的研究方法普遍强调“系统先验注入”策略,即在训练样本构建环节显式引入成像系统结构参数、光学传输特性以及采集路径约束,通过构建“仿真-训练”闭环,显著提升模型在训练与推理阶段对成像物理规律的响应一致性。从方法论视角看,该类策略可归属于迁移学习范畴^[108-109],其核心思想在于通过物理先验与任务驱动信号的融合,提升输入与目标相位之间的互信息密度^[110-111],增强监督信号的有效性与可控性,其优点包括训练效率高、网络结构设计灵活、模型可解释性较强以及物理一致性良好,尤其适合在有限实验数据条件下的成像任务。然而,该方法虽在理想条件下表现优异,但其对仿真精度与场景匹配度的高度依赖,使得其在存在仿真-实验域差异时泛化能力受限,并在噪声、系统漂移或光学非理想条件下系统性能进一步削弱,因而在真实应用中往往需要结合域适配或自校正机制加以改进。

4.1.2 物理近似标签的迁移学习

2020年以后,一类先利用简化物理模型计算粗略相位并将其作为网络初值或先验输入的物理近似标签迁移学习策略逐渐兴起,成为PASL法的重要分支。如图10所示,Goy等^[112]与Deng等^[42]分别提出将基于GS迭代的近似相位作为网络训练输入,以在提高网络物理一致性的同时,避免了昂贵的相位标注开销。2018年,Kemp^[44]进一步发展了基于TIE传播模型的正则补偿训练策略,增强了网络对强噪声条件下边界相位恢复的鲁棒性。同年,Rivenson等^[40]提出基于角谱传播模型的单帧复场重建方法,显著提升了网络训练过程的物理可解释性与收敛稳定性。2022年,Huang等^[113]提出一种基于预训练循环神经网络的全息图小样本迁移重建方法,同样采用角谱传播生成初始复场作为物理引导输入,并通过固定RNN骨干模块实现结构化迁移。该方法在仅需要少量新样本的条件下实现了对未知样本类型的高精度复场重建,不仅显著降低了可训练参数规模与训练成本,也展现出优异的跨域泛化能力与工程适应性。

这类方法可视为信息瓶颈机制在物理引导条件下的具体实现:先由物理模型提供低信息熵的粗估结果,再通过深度网络进行非线性映射,补充细节、抑制伪影,并提升表达能力。这种“物理先验+迁移压缩”的策略不仅提高了训练效率,还增强了模型在跨域场景下的泛化能力与物理可解释性,尤其适用于成像机理明确且需要快速适配的应用场景,如不同样本类型的快速切换、实验系统参数变化后的自适应重建等。然而,这类方法的性能在很大程度上受物理模型初值质量的制约。当初始估计存在系统性偏差时,网络容易在高频细节或边缘区域产生伪影,导致重建质量下降与训练收敛不稳定。为应对这一局限,未来研究可

(a) Classification of QPI methods based on physics driven deep learning

Methods	Physics-assisted supervised learning, PASL	Physics-embedded inference networks, PEIN		Physics-regularized learning, PRL
Introduction position	Data layer	Structural layer	Network	Loss function
Mechanism description	Physical modeling generates training sample pairs Transfer learning of physical approximation labels Network output feeds back physical model updates	Modular design of differentiable propagation operators	Optimizing iterative unfolding network	Unsupervised propagation residual loss Self supervised pseudo label closed loop

(b) Schematic diagram of the training / inference process of different PD-DL QPI methods

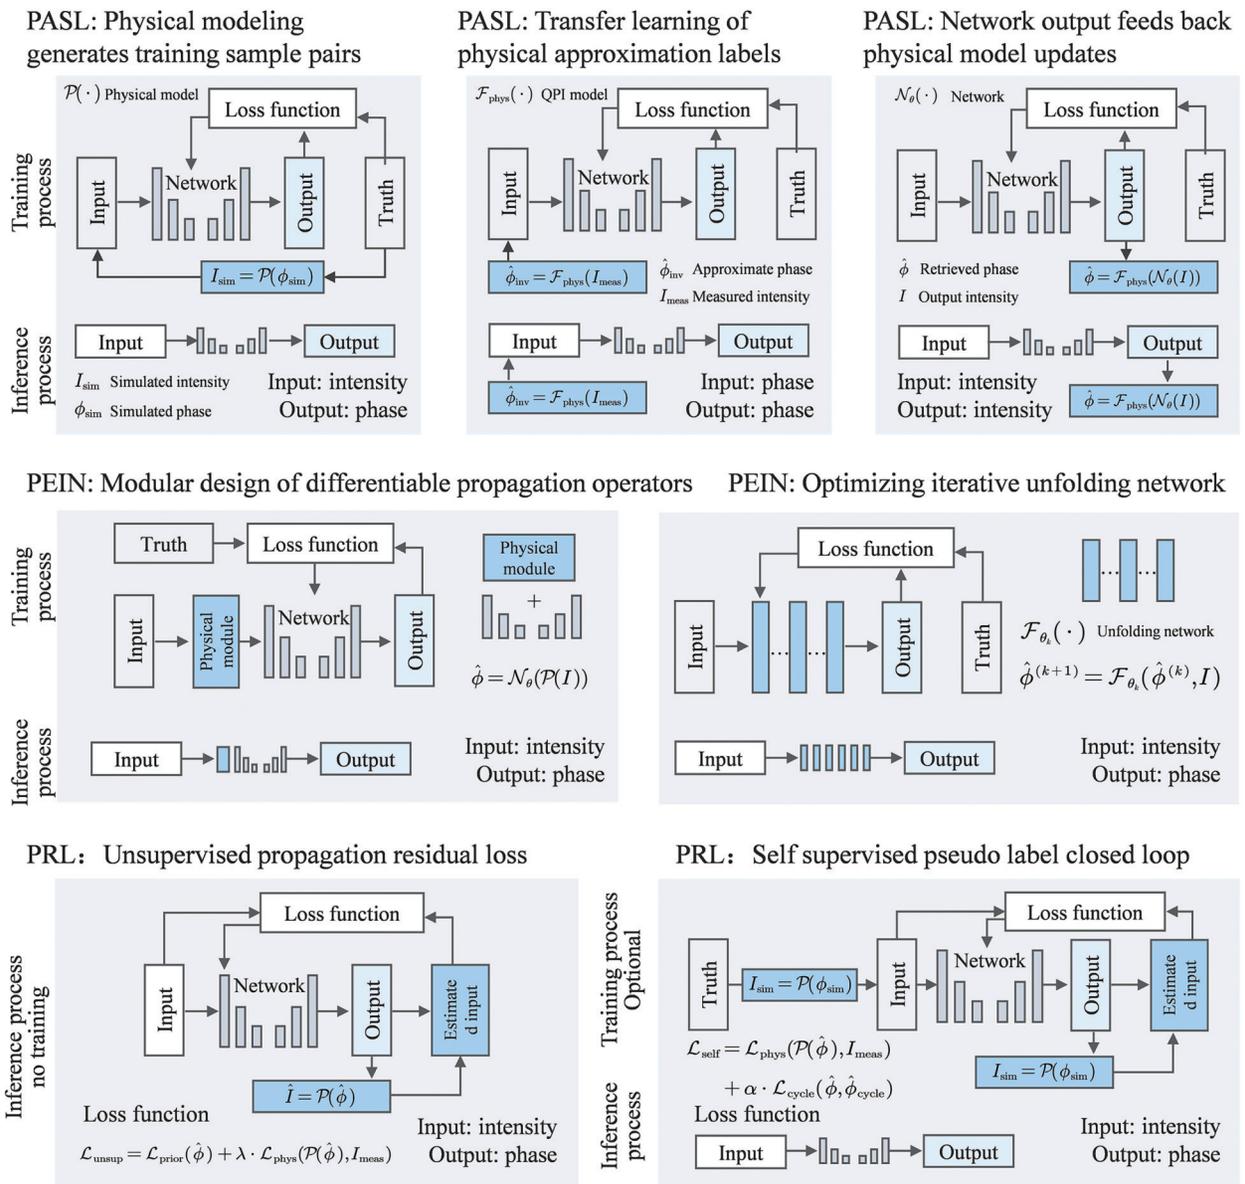
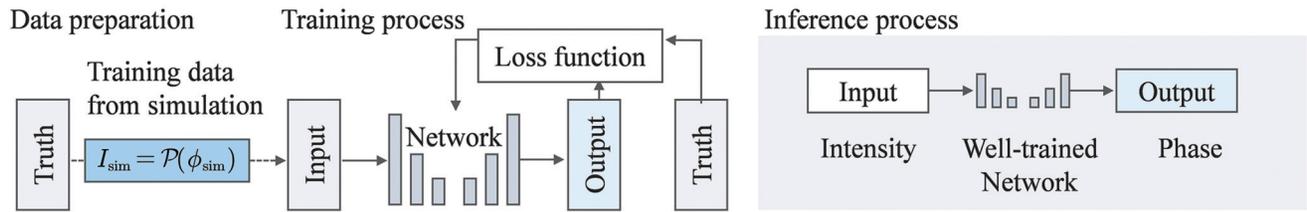


图 8 物理驱动深度学习方法分类概览图。(a) 基于物理驱动深度学习的定量相位成像方法分类汇总表; (b) 基于物理驱动深度学习的定量相位成像方法的训练/推理示意图

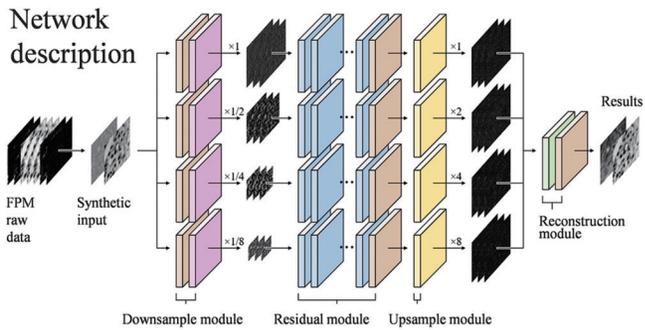
Fig. 8 Overview of classification of physics-driven deep learning methods. (a) Summary of QPI methods based on physics-driven deep learning; (b) schematic diagram of training/inference of QPI method based on physics-driven deep learning

(a) Schematic diagram of training process / inference process

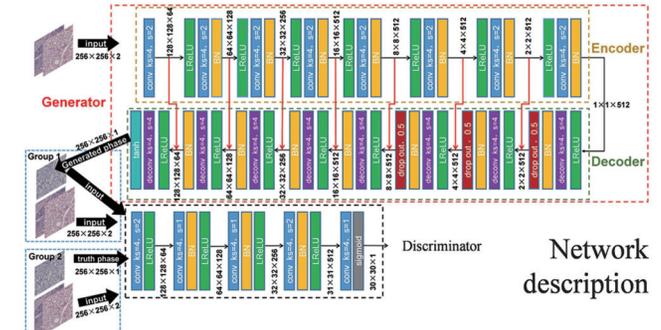


Method	PASL: Physical modeling generates training sample pairs				
Definition	Based on the physical propagation model, the simulated intensity is generated from the phase, so as to construct the training sample pair to supervise the training process of the neural network				
Category	Input	Output	Task type	Advantages	Limitations
Content	Intensity Diffraction Hologram	Phase	Supervised learning	Reduce the dependence on real labels and ensure the physical consistency of data	Domain gap

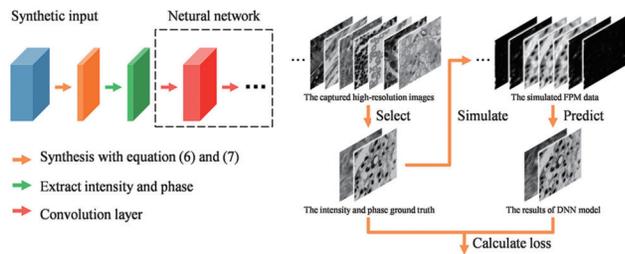
(b) FPNN



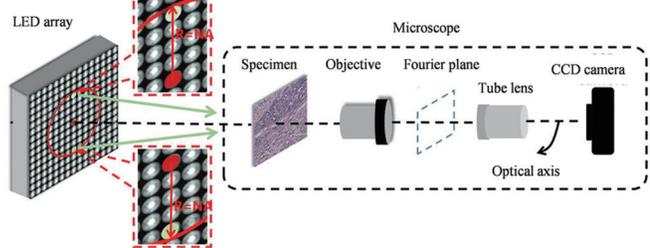
(c) cGAN



Examples of building and using training data sets



Schematic diagram of imaging system



Methods	Input	Training data	Training time	Inferential efficiency
FPNN	Intensity and phase from angular spectrum propagation	Simulation 23,040 pairs + fine tune 800 pairs	Not mentioned	Millisecond Level
cGAN	Two intensity under symmetrical illumination	Simulation 1,301 pairs	Not mentioned	Millisecond Level

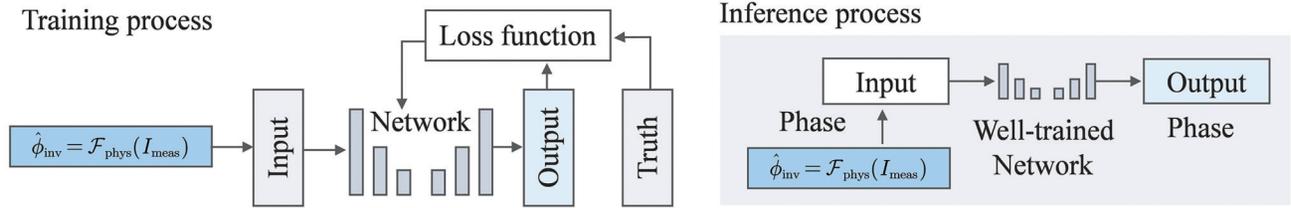
图9 PASL代表方法:基于物理建模生成训练样本的定量相位成像的代表性方法。(a)训练/推理过程示意图及方法小结;(b)基于FPNN的方法^[104];(c)基于cGAN的方法^[105]

Fig. 9 PASL representative methods: representative methods of QPI based on physical modeling to generate training samples. (a) Schematic diagram of training/inference process and method summary; (b) method based on FPNN^[104]; (c) method based on cGAN^[105]

结合多尺度相位估计、迭代优化嵌入、自适应域适配等技术,以进一步减小对初值精度的依赖,提升系统

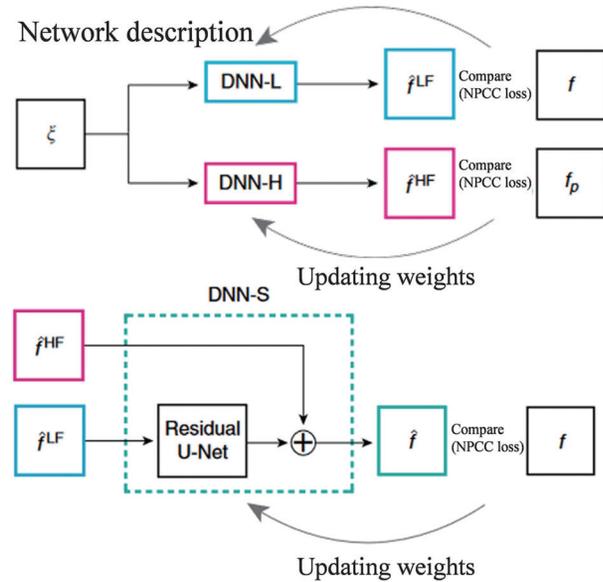
在复杂噪声、系统漂移及非理想光学条件下的鲁棒性。

(a) Schematic diagram of training process / inference process

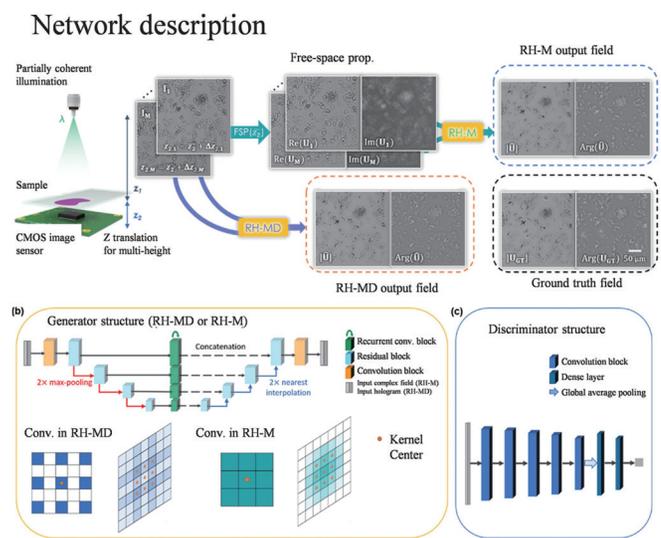


Method	PASL: Transfer learning of physical approximation labels				
Definition	The phase estimated via the classical physical model serves as the network's initial input, guiding it to converge from an approximate solution to a more accurate reconstruction				
Category	Input	Output	Task type	Advantages	Limitations
Content	Estimated phase	Phase	Supervised learning	Reduce learning pressure Improve cross domain generalization ability	Quality is limited by physical model

(b) RNN



(c) RH-M



Methods	Input	Training data	Training time	Inferential efficiency
RNN	Approximate phase obtained by GS iteration	9,500 pairs	Not mentioned	Millisecond level
RH-M	Intensity and phase from angular spectrum propagation	Pre-training 2,000 pairs training 80 pairs	Not mentioned	Millisecond level

图 10 PASL 代表方法: 基于物理近似标签的迁移学习的定量相位成像的代表性方法。(a) 训练/推理过程示意图及方法小结; (b) 基于 RNN 的方法^[42]; (c) 基于 RH-M 的方法

Fig. 10 PASL representative methods: representative methods of QPI based on transfer learning of physical approximation labels. (a) Schematic diagram of training/inference process and method summary; (b) method based on RNN^[42]; (c) method based on RH-M

4.1.3 网络输出反哺物理模型更新

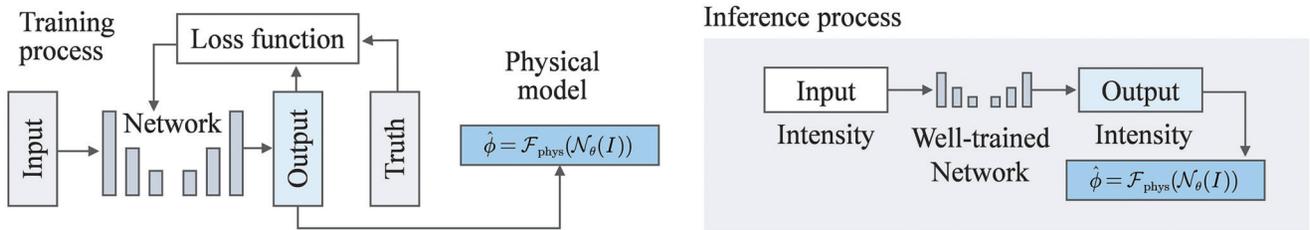
近年来逐步出现融合结构反馈与物理校正机制的 PASL 法, 即网络输出反哺物理模型更新法。如

图 11 所示, 2023 年, Li 等^[54] 提出 DL-VHQPI (Deep Learning Assisted Variational Hilbert Quantitative Phase Imaging) 方法, 将变分 Hilbert 模型作为基础物

理框架,并利用卷积神经网络对残差部分进行补偿,实现了物理-学习的联合建模。Zhang 等^[114]则提出 Deep Phase Shifter 方法,利用深度生成网络构造拟干涉图,驱动后续的物理重建过程,体现出“网络优化+物理反馈”双向协同的新特征。该机制在成像反演中保留了物理建模的主导地位,保障结果的物理一致性与可解释性,并通过结构反馈聚焦物理残差区域,充分发挥深

度网络在图像结构与噪声建模上的优势,从而增强系统对复杂样本及系统非理想因素的适应性,同时,其在输出空间引入的物理约束实现了不确定性压缩,进一步提升了低信噪比条件和跨域任务下的泛化性能。然而,相较于传统以静态伪标签训练为主的 PASL 法,该类协同建模机制在实现上更为复杂:一方面,需要在网络中集成残差估计、生成反馈等模块,这对结构设计与

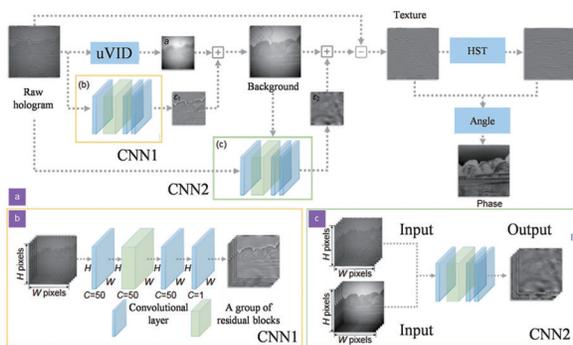
(a) Schematic diagram of training process / inference process



Method	PASL: Network output feeds back physical model updates				
Definition	The neural network denoises or enhances the original intensity to produce a preprocessed image, which is then fed into the classical physical model for more robust or precise QPI				
Category	Input	Output	Task type	Advantages	Limitations
Content	Intensity Diffraction Hologram	Intensity diffraction Hologram	Supervised learning	Reduce learning pressure Improve cross domain generalization ability	Quality is limited by physical model

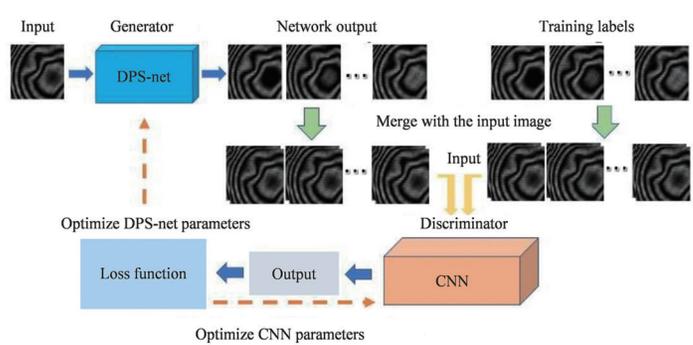
(b) uVID + CNN

Network description



(c) DPS-net

Network description



Methods	Input	Training data	Training time	Inferential efficiency
uVID + CNN	Single frame hologram	324 pairs	2.8 h	Millisecond level
DPS-net	Single frame hologram	Not mentioned	Not mentioned	Millisecond level

图 11 PASL 代表方法:基于网络输出反哺物理模型更新的定量相位成像的代表性方法。(a)训练/推理过程示意图及方法小结;
(b)基于 uVID+CNN 的方法^[54]; (c)基于 DPS-net 的方法^[114]

Fig. 11 PASL representative methods: representative methods of QPI based on network output feedback physical model updating.
(a) Schematic diagram of training/inference process and method summary; (b) method based on uVID+CNN^[54]; (c) method based on DPS-net^[114]

物理建模之间的协同提出更高要求;另一方面,反馈过程依赖传播模型的准确性与可微性,系统误差或模型近似可能导致训练不稳定甚至优化偏移。因此,尽管协同建模机制在表达能力与系统适应性方面具有明显优势,但在工程落地中仍面临设计复杂、模型耦合强与资源消耗高等挑战,推广应用尚需进一步优化与简化。

4.1.4 小结

PASL法的三类典型路径分别对应于深度学习流程中信息调控的不同阶段:物理建模驱动的仿真样本构建提升了输入与输出之间的互信息密度,强调信息注入的先验增强作用;基于物理估计的近似监督机制则在特征学习阶段引入低熵引导,形成中间压缩的特征约束;而结构反馈与物理残差校正策略则通过输出端的闭环调控,有效压缩解空间的不确定性,体现输出投影的信息收敛功能。三类方法从输入构造、网络表示到输出优化形成了层层递进的信息瓶颈控制链条,其本质在于以成像物理为先验约束,系统性地调节模型各阶段的信息冗余结构,以保障在弱标签甚至无标签条件下的稳定训练与有效泛化。总体来看,PASL法作为一种以物理建模为先导、以样本构建为媒介、以监督训练为承载的融合范式,在显著降低训练数据获取成本的同时,有效提升了模型的物理一致性与可解释性,其贯穿网络输入-结构-输出的信息调控策略,不仅扩展了数据驱动方法在实际成像系统中的适用边界,也为构建更高效、更具物理可解释性的弱监督学习框架提供了理论依据与方法范式,为后续物理建模与深度学习深度融合的发展方向提供了重要支撑。

4.2 结构层嵌入:物理过程嵌入型网络

在物理驱动深度学习的发展体系中,PEIN方法标志着从数据生成层面的物理辅助PASL向结构建模层面的物理融合迈进的关键阶段。相较于PASL方法主要在样本构建过程中嵌入物理模型以提升训练数据的表达能力与物理一致性,PEIN方法则进一步将光学传播机制、成像控制方程或优化算法直接融入网络结构,使物理先验在信息流动与特征建模过程中发挥显性作用。这一机制体现了从辅助式建模向结构级协同的跃迁,有效增强了模型的系统适应性、物理可解释性与泛化稳健性,其核心理念是将物理建模结构与可学习参数共同表达,通过模块化方式嵌入网络生成器、解码器或优化路径,实现可训练性与物理约束性的协同统一。根据物理过程与网络耦合机制的不同,PEIN方法主要分为结构嵌入策略与优化展开策略两大类,分别代表了显式建模与结构反演的两种融合思路,共同构建起当前以结构为核心的物理融合技术图景。

根据物理过程与网络结构的耦合方式不同,现有PEIN方法大致可分为两类典型路径。第一类为基于可微传播算子的模块化设计(结构嵌入策略),其核心思想是将成像过程中的传播机制(如角谱传播或光场衍射等物理模型)参数化为神经网络中的可微模块,从

而使物理模型直接参与网络的前向传播过程,在数学上可表示为 $\hat{\phi} = \mathcal{N}_\theta(I)$,其中, I 为输入光强, $\mathcal{N}_\theta(\cdot)$ 为嵌入参数化物理传播模块(如数值传播算子)的深度神经网络, $\hat{\phi}$ 为输出相位。该策略强调通过结构性建模将物理先验内嵌于网络表征中,提升模型的物理一致性与可解释性。第二类为优化迭代展开网络策略(迭代展开),其基本思路是以传统优化算法(如ADMM^[115])为原型,将迭代求解过程逐步展开为具有可训练参数的网络层级,即 $\hat{\phi}^{(k+1)} = \mathcal{F}_{\theta_k}(\hat{\phi}^{(k)}, I)$,此处 $\hat{\phi}^{(k)}$ 表示第 k 层(即第 k 次迭代)的中间重建结果, $\mathcal{F}_{\theta_k}(\cdot)$ 表示把对相位的迭代步骤表示为迭代超参数的可学习模块, θ_k 可在训练中学习得到。该策略在保持优化算法物理结构的基础上,赋予网络更好的灵活性与适应性。这两类路径分别体现了“物理辅助-网络主导”与“优化求解-网络协同”的两种典型融合机制。前者以物理建模为结构引导核心,通过在网络中嵌入光学传播算子、成像方程或系统参数先验,为深度网络提供与任务高度相关的物理结构框架,使其在特征提取与映射过程中始终保持对成像物理的感知。后者则以迭代展开为代表,将传统迭代反演算法的求解流程显式展开为网络层级,实现物理建模与深度学习的逐步协同优化,使网络在遵循物理约束的同时具备非线性表达与自适应调节参数的能力,从而显著提升重建精度、收敛速度及对复杂系统扰动的鲁棒性。二者虽在实现路径与物理嵌入位置上有所差异,但共同构成了PEIN方法从松散耦合(如物理模块外置)到强融合(如端到端协同优化框架)的技术演进图景。这一演进不仅反映了物理建模与深度学习在结构层面融合模式的多样化,也揭示了该领域正从单一的前后端约束向多层次、多阶段的深度协同发展,为未来实现高精度、高鲁棒性与高可解释性的定量相位成像提供了坚实的技术基础。

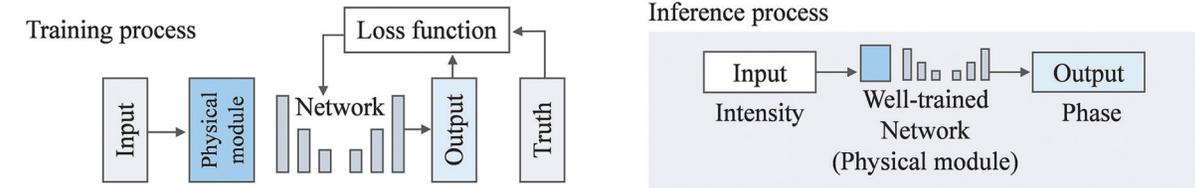
4.2.1 可微传播算子的模块化设计

在结构嵌入策略方面,学者持续探索将光学传播过程构建为可微分模块并集成于网络的生成器或解码器等结构中,从而增强模型对成像机制的刻画能力。2018年,Nguyen等^[47]在傅里叶叠层显微成像中提出结合多角度照明与传播模拟的卷积神经网络架构,在弱监督条件下实现了复振幅的端到端重建,率先验证了传播算子与神经网络结构融合的可行性。如图12所示,2021年,Zhang等^[53]提出的PhaseGAN方法在生成器输出端嵌入可微的菲涅耳传播算子,使物理传播过程直接参与网络推理,这体现了结构层物理建模的典型特征;同时,该方法在训练中引入传播一致性损失以约束输出图像,与物理一致性约束PRL法存在一定交叉融合(PRL法的相关内容详见4.3节)。2023年,Lee等^[116]进一步提出Parameterized PhaseGAN,通过将传播距离、像素尺寸等系统参数建模为可学习变量并嵌

入传播路径中进行联合优化,实现了复振幅与成像参数的协同反演,显著增强了模型对系统扰动与跨域分布的自适应能力。2024年, Li等^[117]提出 DL-CSPF (Deep-Learning-Based Cell Segmentation with Physical Framework)方法,将数字全息的光学传播先验与前景边缘/种子点提取机制嵌入双网络结构,并结

合理物理约束分水岭算法,实现了在噪声和系统参数变化下依然保持高精度的定量相位成像与细胞结构识别。此类方法可视为一种面向中间表征空间的信息重构机制,通过引入可微传播模型将成像系统的光学传播过程显式嵌入到网络结构中,从而在深度特征空间中保留并强化物理场的因果关系与演化逻辑。可微传

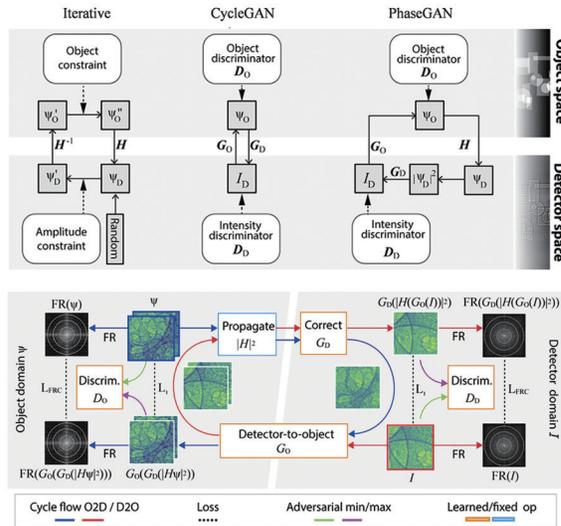
(a) Schematic diagram of training process / inference process



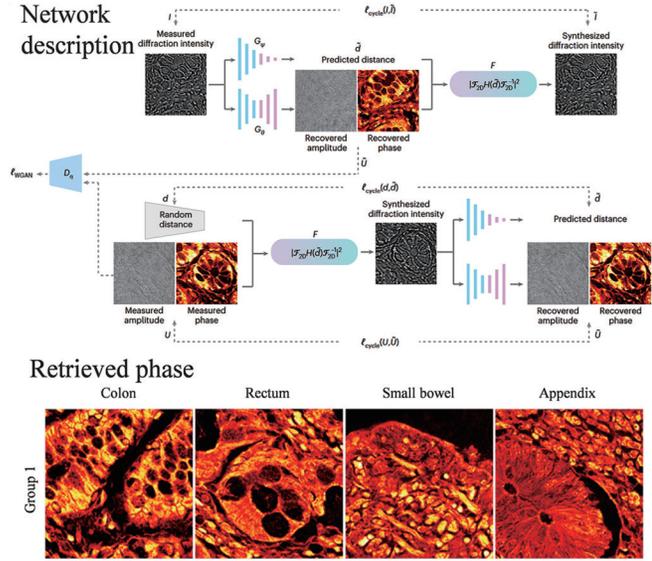
Method	PEIN: modular design of differentiable propagation operators				
Definition	The imaging propagation mechanism is parameterized as a differentiable module, allowing the physical model to directly participate in the network's forward propagation				
Category	Input	Output	Task type	Advantages	Limitations
Content	Intensity Diffraction Hologram	Phase	Unsupervised/ Supervised learning	Strong physical interpretability and improved cross domain generalization ability	Quality is limited by physical model

(b) PhaseGAN

Principle comparison and network description



(c) Parameterized PhaseGAN



Methods	Input	Training data	Training time	Inferential efficiency
PhaseGAN	Single frame diffraction pattern	10,000 unmatched samples	Number of hours	Millisecond level
Parameterized PhaseGAN	Intensity and phase from angular spectrum propagation	6,000 unmatched samples	12 h	Sub-millisecond level

图 12 PEIN 代表方法: 基于可微传播算子的模块化设计的定量相位成像的代表性方法。(a) 训练/推理过程示意图及方法小结; (b) 基于 PhaseGAN 的方法^[53]; (c) 基于 Parameterized PhaseGAN 的方法^[116]
Fig. 12 PEIN representative methods: representative methods of QPI based on modular design of differentiable propagator. (a) Schematic diagram of training/inference process and method summary; (b) method based on PhaseGAN^[53]; (c) method based on Parameterized PhaseGAN^[116]

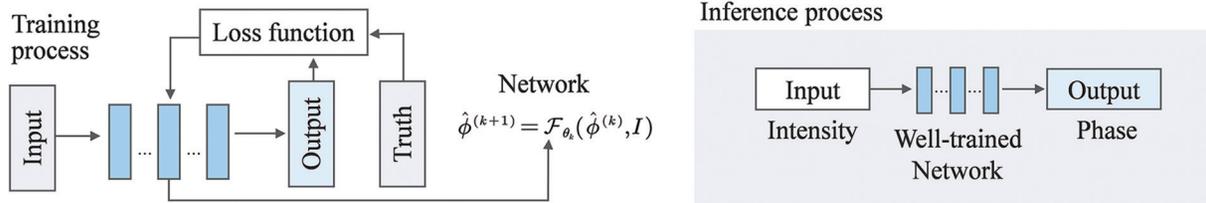
播模块不仅提高了特征层的信息保真度,避免因黑盒特征提取造成的物理失真,还能结合传播一致性损失等手段实现对物理规律的显式约束,形成“结构约束下的信息整合”范式。相比传统深度网络在中间层存在的信息混叠与物理割裂,该类方法在实现有效重建的同时,也提升了模型的结构透明度与物理可解释性。因此,该方法适用于传播模型精确、系统参数可测、成像链路明确的场景,在此类场景下可实现对系统结构、噪声机制与边界条件的高保真建模与鲁棒推理。

4.2.2 优化迭代展开网络

优化迭代展开网络法以传统相位重建算法为原型,将变量更新过程展开为神经网络的可训练层,从而

在继承优化逻辑的同时引入深度学习的表达能力。2019年,Monakhova等^[118]提出Le-ADMM系列方法,率先将ADMM框架的重建-正则交替迭代过程模块化并表达为网络结构,引入图像感知损失与可学习滤波器,兼顾了推理效率与图像质量,在模型控制性与重建泛化性之间取得良好平衡。如图13所示,2022年,Ma等^[119]推出Net-ADM方法,将ADMM框架^[115]与无训练生成网络(如Deep Decoder)相结合,通过引入结构隐式先验对中间变量进行正则化投影,在无监督、极低采样率等苛刻条件下仍实现了高保真相位恢复,并通过理论分析验证了算法的收敛性与稳健性。2023年,Yang等^[120]提出HIONet方法,以Fienup^[121]的HIO(Hybrid Input-Output)算法为基础构建深度展开网络,

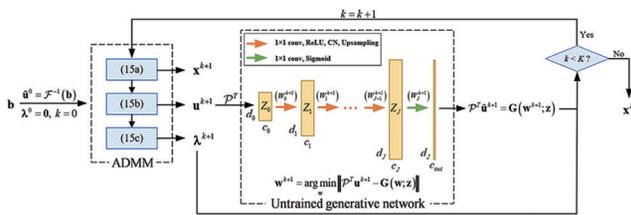
(a) Schematic diagram of training process / inference process



Method	PEIN: Optimizing iterative unfolding network				
Definition	Taking the traditional optimization algorithm as the prototype, the iterative solution process is expanded into the network level with trainable parameters				
Category	Input	Output	Task type	Advantages	Limitations
Content	Intensity Diffraction Hologram	Phase	Unsupervised/ Supervised learning	Structure level fusion of physical modeling and deep learning	Expandability of dependency optimization framework

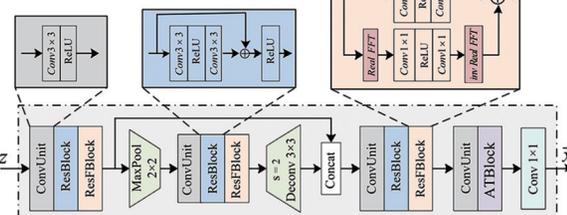
(b) Net-ADM

Network description



(c) HIONet

Network description



Methods	Input	Training data	Training time	Inferential efficiency
Net-ADM	Single frame Fourier amplitude spectrum	No training required	No training required	Minute level
HIONet	Single frame Fourier amplitude spectrum	2,000 pairs	30 h	Second level

图 13 PEIN 代表方法: 基于优化迭代展开网络的定量相位成像的代表性方法。(a) 训练/推理过程示意图及方法小结; (b) 基于 Net-ADM 的方法^[119]; (c) 基于 HIONet 的方法^[120]
 Fig. 13 PEIN representative methods: representative methods of QPI based on optimized iterative unfolding network. (a) Schematic diagram of training/inference process and method summary; (b) method based on Net-ADM^[119]; (c) HIONet based method^[120]

并引入空间-频域融合的多尺度卷积模块作为可学习投影单元,在提升边缘结构与高频细节恢复能力的同时,保持了物理约束的可解释性与稳定性。优化展开类方法将传统迭代重建算法映射为神经网络结构,在保留物理建模可解释性的同时引入可学习参数,有效提升了重建精度与推理效率。这类方法在推理阶段对求解路径进行显式信息编码,形成迭代求解下的结构压缩,从而有效抑制重建解的多解性与不确定性。优化展开类方法尤其适用于成像物理机制明确、算法迭代路径可解析,且对推理效率与模型可控性具有较高要求的高精度重建任务。

4.2.3 小结

PEIN法通过在网络内部显式引入成像物理过程,将物理传播算子嵌入可微图,使梯度回传路径与光场实际传播路径一致。该类方法的核心思想在于:将光场传播模型、优化求解策略或系统响应函数以可微形式嵌入网络结构,使物理规律不仅作为先验约束存在于训练目标中,更使其深度融入到特征提取与推理建模的全过程,从而形成一个由物理机制主导的信息压缩链条。具体而言,PEIN法主要在网络中间结构层面发挥作用。首先,通过将角谱传播、波动方程或衍射积分等物理过程模块化并嵌入网络,可显著提高特征表示的物理一致性,避免语义特征与光学机制之间的脱节,体现为“结构层的信息压缩”;其次,通过将ADMM^[115,122-123]等求解器迭代步骤展开为网络结构,不仅复刻了物理建模中的优化路径,还在输出端引入了动态的物理收敛机制,形成推理路径的信息约束;此外,部分方法通过引入可微仿真器或结构反馈机制,实现参数、结构与行为三者之间的物理一致性闭环。在贝叶斯视角下,该约束等价于对后验方差的显式缩减。

从整体上看,PEIN方法构建了贯穿结构-推理-输出的中层信息调控框架,不再依赖大量高熵输入或输出端的后验校正,而是以内嵌结构引导网络内的特征演化与信息流动路径。PEIN方法的本质是一种基于结构物理性的归纳偏差引入策略,能够有效弥合神经网络的强表达能力与成像任务中物理建模的可靠性之间的张力。综上,PEIN法作为一种以结构嵌入为路径、物理建模为基础、端到端推理为目标的融合范式,显著提升了模型在弱监督条件下的训练稳定性与物理可解释性,并为高复杂成像系统中的泛化建模、优化控制与跨域迁移提供了统一的理论支撑与方法框架。未来,结合可微分仿真、元学习与神经渲染等技术,PEIN法有望发展为集物理约束、结构优化与学习表达于一体的下一代深度成像推理模型。

4.3 目标层约束:物理一致性约束

随着现代定量相位成像系统向多模态、高分辨、实时化方向迅速演进,成像链路中的光学元件数量激增,系统标定、机械漂移、环境扰动等因素导致的非理想效

应呈指数级放大。与此同时,获取与真实生物或工业场景严格对应的高质量相位标签受限于设备仪器、样品制备的批次差异、动态过程的不可重复性等,使得真值标注成本高昂、周期较长。传统依赖大规模配对数据的监督学习范式在数据获取、存储、标注等环节均遇到瓶颈。为突破这些瓶颈,研究者提出物理一致性约束(PRL)法,其核心思想是将波动光学、衍射传播等第一性物理规律显式嵌入深度网络的学习目标:一方面,通过构造可微的物理前向算子与可导的损失函数,将网络输出映射回测量空间,计算与实测强度或相位差的物理一致性误差;另一方面,利用无标签光强图构建自洽的“伪监督”信号,例如将网络预测的复振幅再次传播到探测器平面,要求重投影强度与原始测量结果一致,形成无真值情况下的闭环约束。得益于物理规律的数学可微性,PRL法的框架可在端到端训练中实现梯度反向传播,实时校正网络权重,从而在无标签或弱标签条件下仍能维持稳定收敛,并输出具有明确物理意义的复振幅场。

从物理监督信号的构建方式与网络学习策略出发,当前研究工作大致可分为两类。一类为结构优化导向的“无监督法”,该方法通过最小化网络预测相位经物理传播后的估算结果与实际测量结果之间的误差,侧重于通过传播一致性约束来优化网络结构(此过程中,“传播”指的是物理模型中的角谱传播过程,而非神经网络的前向传播)。另一类为可训练网络导向的“自监督法”,通过正向传播-反向闭环一致性构建伪监督信号,该方法适用于跨样本模型训练与工程部署。两类方法在目标函数构建与训练流程上虽有差异,但均依托物理一致性驱动机制,构成当前PRL体系的两种主要实现范式。无监督法通常构建如下损失函数形式: $\mathcal{L}_{\text{un sup}} = \mathcal{L}_{\text{prior}}(\hat{\phi}) + \lambda \cdot \mathcal{L}_{\text{phys}}[\mathcal{P}(\hat{\phi}), I_{\text{meas}}]$,其中: $\mathcal{L}_{\text{prior}}(\hat{\phi})$ 为正则项,用于引入先验先导的结构约束; $\mathcal{L}_{\text{phys}}$ 则依据成像物理模型 $\mathcal{P}(\hat{\phi})$ 构建传播残差损失,与实测图像 I_{meas} 进行匹配,从而提升输出结果的物理一致性。而自监督法通常是基于损失函数 $\mathcal{L}_{\text{self}} = \mathcal{L}_{\text{phys}}[\mathcal{P}(\hat{\phi}), I_{\text{meas}}] + \alpha \cdot \mathcal{L}_{\text{cycle}}(\hat{\phi}, \hat{\phi}_{\text{cycle}})$,其中: $\mathcal{L}_{\text{phys}}$ 表示网络输出经传播后的重建图像与实测图像 I_{meas} 之间的误差; $\mathcal{L}_{\text{cycle}}$ 则引入闭环一致性损失,约束网络输出在反传播或再输入网络后生成的结果 $\hat{\phi}_{\text{cycle}}$ 与原预测相位保持一致。相较之下,无监督路径适用于标签完全缺失、样本物理结构明确的场景;而自监督路径适合具备多帧或多模态采集能力的系统实现。二者在机制与应用上各具特色,构成了当前PRL体系中最具代表的融合范式。

4.3.1 无监督传播残差损失

无监督法的发展经历了从结构先验建模到强物理

机制引入的递进过程。2018年,Boominathan等^[124]提出cDIP(conditional Deep Image Prior)方法,首次将深度图像先验(DIP)^[125]框架引入相位成像任务,通过最小化网络输出与物理传播结果之间的差异,在无需外部训练样本的情况下实现复振幅重建,这奠定了物理一致性约束学习的雏形。如图14所示,2020年,Bostan等^[58]在此基础上提出Deep Phase Decoder(DPD)方法,进一步引入泽尼克像差建模策略,实现了复振幅与系统误差的联合重建,验证了结构先验在物理一致性驱动下可作为“隐式正则项”指导网络训练。同年,Wang等^[60]提出PhysenNet,通过将网络预测的相位输入物理传播模型,并与实测光强图进行残差计算,有效增强了对系统误差的适应能力,推动了从结构主导向物理主导的范式转变。随后,研究者开始探索多模态融合与传播建模的协同机制。2021年,Niknam等^[59]在DPD框架中引入频域先验与空间残差联合优化策略,提升了对高频信息重建能力,并抑制了孪生像伪影。

2022年,Zhang等^[126]提出BlindNet框架,在系统参数未知的前提下,联合传播误差与图像正则项实现鲁棒的复场重建。2022年,Li等^[57]则在YNet框架中融合两种传播距离下的光强图,通过双路径传播残差提升网络的训练稳定性。同年,Zhu等^[127]提出Diffractive Neural Field(DNF)法,创新性地引入相干照明下的定量相位建模任务。该方法以空间坐标作为神经网络输入,同时回归振幅、相位与离焦参数,并通过传播一致性构建物理约束,有效提升了模型的自标定能力与在多域成像任务中的泛化性能。同期,Li等^[128]将物理衍射模型嵌入常规的DNN,将低频离轴全息相位解调转化为单帧、无伪影的非线性优化过程,实现高通量数字全息的高保真相位重建。此外,Chen等^[130]将该思想进一步拓展至傅里叶叠层显微系统,提出了基于无训练CNN的多角度传播残差优化框架,在无标签条件下实现了大视场、高分辨率复振幅的有效恢复,显著拓展了PRL法的应用边界。2024年,Jin等^[129]提出NFTPM方法,将神经场表示与部分相干照明下的完整正向成像模型相结合,构建了从空间坐标到相位的隐式映射关系,并以传播误差作为损失函数驱动网络迭代,从而在复杂成像条件下实现了高精度的相位重建及离焦距离的同步预测。总体来看,无监督法通过将物理传播模型嵌入目标函数,在无标签条件下实现了物理一致性引导下的复场重建,具有不依赖训练数据、系统先验适应性强等优势,适用于系统参数未知或难以标注的任务场景。该方法采用单样本迭代优化学习网络参数,但由于优化过程仅针对单一样本,模型泛化能力有限,因此该方法难以适应其他样本或成像场景。同时,其推理效率受限,这进一步制约了其在高通量和实时成像等实际应用中的推广潜力。

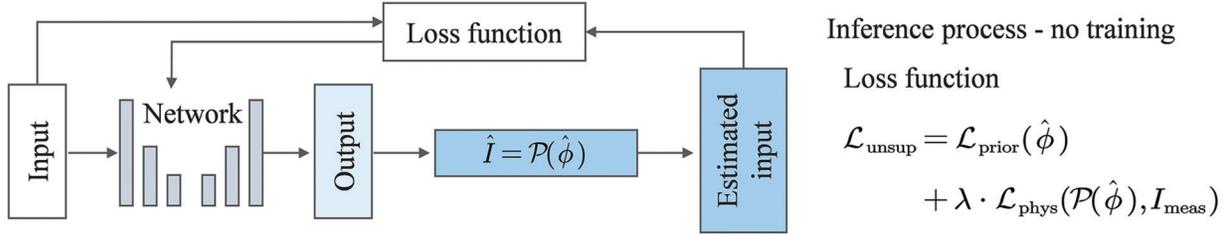
4.3.2 自监督伪标签闭环

相较之下,自监督法则更强调通过构建“网络预测-物理传播-实测图像”的伪监督路径,实现对网络输出结果的反馈调节。如图15所示,2023年,Chen等^[61]提出DIP-QDPC(Deep Image Prior Quantitative Differential Phase Contrast)方法,首次将DIP与DPC物理层相耦合,基于弱物体近似下的线性物理模型提供物理引导,实现了无需相位真值的自监督、免调参、部分相干照明定量相位恢复。同年,Huang等^[56]在*Nature Machine Intelligence*发表的研究系统验证了传播一致性约束在提升复场重建稳定性和抑制伪影方面的关键作用,从而确立了传播路径物理反馈在自监督机制中的核心地位。2024年,Rogalski等^[131]通过分别构建用于振幅与相位处理的双通道CNN子网络,实现对复场中孪生像成分的有效抑制,并在重建流程中引入一次GS迭代以更新光场幅度,确保结果与输入全息图的一致性,从而增强网络输出的物理可信度与可靠性。2025年,Dou等^[132]提出基于复值神经网络的自监督方法,在无标签条件下实现单帧全息图的高鲁棒复场重建,并有效抑制了双共轭伪影与高频损失问题。总体而言,自监督法通过构建传播残差反馈路径,以实测图像作为物理一致性监督信号,有效缓解了标签缺失问题,并在非干涉、部分相干照明等复杂成像条件下实现较高的重建精度与较好的系统适应性,具备较强的物理解释性与泛化能力。该方法的优势在于在保留神经网络表达能力的同时引入物理约束,适用于无法获得真实标签但可进行物理建模的成像任务。然而,自监督法对传播模型的准确性与网络输出的初始质量较为敏感,且在构建损失函数时需要合理平衡物理残差与图像特征之间的权重,仍存在稳定性调优与工程部署方面的挑战。

4.3.3 小结

在病态反演问题中,观测信息不足往往导致预测结果存在较高的不确定性与多解性,其统计特征可通过输出信息熵加以量化。该不确定性不仅降低了重建结果的稳定性与鲁棒性,还使模型易受噪声、系统非理想因素及跨域分布变化的影响而失效。针对该问题,PRL法通过在训练目标中引入基于成像物理规律构建的损失项,以低熵物理一致性信号替代真实标签,从输出端直接施加物理约束,从而压缩解空间、降低信息熵,并缓解由多解性引发的不稳定性。PRL法的核心思想是利用光场传播方程等物理先验构建物理残差,将其作为优化目标的一部分参与学习。一方面,物理损失函数在前向传播中限制解的漂移与冗余,直接约束预测结果的物理合理性;另一方面,这些物理残差在反向传播中提供梯度信号,引导特征提取逐步向符合成像物理规律的方向收敛,从而构建出一种基于物理一致性驱动的自监督机制,实现无标签或弱标签条件下的稳定学习与动态适应。与依赖结构嵌入的PEIN

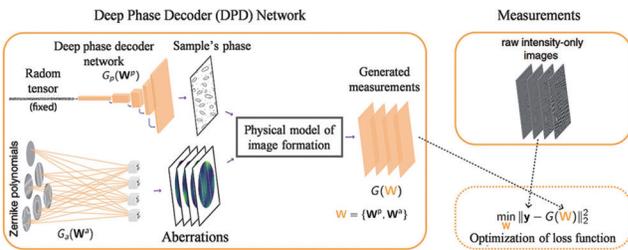
(a) Schematic diagram of training process / inference process



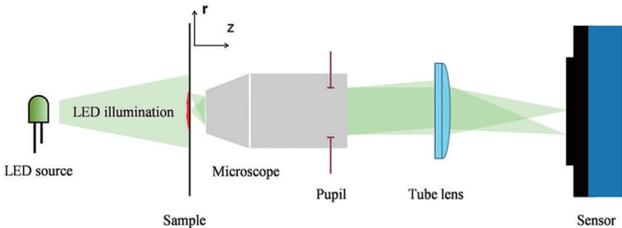
Method	PRL: Unsupervised propagation residual loss				
Definition	Propagation-model converts predicted phase to intensity loss from its residual with measured data guides network optimization				
Category	Input	Output	Task type	Advantages	Limitations
Content	Intensity Diffraction Hologram	Phase	Unsupervised learning	Strong physical interpretability, no phase truth required	Slow convergence speed

(b) DPD

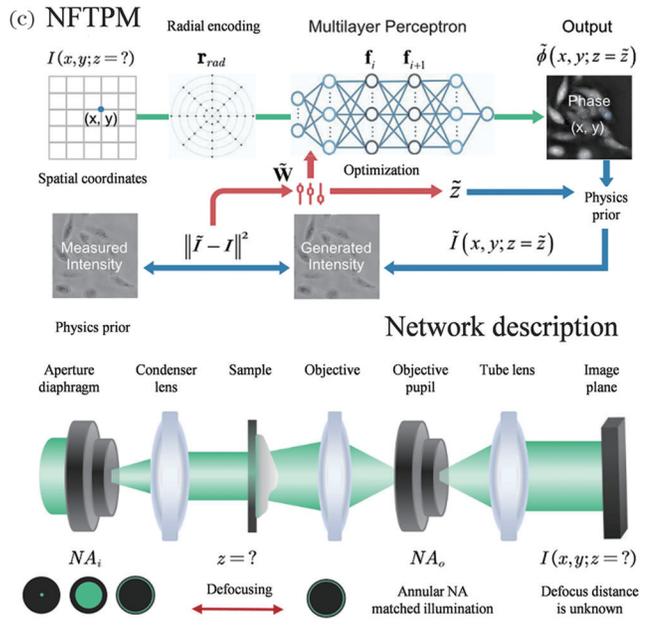
Network description



Imaging system



(c) NFTPM



Methods	Input	Training data	Training time	Inferential efficiency
DPD	Single frame defocus intensity	No training required	No training required	Minute level
NFTPM	Single frame defocus intensity	No training required	No training required	Minute level

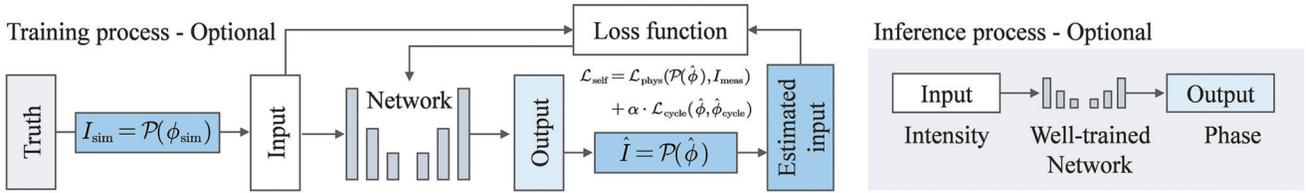
图 14 PRL 代表方法: 基于无监督传播残差损失的定量相位成像的代表性方法。(a) 训练/推理过程示意图及方法小结; (b) 基于 DPD 的方法^[58]; (c) 基于 NFTPM (Neural-Field-Assisted Transport-of-Intensity Phase Microscopy) 的方法^[129]

Fig. 14 PRL representative methods: representative methods of QPI based on unsupervised propagation residual loss. (a) Schematic diagram of training/inference process and method summary; (b) DPD based method^[58]; (c) NFTPM based method^[129]

法不同, PRL 法无需改动网络架构, 而是通过物理损失项建立可泛化的低熵监督通道, 因而在兼容性与扩展性方面具有优势。实践表明, PRL 法不仅能在低信噪比条件下提升重建稳定性, 还能减少对特定域特征的过拟合依赖, 使其在不同样本类型、成像条件或系统

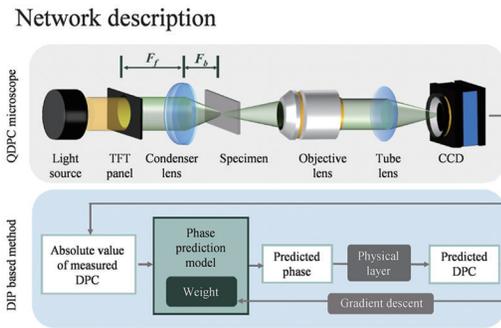
参数变化的跨域场景中保持较高的泛化性能。同时, 低熵预测结果在统计特性上更接近真实物理场, 从而增强了物理可解释性。综上, PRL 构建了以物理模型为核心的输出信息压缩链条, 其本质是一种基于物理残差引导的无需标签学习机制, 不仅确保物理一致性,

(a) Schematic diagram of training process / inference process

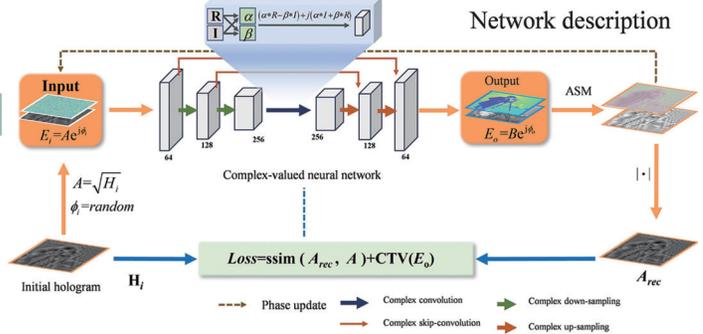


Method	PRL: Self supervised pseudo label closed loop				
Definition	The network's intermediate output is propagated forward to generate intensity, compared with actual measurements, and used to build a pseudo-label feedback mechanism				
Category	Input	Output	Task type	Advantages	Limitations
Content	Intensity Diffraction Hologram	Phase	Unsupervised learning	Strong physical interpretability No phase truth required	Slow convergence speed

(b) DIP



(c) CVNN



Methods	Input	Training data	Training time	Inferential efficiency
DIP	Four frame QDPC intensity images	No training required	No training required	Minute level
CVNN	Single frame hologram	No training required	No training required	Minute level

图 15 PRL 代表方法: 基于自监督伪标签闭环的定量相位成像的代表性方法。(a) 训练/推理过程示意图及方法小结; (b) 基于 DIP 的方法^[61]; (c) 基于 CVNN 的方法^[132]

Fig. 15 PRL representative methods: representative methods of QPI based on self supervised pseudo label closed loop. (a) Schematic diagram of training/inference process and method summary; (b) DIP based method^[61]; (c) CVNN based method^[132]

还兼顾泛化能力、可解释性与系统适应性, 为构建高可信度物理驱动深度学习模型提供了基础。

5 三类范式对比: 性能雷达与适用场景

为系统评估各类方法的适用性与性能特征, 本文从物理嵌入层级、信息调控机制、监督策略、模型泛化能力及实现复杂度等维度对三类典型方法进行了量化对比, 并结合信息论视角揭示其本质差异与互补特性。现有 PD-DL 方法主要分为三类, 即 PASL 法、PEIN 法和 PRL 法。这三类方法分别在数据构造、网络结构与损失函数等不同环节引入物理建模机制, 构建了贯穿输入、结构到输出的完整信息调控链条。在这一链条中, PASL 法侧重利用高一致性训练数据提升模型感

知能力, 物理过程嵌入网络法强调在特征建模过程中深度融合成像物理, 物理一致性约束法则通过输出端的物理反馈保障结果的自治性。三者既各具优势, 又在融合策略与性能侧重上体现出互补关系, 共同推动了物理建模与深度学习在定量相位成像领域的协同发展。

从信息调控路径出发, 物理驱动深度学习法在定量相位成像中的典型形式可归纳为三类, 分别是 PASL^[39,96,133-134]、PEIN^[118-119,135] 与 PRL^[58,60,128] 法。如表 1 所示, 三类方法分别在输入端、结构体、输出端引入物理建模机制, 构成了一条由物理规律主导的信息压缩与建模链条, 在融合方式、信息流调控策略以及对监督信号的依赖程度等方面各具特征。

表 1 三类物理驱动深度学习方法的比较
Table 1 Comparison of three types of physics-driven deep learning methods

Evaluation dimension	Physics-assisted supervised Learning, PASL	Physics-embedded inference networks, PEIN	Physics-regularized Learning, PRL
Physical model embedding location	<p>Input / data structure</p>	<p>Network structure / optimization path</p>	<p>Optimized end / loss function</p>
Information regulation mechanism	Physical sample enhancement (Enhance input mutual information)	Intermediate structure compression (Information bottleneck modeling)	Constrained physical feedback (Consistent projection)
Supervision mechanism	Supervised learning	Supervised / semi-supervised / unsupervised	Unsupervised / self supervised
Label dependency	Medium high (Simulate or approximate label)	Medium (Few labels)	Low (Completely unlabeled)
Physical consistency	Weak (Dependent on input rationality)	Medium strong (Structure explicit fusion)	Strong (Output strictly physically consistent)
Model interpretability	Medium (Training controlled)	High (Structural physical semantics)	High (Output can be physically verified)
Generalization ability	Medium (Affected by domain gap)	Medium high (Good structural mobility)	High (Strong system adaptability)
Inferential efficiency	High (Network forward fast)	Medium (Time consuming to embed module)	Medium (Low efficiency of iteration)
Feasibility	High (General structure)	Low (Module needs to be customized)	Medium (Need analytic physical model)
Applicable scenarios	<ol style="list-style-type: none"> 1. Stable system structure 2. Lack of labels 3. Controllable modeling accuracy 4. High reasoning efficiency 	<ol style="list-style-type: none"> 1. Clear communication path 2. Fewer labels 3. Imaging mechanism is analyzable 4. Low inferential efficiency need 	<ol style="list-style-type: none"> 1. System non idealization 2. Labels are difficult to obtain 3. Imaging mechanism is analyzable 4. Low inferential efficiency need
Performance radar chart			

在物理嵌入位置与信息调控机制上, PASL法主要通过物理建模生成的仿真样本或伪标签增大训练数据的互信息密度, 从而在输入端提供高结构性先验, 提升网络对成像物理的感知能力^[136]。PEIN法则在网络

结构中引入传播模型或优化迭代流程, 实现在中间特征空间的信息压缩与物理约束, 相当于构建了由结构主导的信息瓶颈机制, 强化了网络对物理过程的动态建模能力^[99, 137]。PRL法则不依赖标签和结构注入, 而

是在输出端引入基于成像物理模型构建的物理一致性项,通过最小化物理残差,在无监督或自监督的情形下约束与调节输出熵,实现预测的物理自治^[137]。

在监督机制与标签依赖性方面,三类方法体现出明显的层次结构: PASL法通常依赖仿真生成的高质量标签或近似标签作为监督目标,虽可缓解真实标签获取困难的问题,但依然存在一定的标签构建成本,标签依赖性偏高; PEIN法具备较强的结构自监督能力,可在极少标签或仅有初始估计引导的条件下完成端到端训练,标签依赖性适中,适合数据量受限的成像任务; PRL法则几乎完全摆脱了对标签的依赖,通过传播残差、物理残差等损失函数构建自监督反馈回路,训练信号由物理规律直接生成。更有甚者,部分PRL策略甚至无需预训练(如NFTPM^[129]与DPD^[58]等方法),仅依托输入进行逐样本优化,从而在部署阶段实现无须依赖特定模型参数的高灵活推理,并具备对不同样本与成像条件的广泛适配性。

在物理一致性与模型可解释性方面: PEIN法由于嵌入了传播结构或优化迭代,其中间特征具备明确的光学语义,模型行为具有较强可解释性与中强一致性保障^[99]; PRL法则通过输出端施加物理一致性约束,对预测结果进行显式物理筛选与反馈校正,能够在不依赖结构建模的前提下实现预测结果的物理验证,这是实现推理-物理-反馈闭环路径的重要方案^[137]。相比之下, PASL法虽可提升训练数据的物理一致性,但其物理先验并不直接参与推理过程,模型中缺乏真实反馈路径,导致其可解释性与物理一致性均相对有限。在泛化能力与系统适应性方面, PRL法因其不依赖标签与结构设计,物理模型可直接适配不同系统参数与采集模式,具备最强的任务迁移能力,适用于复杂系统、跨域成像或真实标签不可得的场景^[137]。PEIN法依托模块结构,在传播关系明确、系统建模稳定的条件下的泛化性较好。PASL法受限于训练-测试域的一致性,易受到域间差异的影响,其泛化性能对仿真建模质量高度敏感^[138]。在推理效率与实现复杂度方面,三者也表现出显著差异。PASL的结构最简单,通过前向传播即得结果,适合具有高效率需求的成像场景; PEIN因包含传播或优化模块,网络结构复杂、推理效率适中; PRL虽无需预训练模型,但通常需要在推理阶段执行基于物理残差的迭代优化,适合于对成像效率需求低但系统差异大或数据量极少的场景部署。

通过上述分析可见三类物理驱动深度学习方法在信息调控机制、监督策略、结构建模与推理范式等方面各具特点,能够适配于不同复杂度与物理先验条件的定量相位成像任务。PASL法依赖高质量仿真样本,提升训练数据的物理一致性与表达能力,适用于系统结构稳定、建模精度可控的成像场景,如明场单帧成像任务。PEIN法通过将传播模型或优化算法模块融入网络结构,在中间特征空间内实现物理规律的

显式表达,适用于传播路径明确、成像机制可解析的问题,如TIE反演、多帧测量或ADMM结构展开。PRL法则不依赖标签或特定网络结构,通过构建基于成像物理的输出残差损失,在无监督或自监督条件下实现物理一致性引导下的泛化推理,适用于系统非理想化、标签难以获取的复杂场景,如相位调制、非均匀照明或傅里叶域成像系统。这三类方法分别作用于“输入增强-结构建模-输出约束”三个注入层级,构成了具有分层协同特征的PD-DL方法体系。表1从物理嵌入位置、信息调控路径、监督方式与系统适应性等维度对三类方法进行了量化比较,揭示了其在成像系统复杂性、标签可用性与物理解释性方面的适配差异。

值得注意的是,近年来研究工作已逐步展现出三类范式融合的趋势。在具体任务实现中,研究者越来越倾向于将仿真数据构造、结构与物理残差反馈协同集成,以提升模型的整体稳定性、物理一致性与跨域适应能力。例如: HIONet^[120]在结构层面采用PEIN范式对物理反演过程进行优化展开,并在目标函数中引入PRL类传播残差以强化物理约束; FPNN^[104]则在训练数据生成阶段引入角谱传播与复振幅估计,不仅用于输入构造,也作为中间特征嵌入网络,形成了“物理变量注入+结构耦合”的复合机制。这类跨范式融合策略有效缓解了单一路径建模的适应性局限,为模型在实际系统中的部署与推广提供了更强的工程支撑。与此同时,随着神经渲染、可微光学建模与隐式神经表示等新兴建模技术的发展,PD-DL法正逐步由“功能模块组合”向“统一建模机制”演进。以神经场(NF)类方法为代表,研究者尝试通过隐式神经网络建立空间坐标与物理场(如振幅、相位、深度)之间的连续映射关系,并结合可微传播模型实现端到端的无标签反演。如NFTPM^[129]与DNF^[127]等方法初步验证了此类建模框架在复杂传播条件下的适应性及跨域泛化能力。从理论视角出发,三类机制融合后可分别作用于神经网络的输入表示域、结构搜索空间与优化收敛路径,构建贯穿学习全流程的多层次物理一致性约束体系。在数据层面,物理建模生成的训练样本或中间特征有助于限定输入分布,提高监督信号质量;在结构层面,嵌入传播模型或物理模块可增强网络归纳偏差的能力与系统适应性;在目标层面,引入传播残差或成像方程作为损失项有助于优化路径向物理可行解空间收敛,提升训练稳定性与结果可信度。

综上所述, PASL法、PEIN法与PRL法正逐步由分立演进走向深度融合,其建模范式已从早期的分层嵌入扩展为面向统一目标的协同优化。面向未来, PD-DL方法的发展趋势应聚焦于构建多路径融合与统一物理调控框架,整合三类范式的互补优势: 结合PASL法的仿真支撑能力、PEIN法的结构建模能力与

PRL法的物理约束能力,推动从数据生成、网络设计到目标优化的端到端闭环体系构建。该融合路径不仅有望进一步提升模型的泛化能力、物理解释性与部署灵活性,也将为构建具备跨模态、自适应、高精度能力的下一代智能成像系统提供方法论支撑与理论基础。

为进一步印证上述融合路径的实际价值,本文补充两类具有代表性的应用示例。其一是生物医学领域的无试剂血液学与病原快速检测。基于QPI与深度学习的成像血液分析仪已在真实样本上实现对白细胞及其亚群的准确分型,体现出无标记、高通量、易部署的优势;同时,结合三维折射率成像与卷积网络的研究在细菌种属判别中达到99.9%的准确率,并有工作将时序干涉成像与深度网络结合,将大肠菌群检测与物种判定的总用时压缩至约12 h,显示出PD-DL QPI在临床快速筛查中的效率潜力^[51]。其二是工业检测领域的在线颗粒/缺陷监测与过程质控。Lucendi(Aqusens)已实现液体中微小颗粒的现场自动监测,这体现定量相位测量在复杂工况下的适配性;Spheryx的全息特性表征方案面向半导体筛检与水质检测,展现出明确的产业化路径^[139]。此外,深度学习亦可承担降噪与分辨率提升等改进任务^[140-141],其处理时延较传统方法有明显的减少,为产线级在线重建与异常告警提供工程基础。上述两类案例与本文提出的PASL-PEIN-PRL协同思路相契合:通过仿真数据扩展训练分布、在网络中嵌入传播/成像算子以及以物理一致性构造目标,可将“数据生成-网络设计-目标优化”的闭环真正落地于生物医学与工业检测场景,进而推动PD-DL的推广与应用。

6 挑战、趋势与展望

为系统解析这些瓶颈并指明未来发展路径,本文围绕建模维度(高维表示与复杂传播机制)、数据效率(伪标签策略与数字孪生)、系统落地(推理性能与临床适配)以及技术演进趋势(范式跃迁与系统架构)4个方面展开分析,力图为PD-DL在QPI中的可持续演进提供理论支撑与方法启发。

6.1 当前挑战:从方法突破走向系统泛化的关键瓶颈

随着物理驱动深度学习方法在定量相位成像中的广泛应用,其研究重心正逐步从二维图像反演拓展至系统建模与智能化优化。然而,面对真实应用中样本结构复杂、训练数据稀缺、系统参数变化多样等问题,现有方法体系仍面临以下多维度挑战。

6.1.1 高维建模挑战:三维重建中的复杂物理与结构表征难题

随着成像需求从二维面内相位反演逐步迈向三维体积复场恢复,PD-DL方法在高维建模任务中的表达能力正面临新的考验。尽管近年来涌现出的一系列方法尝试将隐式神经表示、多散射调控机制与矢

量传播正则等引入到三维重建中,但在处理真实厚样本场景时,现有方法体系仍暴露出以下三方面突出问题:1)物理建模复杂度高。现有模型难以覆盖复杂传播机制。三维成像过程常涉及多层结构、多散射路径、边界反射与相干干涉等复杂传播机制,远超传统线性模型的适用范围。尤其在不具备精确标签的弱监督或无监督训练条件下,网络需要在欠约束场景中恢复高维折射率分布,其对物理一致性与表达精度的双重要求显著增加,导致模型训练易陷入局部最优或收敛失败。2)结构表达与推理效率难以兼顾,连续建模存在优化瓶颈。以隐式神经场为代表的连续建模方法虽具备高空间分辨率和光滑表达能力,但其在三维空间下的参数冗余度高,训练与推理计算开销大,且对网络初始化与监督信号敏感,这制约了其在复杂生物样本中的稳定应用。3)缺乏统一可推广的高维神经结构体系。当前三维PD-DL方法多针对特定任务或系统进行定制设计,缺少通用性的建模框架与结构体系,难以适应不同厚度、散射特性和系统参数下的任务迁移与性能对比。整体上,三维建模能力尚未形成范式性突破,仍处于方法分散、架构零散的发展阶段。

6.1.2 数据效率挑战:弱标签、强先验与物理一致性三重矛盾

在实际QPI系统中,由于相位信息无法直接测量,获取高质量标签往往需要依赖复杂的干涉系统或多帧联合反演,数据获取成本高昂,难以支撑深度神经网络的高效训练。尽管近年来PD-DL方法已逐步引入伪标签生成、物理一致性正则与数字孪生辅助机制,以缓解标签依赖问题,但在“低标签-强建模”背景下仍面临以下三重矛盾:1)伪标签策略受限于模型近似精度与实验差异,真实适用性不足。通过显式物理模型生成“光强-相位”伪标签,虽可快速扩展训练集,但模型精度受限,且系统响应、成像噪声等因素在实际采集中不可忽视,模拟数据与实验数据之间存在明显的分布差异,导致训练效果在真实场景中难以维持。2)物理一致性损失设计仍不完善,网络优化易受扰动影响。弱监督与自监督方法多依赖传播残差、相位正则或能量守恒等物理量构造损失函数,以实现“无标签”的物理驱动学习。但在多模态、非理想采集环境下,物理约束之间可能存在矛盾或不兼容性,导致训练过程出现发散、不收敛或结果不唯一的问题,限制了模型鲁棒性与可控性。3)数字孪生平台发展尚不成熟,难以支撑系统级建模任务。尽管已有研究尝试构建可学习物理参数或模拟系统配置的虚拟副本,实现离焦像差校正与系统参数自适应建模,但现有数字孪生平台多停留在传播链路建模层面,尚未形成对光源稳定性、器件响应、环境干扰等多因素联动的系统级仿真机制,这制约了其在任务泛化与跨模态迁移中的实用价值。

6.1.3 工程部署挑战:推理效率、适配能力与系统稳定性的多重制约

随着 PD-DL 方法逐步从实验验证走向系统集成,其工程部署能力正成为制约其技术落地的关键因素之一。在追求高精度与强物理建模能力的同时,兼顾推理效率、系统适配性与结果可解释性,成为当前 QPI 方法面临的重要现实挑战:1)高性能模型计算成本高,难以支撑高通量应用需求。多数 PD-DL 方法采用多通道输入、大深度网络与传播模拟模块,模型结构复杂、运算资源消耗大,难以在实时成像或资源受限设备中部署,这阻碍了其在临床诊断、活体成像等高吞吐场景下的推广应用。2)模型对场景变化的适应性弱,泛化能力仍待加强。生物医学样本往往具有结构复杂、信噪比低、物性差异大的特点,在跨系统、跨样本部署时,模型容易出现泛化失效或重建失真的问题。当前多数方法缺乏任务感知或系统自适应机制,仍依赖固

定网络结构与训练分布匹配,限制了其实际适配能力。3)可解释机制缺失,难以满足临床高可信应用需求。在高风险医学场景中,模型不仅需要生成高精度的重建结果,还必须具备可追溯性与物理可解释性,以确保诊断结论的可信度与可验证性。目前,尽管部分 PD-DL 方法已在网络结构中引入传播模型或物理残差等机制,但尚未构建起结构、物理机理与功能目标相统一的系统化可解释框架,因而在临床验证、医疗审查及工程安全等关键环节中仍存在应用局限。

6.2 发展趋势:通向泛化建模与智能系统的演进路径

针对当前物理驱动深度学习在定量相位成像中所面临的建模、数据与部署挑战,研究范式正逐步从二维反演算法拓展至高维建模、系统自适应与工程集成三大方向,旨在构建更具通用性、高效率与可解释性的成像系统。基于物理驱动深度学习的定量相位成像面向未来发展的挑战与趋势如图 16 所示。

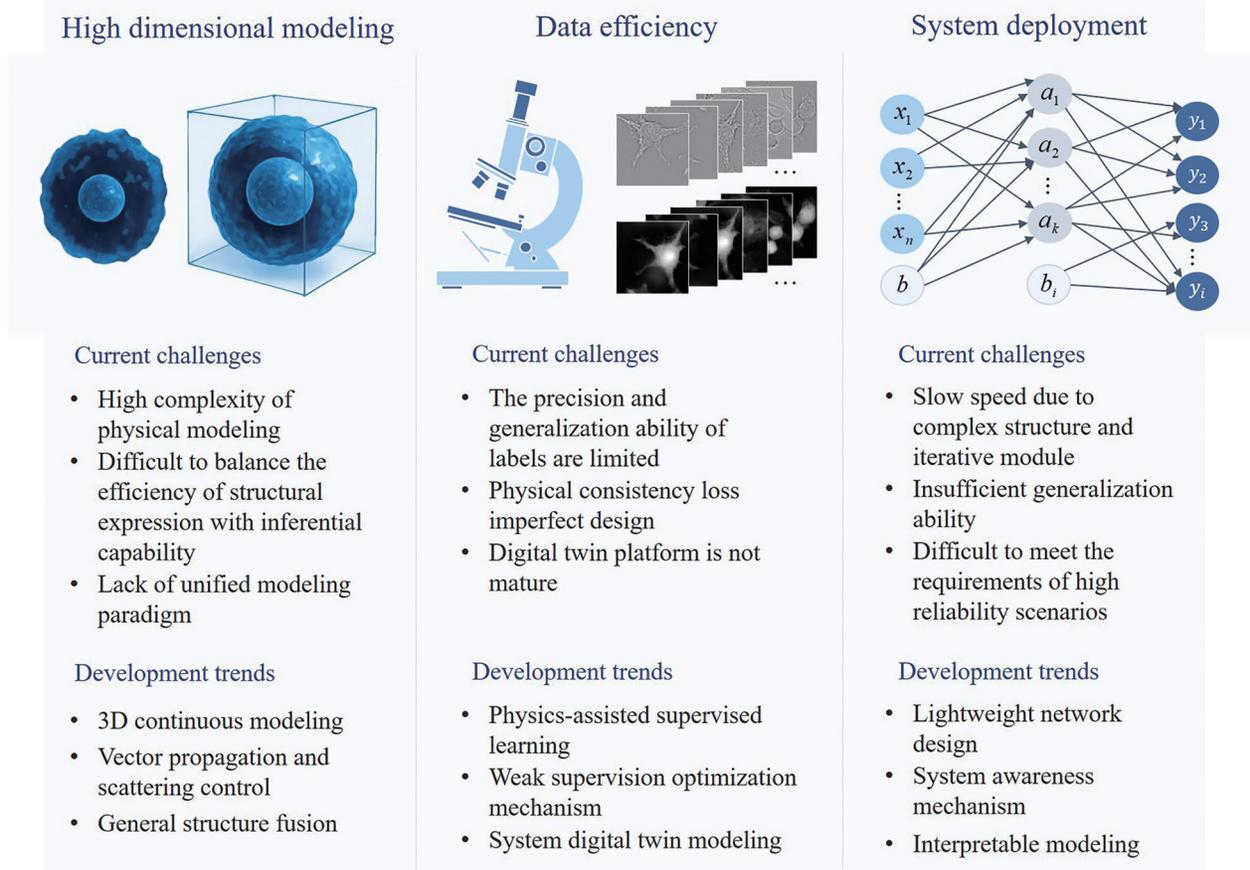


图 16 基于物理驱动深度学习的定量相位成像面向未来发展的挑战与趋势对照

Fig. 16 Challenges and trends of future development in QPI based on physics-driven deep learning

6.2.1 建模维度:向高精度三维成像与矢量传播机制拓展

随着生物组织结构复杂性与观测深度需求的不断提升,定量相位成像逐步从二维面内重建向三维体积建模扩展。在该过程中,传统基于物理模型的三维复场恢复方法,如光学衍射层析(ODT)^[142-144]与强度衍射层析(IDT)^[145-147],虽然在一定程度上解决了厚样本成

像问题,但仍面临弱散射近似失效、重建过程复杂、采集条件苛刻等诸多挑战。尤其在真实样本中多散射、折射率梯度与噪声扰动普遍存在,传统反演算法难以兼顾建模精度与计算效率。在此背景下,物理驱动深度学习方法为三维成像提供了新的突破路径。相比依赖精确建模的传统算法,PD-DL 通过引入传播物理、系统结构与网络表达能力之间的融合机制,在提

升建模精度的同时显著增强了算法的自适应性与鲁棒性。

当前研究进展主要聚焦于以下几个方向。一是结构嵌入型建模方法的涌现。代表研究如Liu等^[148]提出的神经场重建框架,将三维折射率分布表示为隐式神经场,并引入Fresnel传播模型构建物理一致性损失,在弱监督条件下实现连续体重建。该方法实现了从“离散重建”向“连续建模”的范式跃迁,在表达精度与推理灵活性之间取得较好的平衡。二是散射感知的结构调制机制。如Tahir等^[149]提出的动态路径抑制网络,通过结构模块对多散射路径进行编码调控,虽然未显式引入传播模型,但是体现了对散射机制的先验建模。该思路有望拓展至更多的散射感知场景,如活体组织、光敏材料等复杂介质重建任务。三是传播正则化与全矢量建模策略的拓展。如Lim等^[150]提出的MaxwellNet方法引入三维麦克斯韦方程残差作为网络损失项,首次实现了无监督下的矢量电磁场建模,显著提升了边界处理能力与物理一致性,推动PRL范式在三维复杂场建模中的落地实践。

总体来看,为突破二维相位重建的表达瓶颈,PD-DL方法正加速迈向三维连续建模与复杂物理过程融合:构建基于隐式神经表示的体积折射率建模框架,实现由离散切片向连续场重建的方法跃迁;引入散射感知结构与矢量传播正则项,来应对多散射、多偏振、多界面等复杂光场行为;发展支持弱监督、无监督或自监督条件下稳定训练的三维传播损失机制,增强模型的边界表达与物理一致性。该方向有望实现PD-DL在厚样本、多模态成像任务中的性能突破,推动三维成像系统在生物组织成像等领域的实用化进程。

6.2.2 数据效率:数字孪生与弱监督训练

在定量相位成像中,训练标签稀缺、高质量数据获取成本高、仿真与实测存在域差异问题,严重制约了深度学习在复杂成像场景下的推广与落地。尤其在非干涉条件下,相位无法直接测量,这进一步加剧了数据不足与监督困难的矛盾。因此,如何在有限标签甚至无标签条件下保持模型性能、提升数据利用效率,已成为PD-DL方法亟待突破的关键挑战之一。

针对这一问题,物理驱动深度学习框架在数据效率层面主要展现出以下三类发展趋势:第一,基于物理建模的数据生成与辅助监督。该路径通过显式传播模型合成“光强-相位”伪标签样本,辅助神经网络训练,以缓解实验数据匮乏问题,其优势在于可控性强、生成速度快、适用于系统结构稳定场景,但其性能往往受限于模型近似精度与实验-模拟之间的域差异,难以直接迁移至复杂样本和真实系统。第二,引入物理一致性约束的弱监督训练策略。该类方法可在训练过程中引入传播残差、光场相容性等物理指标作为损失项,引导网络输出遵循成像物理规律,实现“无标签学习”。相

比完全监督训练,弱监督方法可显著降低对真实相位标签的依赖,具有更强的跨样本适应能力,尤其适用于在系统变化频繁或标注不可得的场景下。第三,构面向系统级建模的数字孪生体。数字孪生最初源于工业制造领域,旨在构建一个与物理实体高度一致的虚拟副本,实现对系统行为的建模、预测与优化^[151-153]。在基于物理驱动深度学习的定量相位成像中,该理念近年来被引入用于模拟复杂成像系统的结构配置、传播机制与非理想响应,并以此提升模型的适应能力与物理一致性。相比传统依赖静态传播模型的方式,数字孪生体更注重系统级建模与虚实耦合,强调模型的动态性、自更新能力以及与神经网络训练的深度融合。尽管“数字孪生”理念在QPI领域的应用尚处于起步阶段,其核心思想已在多项基于物理驱动深度学习的方法中初步体现。以Kellman等^[45]所提出的研究为例,通过将非线性相位重建算法结构化展开并融合物理模型,构建了面向任务的端到端学习框架。该方法在仿真阶段以少量训练样本优化前端照明编码,在实验阶段实现了高度一致的重建性能,展现出典型的数字孪生特征,即融合“建模-优化-验证”闭环的系统设计范式,为QPI系统级数字建模提供了早期实践样本。该思想在PASL法与PRL法中均已体现,构成具备数字孪生雏形的实现路径。BlindNet^[126]、DNF^[127]、NFTPM^[129]等方法则通过显式引入可学习的物理参数,实现对离焦像差的自适应校正与物理一致性约束,初步具备了数字孪生体所强调的“物理建模-网络协同优化”机制,反映出数字孪生理念在QPI中的可行性与应用潜力。

针对真实样本标签缺失与数据获取成本高的问题,PD-DL研究正向融合物理建模与弱标签学习的“知识-数据双驱动”形式演进:基于物理传播模型的伪标签生成与辅助监督策略,可提升训练样本的一致性与可控性;发展多尺度、多帧融合的物理一致性约束机制,以传播残差、能量守恒等物理量替代显式标签驱动网络优化;构建面向系统级建模的数字孪生平台,实现对光源、器件、采集链路等物理过程的全流程建模与联合调优,提升模型在系统变化下的适应性与自更新能力。这一趋势将推动PD-DL方法从依赖数据转向生成数据,实现训练样本、物理机制与任务需求三者间的闭环协同^[154-155]。

6.2.3 系统落地:轻量化与生物医学适配

随着QPI在生物医学、药物筛选、病理分析等场景中的逐步应用,其实际部署能力日益成为衡量算法有效性的关键标准。相比精度、速度等模型内性能指标,“是否能落地”为系统设计提出了更为苛刻的约束。这一过程中,物理驱动深度学习如何兼顾推理效率、硬件适配与场景通用性,构成了当前QPI方法走向工程化、智能化的重要挑战。首先,当前定量相位成像领域亟须满足高效率、高通量系统构建的现实需求。传

统高精度QPI方法多依赖多帧图像采集与数值迭代算法,计算复杂度高、处理速度慢,难以满足大规模活体样本监测或临床实时筛查等场景对成像速率与系统吞吐的要求。为缓解该瓶颈,部分研究提出以全光学衍射QPI网络为核心的新型架构^[156-158],通过设计由多层被动衍射面构成的紧凑型系统,实现输入相位场到输出光强图的光学映射过程。该方法利用深度学习手段对衍射层进行空间编码,使得相位恢复过程在传播路径中以无透镜、无迭代的方式完成,从而显著降低了对传统数值重建的依赖,具备低功耗、高帧率与紧凑集成等优势。在深度网络方面,也逐渐涌现出结构紧凑、推理快速的轻量级PD-DL模型,这类模型结合单帧输入^[95,159-160]、明场重建^[96,161-162]等策略,为便携式、低功耗部署提供了路径可能。

此外,还存在对生物学场景的适配性问题。实际应用中的生物组织样本通常具有厚度大、折射率梯度大、信噪比低等特点,远超传统仿真模型的复杂性。此类样本下,常规数据驱动方法易出现泛化失效或重建不稳定的问题。PD-DL方法通过引入系统物理建模与成像先验,增强了对复杂结构与多散射现象的鲁棒性。例如,利用传播模型进行弱监督优化^[56,61]、构建传播一致性项^[58,129],有助于提升模型在不同样本条件下的适应能力。此外,生物样本对系统集成度与操作便捷性的要求也推动了PD-DL方法向低帧率、少通道、端到端架构发展。最后,工程实现中的可解释性与稳定性仍为关键瓶颈。在医疗诊断等高风险场景中,算法的物理合理性与可追溯性比单一指标更为重要。物理驱动深度学习方法由于保留了成像过程的结构性与物理约束,可为模型提供更强的稳定性与解释能力。

当前已有研究尝试将传播路径、残差图像或物理控制方程作为可视化通道,提升模型的临床可验证性^[163-165]。这类结构-物理-功能三位一体的融合策略,将在QPI技术走向临床落地过程中发挥越来越重要的作用。为实现PD-DL模型在实际QPI系统中的快速部署与稳定运行,研究正向轻量化、适配性与可解释性的融合设计方向推进:构建推理效率高、结构压缩性强的神经网络架构,结合单帧输入、明场重建等的策略满足边缘部署与高帧率要求;发展任务感知型网络结构与系统状态驱动的模式调参机制,以适应不同采集参数、样本特征与应用场景;引入物理解释通道与可视化机制,提升模型在临床、生物分析等高风险领域的可验证性与信任度。最终目标是实现PD-DL法从实验验证走向跨平台、跨任务的实用化智能成像系统。

6.3 未来展望:技术演进展望

基于PD-DL的定量相位成像方法正在经历从感知层到系统层的全面范式转型。如图17所示,综合当前文献进展,未来该领域的演进趋势可归纳为4维范式跃迁:从方法协同、知识驱动,到系统任务融合与架

构解耦,构成了构建智能化成像基础设施的关键路径。

其一,从“局部优化”走向“系统协同”:构建光学-算法-物理闭环联合优化体系。当前PD-DL方法多聚焦于图像反演层面的网络正则与训练机制,而在系统级层面仍缺乏闭环协同。面向高通量、复杂环境的成像任务,研究正逐步转向以可微光学层与物理建模单元为前端,以神经网络为后端的全链路优化模式。例如,HIONet^[120]将物理传播可微结构嵌入网络框架,有效缓解了部分相干照明下的重建不稳定性。未来,从前端光场调控到后端信息重建的端到端联合优化将成为构建鲁棒、高效、可解释成像系统的核心方向。

其二,从“数据驱动”迈向“知识-物理”双重驱动:发展可学习先验与物理可微求解器。面对标签获取难、高质量样本缺失、域间差异等现实挑战,QPI研究正逐步从大规模数据依赖,过渡到融合第一性物理规律与结构先验的知识驱动范式。例如,deep phase decoder^[58]将可学习像差参数融入学习过程,在非理想条件下实现高质量重建与自适应调节。未来将进一步引入神经微分方程^[166]、可微分物理引擎^[167]与任务自适应元学习^[168]机制,推动少样本、高不确定性条件下的贝叶斯最优泛化。

其三,从“相位重建”拓展至“智能感知”:构建物理引导的自监督闭环系统。下一代PD-DL QPI技术正建设长期动态结构建模能力,迈向感知-认知-决策融合系统。已有研究在QPI框架中,通过将光传播物理层整合进学习流程、借助deep image prior展开物理一致性的自监督优化,实现在无配对标签情况下的高精度相位重建,误差低于10%^[61]。未来,可将此方法与数字孪生平台结合,在“物理系统-模拟系统-推理任务”的循环中,通过“实时采集-仿真预测-自监督蒸馏”的方式实现活体样本的结构变化提示。该方式支撑毫秒级反馈机制,有望成为QPI系统实现动态连续观测与智能感知能力的范式基础。

其四,从“统一框架”演进为“解耦式模块化架构”:支持跨模态迁移与灵活部署。由于QPI系统在照明结构、传感路径与系统响应等方面存在显著异构性,传统依赖固定建模结构的PD-DL方法往往难以在不同系统间直接迁移。为应对这一挑战,未来方法将逐步趋向结构解耦与功能模块化设计,即通过分离物理建模模块、任务适配模块与噪声建模单元,实现灵活组合与可插拔式部署。在计算成像领域,已有研究引入领域自适应^[169]机制,通过对抗学习或统计对齐等手段显式引导模型对成像域间分布差异进行校准;同时,联邦学习^[170]策略也被广泛探索,用于实现分布式成像系统中的模型共享与隐私保护;此外,持续多任务学习^[171]方法则支持任务间的动态迁移与模型在线微调,有助于应对不断变化的应用需求。尽管上述策略目前主要

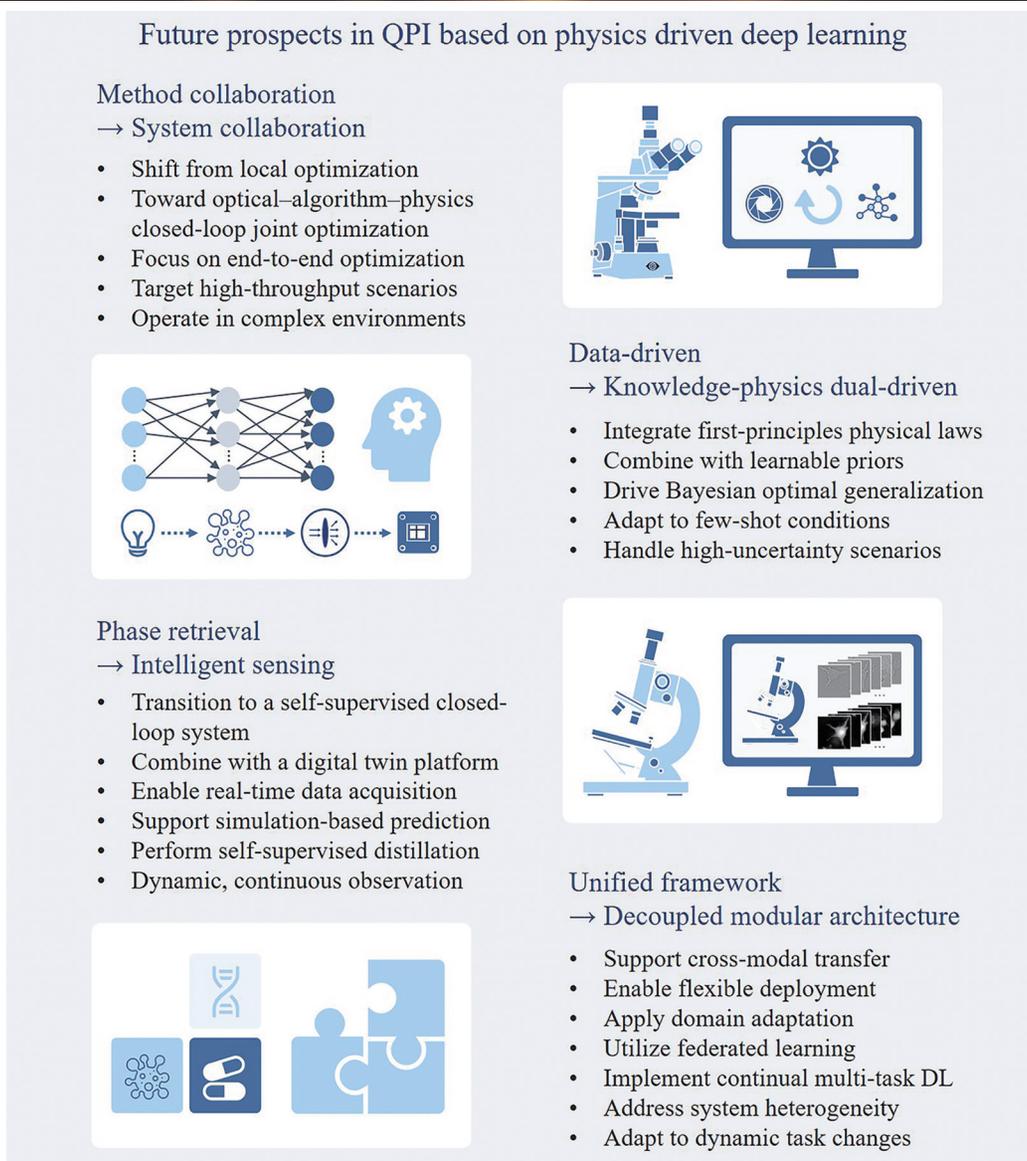


图 17 基于物理驱动深度学习的定量相位成像中的未来展望
Fig. 17 Future prospects in QPI based on physics-driven deep learning

应用于通用医学图像分析与多模态重建任务,在 QPI 领域的应用仍处于空白阶段,但其核心思想与机制对构建具备跨平台、低标签依赖与快速部署能力的下一代 PD-DL 系统具有重要借鉴意义,为其在临床诊断、工业检测等前沿场景中的广泛推广提供了方法学基础。

综上所述,下一代基于 PD-DL 的定量相位成像方法正从局部模块优化迈向系统级结构重构,呈现出以方法融合、知识驱动、任务耦合与架构解耦为核心的 4 维范式跃迁。该演进趋势不仅拓展了相位重建的理论边界,更为构建具备自适应能力、物理一致性与任务迁移性的智能成像系统提供了方法学基础。在数字病理、神经可视化与生物结构动态监测等前沿应用场景中,PD-DL 方法有望成为实现从传统成像工具向智能感知平台转型的关键技术支撑,加速测量系统的范式升级与跨领域融合。

7 结束语

随着成像系统结构日益复杂,观测任务向高维、多模态与实时化演进,QPI 方法正经历一场从“解析模型主导”向“智能学习融合”的范式革新。传统 QPI 方法多依赖物理可解释的传播模型与反演算法,虽具备良好的理论可控性与模型可解释性,但在面对动态条件下的系统变化、高通量采集需求及复杂组织结构时,其建模能力与适应边界逐渐暴露局限。与此同时,纯粹基于数据驱动的深度学习方法虽具有优越的非线性表达能力与推理效率,但往往忽略了成像物理约束与能量守恒等基本规律,导致模型难以推广至新场景、缺乏可解释性,甚至产生物理不一致的预测结果。物理驱动深度学习正是在此背景下应运而生,成为连接解析建模与深度学习之间的桥梁。PD-DL 方法通过在输入、结构与损失等关键环节嵌入物理先验,系统性地弥

合了成像模型精度与表达能力之间的矛盾,成为引领QPI向智能化、系统化方向演进的重要驱动力,其关键不仅在于“引入物理信息”,更在于实现物理建模方式与神经网络推理机制之间的深度耦合与功能协同。

为厘清PD-DL方法的技术发展格局与融合路径,本文从“物理注入层级”出发,构建了统一的分析范式,并将现有工作归纳为三类具有代表性的融合模式: PASL、PEIN与PRL。该分类不仅基于物理信息在网络流程中注入位置的差异,亦揭示了三类方法在建模深度、任务耦合强度与系统适应性方面的层次递进关系。其中: PASL通过仿真先验生成伪标签样本,提升监督信号质量,适用于标签稀缺与建模精度可控场景; PEIN强调传播机制与优化迭代的结构化嵌入,适配于传播模型具备解析表达或可微形式的问题; PRL则通过构造物理残差或正向一致性损失,在缺标签条件下实现输出结果的物理反馈调节,体现出极强的自监督与跨域泛化能力。本文提出的物理注入层级框架不仅弥补了以网络结构或任务类别为分类标准的局限,更在方法论层面建立了一种从数据端到目标端的物理建模协同视角,具备良好的通用性、拓展性与集成能力。该框架有望成为未来设计多模态融合系统、部署低监督学习模型及构建可解释深度网络的理论基础与逻辑工具。本文系统梳理了PD-DL方法在多个前沿方向的演进趋势,包括三维层析建模中的体积一致性强化、矢量场反演中的强散射建模、跨模态融合中的物理约束共享表示,以及系统部署中的数字孪生动态调节机制。特别是在资源受限或系统环境动态变化的条件下,PD-DL方法展现出在弱标签、低算力、高不确定性下保持稳定重建与跨场景适应的潜力。

展望未来,PD-DL方法的核心演进方向将围绕“可控生成-物理反演-推理优化”的闭环结构展开,实现从静态、离线训练向动态、自适应优化的转变。这一过程不仅要求网络具备强表达能力,更需要系统构建具备可解释性、可调控性与可演化性的智能机制,以支撑在真实场景中的长期运行与持续更新。综上,本文聚焦“定量相位成像范式革新”的核心主题,从范式演进视角出发,系统梳理了PD-DL方法的发展逻辑、融合机制与应用趋势,提出了具备系统性、逻辑性与可推广性的“物理注入层级”分类框架。希望本综述不仅为方法理解与技术选择提供明确参照,也能激发后续在高维建模、跨模态感知与工程落地中的创新思考,助力构建具备物理一致性、泛化鲁棒性与部署实用性的下一代QPI智能化系统。

参 考 文 献

- [1] Herzberger M. Optics from Euclid to Huygens[J]. Applied Optics, 1966, 5(9): 1383-1393.
- [2] Chang X Y, Bian L H, Zhang J. Large-scale phase retrieval[J]. eLight, 2021, 1(1): 4.
- [3] Mait J N, Euliss G W, Athale R A. Computational imaging[J]. Advances in Optics and Photonics, 2018, 10(2): 409-483.
- [4] Bhandari A, Kadambi A, Raskar R. Computational imaging[M]. Cambridge: The MIT Press, 2022.
- [5] Fan Y, Li J J, Lu L P, et al. Smart computational light microscopes (SCLMs) of smart computational imaging laboratory (SCILab)[J]. PhotonIX, 2021, 2(1): 19.
- [6] 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.
- [7] Zuo C, Feng S J, Zhang X Y, et al. Deep learning based computational imaging: status, challenges, and future[J]. Acta Optica Sinica, 2020, 40(1): 0111003.
- [8] Cuhe E, Bevilacqua F, Depeursinge C. Digital holography for quantitative phase-contrast imaging[J]. Optics Letters, 1999, 24(5): 291-293.
- [9] Zuo C, Li J J, Sun J S, et al. Transport of intensity equation: a tutorial[J]. Optics and Lasers in Engineering, 2020, 135: 106187.
- [10] Pittman T B, Shih Y H, Strekalov D V, et al. Optical imaging by means of two-photon quantum entanglement[J]. Physical Review A, 1995, 52(5): R3429-R3432.
- [11] Okamoto T, Yamaguchi I. Simultaneous acquisition of spectral image information[J]. Optics Letters, 1991, 16(16): 1277-1279.
- [12] Correa C V, Arguello H, Arce G R. Snapshot colored compressive spectral imager[J]. Journal of the Optical Society of America A, 2015, 32(10): 1754-1763.
- [13] Zuo C, Feng S J, Huang L, et al. Phase shifting algorithms for fringe projection profilometry: a review[J]. Optics and Lasers in Engineering, 2018, 109: 23-59.
- [14] Li J J, Chen Q, Sun J S, et al. Three-dimensional tomographic microscopy technique with multi-frequency combination with partially coherent illuminations[J]. Biomedical Optics Express, 2018, 9(6): 2526-2542.
- [15] Zuo C, Sun J S, Li J J, et al. Wide-field high-resolution 3D microscopy with Fourier ptychographic diffraction tomography [J]. Optics and Lasers in Engineering, 2020, 128: 106003.
- [16] Cutrona L J, Vivian W E, Leith E N, et al. A high-resolution radar combat-surveillance system[J]. IRE Transactions on Military Electronics, 1961, MIL-5(2): 127-131.
- [17] Betzig E, Patterson G H, Sougrat R, et al. Imaging intracellular fluorescent proteins at nanometer resolution[J]. Science, 2006, 313(5793): 1642-1645.
- [18] Gustafsson M G L. Surpassing the lateral resolution limit by a factor of two using structured illumination microscopy[J]. Journal of Microscopy, 2000, 198(2): 82-87.
- [19] Zheng G A, Horstmeyer R, Yang C. Wide-field, high-resolution Fourier ptychographic microscopy[J]. Nature Photonics, 2013, 7(9): 739-745.
- [20] Babcock H W. The possibility of compensating astronomical seeing[J]. Publications of the Astronomical Society of the Pacific, 1953, 65: 229-236.
- [21] 张润南, 蔡泽伟, 孙佳嵩, 等. 光场相干测量及其在计算成像中的应用[J]. 激光与光电子学进展, 2021, 58(18): 1811003.
- [22] Zhang R N, Cai Z W, Sun J S, et al. Optical-field coherence measurement and its applications in computational imaging[J]. Laser & Optoelectronics Progress, 2021, 58(18): 1811003.
- [23] 左超, 陈钱. 计算光学成像: 何来, 何处, 何去, 何从? [J]. 红外与激光工程, 2022, 51(2): 20220110.
- [24] Zuo C, Chen Q. Computational optical imaging: an overview[J]. Infrared and Laser Engineering, 2022, 51(2): 20220110.
- [25] Mir M, Bhaduri B, Wang R, et al. Quantitative phase imaging [M]//Progress in optics. Amsterdam: Elsevier, 2012, 57: 133-217.
- [26] Park Y, Depeursinge C, Popescu G. Quantitative phase imaging in biomedicine[J]. Nature Photonics, 2018, 12: 578-589.
- [27] Javidi B, Carnicer A, Anand A, et al. Roadmap on digital holography[J]. Optics Express, 2021, 29(22): 35078-35118.
- [28] Osten W, Faridian A, Gao P, et al. Recent advances in digital

- holography[J]. *Applied Optics*, 2014, 53(27): G44-G63.
- [26] Rosen J, Alford S, Allan B, et al. Roadmap on computational methods in optical imaging and holography [invited][J]. *Applied Physics B*, 2024, 130(9): 166.
- [27] Gerchberg R. A practical algorithm for the determination of phase from image and diffraction plane pictures[J]. *Optik*, 1972, 35: 237-246.
- [28] Gerchberg R W. Phase determination from image and diffraction plane pictures in the electron microscope[J]. *Optik*, 1971, 34: 275-284.
- [29] Teague M R. Irradiance moments: their propagation and use for unique retrieval of phase[J]. *Journal of the Optical Society of America*, 1982, 72(9): 1199-1209.
- [30] Teague M R. Deterministic phase retrieval: a Green's function solution[J]. *Journal of the Optical Society of America*, 1983, 73(11): 1434-1441.
- [31] Fan Y, Sun J S, Chen Q, et al. Optimal illumination scheme for isotropic quantitative differential phase contrast microscopy[J]. *Photonics Research*, 2019, 7(8): 890-904.
- [32] Mehta S B, Sheppard C J R. Quantitative phase-gradient imaging at high resolution with asymmetric illumination-based differential phase contrast[J]. *Optics Letters*, 2009, 34(13): 1924-1926.
- [33] Tian L, Waller L. Quantitative differential phase contrast imaging in an LED array microscope[J]. *Optics Express*, 2015, 23(9): 11394-11403.
- [34] Sun J S, Chen Q, Zhang Y Z, et al. Efficient positional misalignment correction method for Fourier ptychographic microscopy[J]. *Biomedical Optics Express*, 2016, 7(4): 1336-1350.
- [35] Shu Y F, Sun J S, Lyu J M, et al. Adaptive optical quantitative phase imaging based on annular illumination Fourier ptychographic microscopy[J]. *Photonix*, 2022, 3(1): 24.
- [36] 田璇, 费舒全, 李润泽, 等. 人工智能定量相位成像: 从物理到算法再到物理(内封面文章·特邀)[J]. *红外与激光工程*, 2025, 54(2): 20240490.
- Tian X, Fei S Q, Li R Z, et al. Artificial-intelligent quantitative phase imaging: from physics to algorithm and back to physics (inner cover paper·invited)[J]. *Infrared and Laser Engineering*, 2025, 54(2): 20240490.
- [37] Zuo C, Qian J M, Feng S J, et al. Deep learning in optical metrology: a review[J]. *Light: Science & Applications*, 2022, 11(4): 466-519.
- [38] Ongie G, Jalal A, Metzler C A, et al. Deep learning techniques for inverse problems in imaging[J]. *IEEE Journal on Selected Areas in Information Theory*, 2020, 1(1): 39-56.
- [39] Sinha A, Lee J, Li S, et al. Lensless computational imaging through deep learning[J]. *Optica*, 2017, 4(9): 1117-1125.
- [40] Rivenson Y, Zhang Y B, Günaydin H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks[J]. *Light: Science & Applications*, 2018, 7: 17141.
- [41] Wu Y C, Rivenson Y, Zhang Y B, et al. Extended depth-of-field in holographic imaging using deep-learning-based autofocusing and phase recovery[J]. *Optica*, 2018, 5(6): 704-710.
- [42] Deng M, Li S, Goy A, et al. Learning to synthesize: robust phase retrieval at low photon counts[J]. *Light: Science & Applications*, 2020, 9: 36.
- [43] Wang K Q, Di J L, Li Y, et al. Transport of intensity equation from a single intensity image via deep learning[J]. *Optics and Lasers in Engineering*, 2020, 134: 106233.
- [44] Kemp Z C. Propagation based phase retrieval of simulated intensity measurements using artificial neural networks[J]. *Journal of Optics*, 2018, 20(4): 045606.
- [45] Kellman M R, Bostan E, Repina N A, et al. Physics-based learned design: optimized coded-illumination for quantitative phase imaging[J]. *IEEE Transactions on Computational Imaging*, 2019, 5(3): 344-353.
- [46] Diederich B, Wartmann R, Schadwinkel H, et al. Using machine-learning to optimize phase contrast in a low-cost cellphone microscope[J]. *PLoS One*, 2018, 13(3): e0192937.
- [47] Nguyen T, Xue Y J, Li Y Z, et al. Deep learning approach for Fourier ptychography microscopy[J]. *Optics Express*, 2018, 26(20): 26470-26484.
- [48] Jiang S W, Guo K K, Liao J, et al. Solving Fourier ptychographic imaging problems via neural network modeling and TensorFlow[J]. *Biomedical Optics Express*, 2018, 9(7): 3306-3319.
- [49] Kellman M, Bostan E, Chen M, et al. Data-driven design for Fourier ptychographic microscopy[C]//2019 IEEE International Conference on Computational Photography (ICCP), May 15-17, 2019, Tokyo, Japan. New York: IEEE Press, 2019: 1-8.
- [50] Wang K Q, Song L, Wang C T, et al. On the use of deep learning for phase recovery[J]. *Light: Science & Applications*, 2024, 13(1): 4.
- [51] Park J, Bai B J, Ryu D, et al. Artificial intelligence-enabled quantitative phase imaging methods for life sciences[J]. *Nature Methods*, 2023, 20(11): 1645-1660.
- [52] Karniadakis G E, Kevrekidis I G, Lu L, et al. Physics-informed machine learning[J]. *Nature Reviews Physics*, 2021, 3: 422-440.
- [53] Zhang Y H, Noack M A, Vagovic P, et al. PhaseGAN: a deep-learning phase-retrieval approach for unpaired datasets[J]. *Optics Express*, 2021, 29(13): 19593-19604.
- [54] Li Z S, Sun J S, Fan Y, et al. Deep learning assisted variational Hilbert quantitative phase imaging[J]. *Opto-Electronic Science*, 2023, 2(4): 220023.
- [55] Bouchama L, Dorizzi B, Klossa J, et al. A physics-inspired deep learning framework for an efficient Fourier ptychographic microscopy reconstruction under low overlap conditions[J]. *Sensors*, 2023, 23(15): 6829.
- [56] Huang L Z, Chen H L, Liu T R, et al. Self-supervised learning of hologram reconstruction using physics consistency[J]. *Nature Machine Intelligence*, 2023, 5: 895-907.
- [57] Li R J, Pedrini G, Huang Z Z, et al. Physics-enhanced neural network for phase retrieval from two diffraction patterns[J]. *Optics Express*, 2022, 30(18): 32680-32692.
- [58] Bostan E, Heckel R, Chen M, et al. Deep phase decoder: self-calibrating phase microscopy with an untrained deep neural network[J]. *Optica*, 2020, 7(6): 559-562.
- [59] Niknam F, Qazvini H, Latifi H. Holographic optical field recovery using a regularized untrained deep decoder network[J]. *Scientific Reports*, 2021, 11: 10903.
- [60] Wang F, Bian Y M, Wang H C, et al. Phase imaging with an untrained neural network[J]. *Light: Science & Applications*, 2020, 9: 77.
- [61] Chen Y J, Vyas S, Huang H M, et al. Self-supervised neural network for phase retrieval in QDPC microscopy[J]. *Optics Express*, 2023, 31(12): 19897-19908.
- [62] 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 Y T, Zhou H Q, Yan J X, et al. Advances in computational optics based on deep learning[J]. *Chinese Journal of Lasers*, 2021, 48(19): 1918004.
- [63] Wang K Q, Lam E Y. Deep learning phase recovery: data-driven, physics-driven, or a combination of both?[J]. *Advanced Photonics Nexus*, 2024, 3(5): 0566006.
- [64] Lee K, Kim K, Jung J, et al. Quantitative phase imaging techniques for the study of cell pathophysiology: from principles to applications[J]. *Sensors*, 2013, 13(4): 4170-4191.
- [65] Popescu G. Quantitative phase imaging of cells and tissues[M]. New York: McGraw-Hill Professional, 2011.

- [66] Klivanov M V. The phase retrieval problem[J]. IEEE Transactions on Antennas and Propagation, 1981, 29(2): 386-391.
- [67] Kreis T. Digital holographic interference-phase measurement using the Fourier-transform method[J]. Journal of the Optical Society of America A, 1986, 3(6): 847-855.
- [68] Huang Z Z, Cao L C. Quantitative phase imaging based on holography: trends and new perspectives[J]. Light: Science & Applications, 2024, 13(1): 145.
- [69] Kang W, Zheng Z, Huang H. Advancements in digital holography for crystalline material characterization: a review[J]. Crystal Research and Technology, 2025, 60(4): 2400264.
- [70] Situ G H. Deep holography[J]. Light: Advanced Manufacturing, 2022, 3(2): 278-300.
- [71] Sheppard C J R. Defocused transfer function for a partially coherent microscope and application to phase retrieval[J]. Journal of the Optical Society of America A, 2004, 21(5): 828-831.
- [72] Mehta S B, Sheppard C J R. Partially coherent microscope in phase space[J]. Journal of the Optical Society of America A, 2018, 35(8): 1272-1282.
- [73] Kakei S, Komuro K, Nomura T. Transport-of-intensity phase imaging with polarization directed flat lenses[J]. Applied Optics, 2020, 59(7): 2011-2015.
- [74] Lopera M J, Rogalski M, Arcab P, et al. Lensless Mueller holographic microscopy with robust noise reduction for multiplane polarization imaging[J]. Optics & Laser Technology, 2025, 181: 111936.
- [75] 范瑶, 陈钱, 孙佳嵩, 等. 差分相衬显微成像技术发展综述[J]. 红外与激光工程, 2019, 48(6): 0603014.
Fan Y, Chen Q, Sun J S, et al. Review of the development of differential phase contrast microscopy[J]. Infrared and Laser Engineering, 2019, 48(6): 0603014.
- [76] Zheng G A, Shen C, Jiang S W, et al. Concept, implementations and applications of Fourier ptychography[J]. Nature Reviews Physics, 2021, 3: 207-223.
- [77] Fienup J R. Phase retrieval algorithms: a comparison[J]. Applied Optics, 1982, 21(15): 2758-2769.
- [78] Creath K. Phase-measurement interferometry techniques[J]. Progress in Optics, 1988, 26: 349-393.
- [79] de Groot P. Derivation of algorithms for phase-shifting interferometry using the concept of a data-sampling window[J]. Applied Optics, 1995, 34(22): 4723-4730.
- [80] Ettl P, Creath K. Comparison of phase-unwrapping algorithms by using gradient of first failure[J]. Applied Optics, 1996, 35(25): 5108-5114.
- [81] Lu L P, Sun J S, Zhang J L, et al. Quantitative phase imaging camera with a weak diffuser[J]. Frontiers in Physics, 2019, 7: 77.
- [82] Lu L P, Fan Y, Sun J S, et al. Accurate quantitative phase imaging by the transport of intensity equation: a mixed-transfer-function approach[J]. Optics Letters, 2021, 46(7): 1740-1743.
- [83] Barone-Nugent E D, Barty A, Nugent K A. Quantitative phase-amplitude microscopy I: optical microscopy[J]. Journal of Microscopy, 2002, 206(3): 194-203.
- [84] Jenkins M H, Gaylord T K. Quantitative phase microscopy via optimized inversion of the phase optical transfer function[J]. Applied Optics, 2015, 54(28): 8566-8579.
- [85] Zuo C, Sun J S, Li J J, et al. High-resolution transport-of-intensity quantitative phase microscopy with annular illumination [J]. Scientific Reports, 2017, 7: 7654.
- [86] 李自强, 李新阳, 高泽宇, 等. 基于深度学习的自适应光学波前传感技术研究综述[J]. 强激光与粒子束, 2021, 33(8): 081001.
Li Z Q, Li X Y, Gao Z Y, et al. Review of wavefront sensing technology in adaptive optics based on deep learning[J]. High Power Laser and Particle Beams, 2021, 33(8): 081001.
- [87] Rodrigo J A, Alieva T. Rapid quantitative phase imaging for partially coherent light microscopy[J]. Optics Express, 2014, 22(11): 13472-13483.
- [88] Lu L P, Li J J, Shu Y F, et al. Hybrid brightfield and darkfield transport of intensity approach for high-throughput quantitative phase microscopy[J]. Advanced Photonics, 2022, 4(5): 056002.
- [89] Dong S Y, Shiradkar R, Nanda P, et al. Spectral multiplexing and coherent-state decomposition in Fourier ptychographic imaging[J]. Biomedical Optics Express, 2014, 5(6): 1757-1767.
- [90] Barbastathis G, Ozcan A, Situ G. On the use of deep learning for computational imaging[J]. Optica, 2019, 6(8): 921-943.
- [91] Goodman J W. Introduction to Fourier optics[M]. Colorado: Roberts and Company Publishers, 2005.
- [92] Zeng T J, So H K H, Lam E Y. RedCap: residual encoder-decoder capsule network for holographic image reconstruction[J]. Optics Express, 2020, 28(4): 4876-4887.
- [93] Huang L Z, Liu T R, Yang X L, et al. Holographic image reconstruction with phase recovery and autofocusing using recurrent neural networks[J]. ACS Photonics, 2021, 8(6): 1763-1774.
- [94] Ding H, Li F J, Chen X, et al. ContransGAN: convolutional neural network coupling global swin-transformer network for high-resolution quantitative phase imaging with unpaired data[J]. Cells, 2022, 11(15): 2394.
- [95] Wang W J, Ali N, Ma Y, et al. Deep learning-based quantitative phase microscopy[J]. Frontiers in Physics, 2023, 11: 1218147.
- [96] Zhou J, Jin Y B, Lu L P, et al. Deep learning-enabled pixel-super-resolved quantitative phase microscopy from single-shot aliased intensity measurement[J]. Laser & Photonics Reviews, 2024, 18(1): 2300488.
- [97] Jo Y, Cho H, Lee S Y, et al. Quantitative phase imaging and artificial intelligence: a review[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2019, 25(1): 6800914.
- [98] Li S, Barbastathis G. Spectral pre-modulation of training examples enhances the spatial resolution of the phase extraction neural network (PhENN)[J]. Optics Express, 2018, 26(22): 29340-29352.
- [99] Shwartz-Ziv R, Tishby N. Opening the black box of deep neural networks via information[EB/OL]. (2023-01-21)[2025-07-23]. <http://arxiv.org/abs/1703.00810>.
- [100] Xue Y J, Cheng S Y, Li Y Z, et al. Reliable deep-learning-based phase imaging with uncertainty quantification[J]. Optica, 2019, 6(5): 618-629.
- [101] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686-707.
- [102] Mooij J, Janzing D, Scholkopf B. From ordinary differential equations to structural causal models: the deterministic case [EB/OL]. (2013-04-30)[2025-08-13]. <http://arxiv.org/abs/1304.7920>.
- [103] Schölkopf B. Causality for machine learning[M]. New York: ACM, 2022: 765-804.
- [104] Zhang J Z, Xu T F, Shen Z Y, et al. Fourier ptychographic microscopy reconstruction with multiscale deep residual network [J]. Optics Express, 2019, 27(6): 8612-8625.
- [105] Li X, Qi H, Jiang S W, et al. Quantitative phase imaging via a cGAN network with dual intensity images captured under centrosymmetric illumination[J]. Optics Letters, 2019, 44(11): 2879-2882.
- [106] Wang H, Zhu J B, Li Y Z, et al. NeuPh: scalable and generalizable neural phase retrieval with local conditional neural fields[J]. Advanced Photonics Nexus, 2024, 3(5): 056005.
- [107] Narayan S K, Gannavarpu R. Simultaneous estimation of multiple order phase derivatives using deep learning method in digital holographic interferometry[J]. Optics and Lasers in

- Engineering, 2025, 184: 108583.
- [108] Chen J W, Zhang Q N, Lu X X, et al. Quantitative phase imaging based on model transfer learning[J]. Optics Express, 2022, 30(10): 16115-16133.
- [109] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [110] Cs sz r I, K rner J. Information theory: coding theorems for discrete memoryless systems[M]. Cambridge: Cambridge University Press, 2011.
- [111] Shannon C E. A mathematical theory of communication[J]. The Bell System Technical Journal, 1948, 27(3): 379-423.
- [112] Goy A, Arthur K, Li S, et al. Low photon count phase retrieval using deep learning[J]. Physical Review Letters, 2018, 121(24): 243902.
- [113] Huang L Z, Yang X L, Liu T R, et al. Few-shot transfer learning for holographic image reconstruction using a recurrent neural network[J]. APL Photonics, 2022, 7(7): 070801.
- [114] Zhang Q, Lu S, Li J, et al. Deep phase shifter for quantitative phase imaging[EB/OL]. (2020-03-06)[2025-06-08]. <https://arxiv.org/abs/2003.03027>.
- [115] Nishihara R, Lessard L, Recht B, et al. A general analysis of the convergence of ADMM[EB/OL]. (2015-02-06)[2025-08-06]. <https://arxiv.org/abs/1502.02009>.
- [116] Lee C, Song G, Kim H, et al. Deep learning based on parameterized physical forward model for adaptive holographic imaging with unpaired data[J]. Nature Machine Intelligence, 2023, 5: 35-45.
- [117] Li Z S, Gu H J, Lu L, et al. DL-CSPF: deep-learning-based cell segmentation with a physical framework for digital holographic microscopy[J]. Applied Optics, 2024, 64(7): B20-B30.
- [118] Monakhova K, Yurtsever J, Kuo G, et al. Learned reconstructions for practical mask-based lensless imaging[J]. Optics Express, 2019, 27(20): 28075-28090.
- [119] Ma L Y, Wang H X, Leng N Y, et al. ADMM based Fourier phase retrieval with untrained generative prior[EB/OL]. (2024-07-01)[2024-07-17]. <http://arxiv.org/abs/2210.12646>.
- [120] Yang Y C, Lian Q S, Zhang X H, et al. HIONet: deep priors based deep unfolded network for phase retrieval[J]. Digital Signal Processing, 2023, 132: 103797.
- [121] Fienup J R. Reconstruction of an object from the modulus of its Fourier transform[J]. Optics Letters, 1978, 3(1): 27-29.
- [122] Shi W, Ling Q, Yuan K, et al. On the linear convergence of the ADMM in decentralized consensus optimization[J]. IEEE Transactions on Signal Processing, 2014, 62(7): 1750-1761.
- [123] Wahlberg B, Boyd S, Annergren M, et al. An ADMM algorithm for a class of total variation regularized estimation problems[J]. IFAC Proceedings Volumes, 2012, 45(16): 83-88.
- [124] Boominathan L, Maniparambil M, Gupta H, et al. Phase retrieval for Fourier Ptychography under varying amount of measurements[EB/OL]. (2018-05-09)[2024-05-08]. <http://arxiv.org/abs/1805.03593>.
- [125] Lempitsky V, Vedaldi A, Ulyanov D. Deep image prior[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 9446-9454.
- [126] Zhang X Y, Wang F, Situ G H. BlindNet: an untrained learning approach toward computational imaging with model uncertainty [J]. Journal of Physics D: Applied Physics, 2022, 55(3): 034001.
- [127] Zhu H, Liu Z, Zhou Y, et al. DNF: diffractive neural field for lensless microscopic imaging[J]. Optics Express, 2022, 30(11): 18168-18178.
- [128] Li Z S, Chen Y Y, Sun J S, et al. High bandwidth-utilization digital holographic reconstruction using an untrained neural network[J]. Applied Sciences, 2022, 12(20): 10656.
- [129] Jin Y B, Lu L P, Zhou S, et al. Neural-field-assisted transport-of-intensity phase microscopy: partially coherent quantitative phase imaging under unknown defocus distance[J]. Photonics Research, 2024, 12(7): 1494-1501.
- [130] Chen Q, Huang D L, Chen R. Fourier ptychographic microscopy with untrained deep neural network priors[J]. Optics Express, 2022, 30(22): 39597-39612.
- [131] Rogalski M, Arcab P, Stanaszek L, et al. Physics-driven universal twin-image removal network for digital in-line holographic microscopy[J]. Optics Express, 2024, 32(1): 742-761.
- [132] Dou J Z, An Q M, Liu X S, et al. Enhanced phase recovery in in-line holography with self-supervised complex-valued neural networks[J]. Optics and Lasers in Engineering, 2025, 184: 108685.
- [133] Nguyen T, Bui V, Lam V, et al. Automatic phase aberration compensation for digital holographic microscopy based on deep learning background detection[J]. Optics Express, 2017, 25(13): 15043-15057.
- [134] Rivenson Y, Wu Y C, Ozcan A. Deep learning in holography and coherent imaging[J]. Light: Science & Applications, 2019, 8: 85.
- [135] Yang Y, Sun J, Li H B, et al. Deep ADMM-net for compressive sensing MRI[EB/OL]. [2025-06-05]. https://proceedings.neurips.cc/paper_files/paper/2016/file/1679091c5a880fa6fb5e6087eb1b2dc-Paper.pdf.
- [136] Alemi A A, Fischer I, Dillon J V. Deep variational information bottleneck[EB/OL]. (2016-12-01)[2025-07-23]. <http://arxiv.org/abs/1612.00410>.
- [137] Achille A, Soatto S. Emergence of invariance and disentanglement in deep representations[EB/OL]. (2017-06-05)[2025-06-08]. <https://arxiv.org/abs/1706.01350>.
- [138] Tishby N, Zaslavsky N. Deep learning and the information bottleneck principle[C]//2015 IEEE Information Theory Workshop (ITW), April 26-May 1, 2015, Jerusalem, Israel. New York: IEEE Press, 2015: 1-5.
- [139] Seo S, Su T W, Tseng D K, et al. Lensfree holographic imaging for on-chip cytometry and diagnostics[J]. Lab on a Chip, 2009, 9(6): 777-787.
- [140] 鲁心怡, 黄昱, 张梓童, 等. 深度学习在超分辨显微成像中的研究进展(特邀)[J]. 激光与光电子学进展, 2024, 61(16): 1611002.
- Lu X Y, Huang Y, Zhang Z T, et al. Advances in deep learning for super-resolution microscopy (invited)[J]. Laser & Optoelectronics Progress, 2024, 61(16): 1611002.
- [141] 周瑶, 费鹏. 中国光学十大进展:深度学习赋能的高通量荧光显微成像技术(特邀)[J]. 激光与光电子学进展, 2024, 61(14): 1400001.
- Zhou Y, Fei P. China's top 10 optical breakthroughs: deep learning-enhanced high-throughput fluorescence microscopy (invited)[J]. Laser & Optoelectronics Progress, 2024, 61(14): 1400001.
- [142] Kim K, Yoon H, Diez-Silva M, et al. High-resolution three-dimensional imaging of red blood cells parasitized by Plasmodium falciparum and *in situ* hemozoin crystals using optical diffraction tomography[J]. Journal of Biomedical Optics, 2014, 19(1): 011005.
- [143] Kim K, Yoon J, Shin S, et al. Optical diffraction tomography techniques for the study of cell pathophysiology[J]. Journal of Biomedical Photonics & Engineering, 2016, 2(2): 020201.
- [144] Sung Y, Choi W, Fang-Yen C, et al. Optical diffraction tomography for high resolution live cell imaging[J]. Optics Express, 2009, 17(1): 266-277.
- [145] Bai Z D, Zhou S, et al. Differential phase contrast intensity diffraction tomography[J]. Optics Letters, 2024, 49(23): 6861-6864.
- [146] Li J J, Zhou N, Sun J S, et al. Transport of intensity diffraction tomography with non-interferometric synthetic aperture for

- three-dimensional label-free microscopy[J]. *Light: Science & Applications*, 2022, 11: 154.
- [147] Li J J, Matlock A, Li Y Z, et al. Resolution-enhanced intensity diffraction tomography in high numerical aperture label-free microscopy[J]. *Photonics Research*, 2020, 8(12): 1818-1826.
- [148] Liu R H, Sun Y, Zhu J B, et al. Recovery of continuous 3D refractive index maps from discrete intensity-only measurements using neural fields[J]. *Nature Machine Intelligence*, 2022, 4: 781-791.
- [149] Tahir W, Wang H, Tian L. Adaptive 3D descattering with a dynamic synthesis network[J]. *Light: Science & Applications*, 2022, 11(1): 42.
- [150] Lim J, Psaltis D. MaxwellNet: physics-driven deep neural network training based on Maxwell's equations[J]. *APL Photonics*, 2022, 7(1): 011301.
- [151] Shafto M, Conroy M, Doyle R, et al. Draft modeling, simulation, information technology & processing roadmap[J]. *Technology Area*, 2010, 11: 1-32.
- [152] Tao F, Zhang H, Liu A, et al. Digital twin in industry: state-of-the-art[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(4): 2405-2415.
- [153] Qi Q L, Tao F, Hu T L, et al. Enabling technologies and tools for digital twin[J]. *Journal of Manufacturing Systems*, 2021, 58: 3-21.
- [154] Singh M, Fuenmayor E, Hinchy E, et al. Digital twin: origin to future[J]. *Applied System Innovation*, 2021, 4(2): 36.
- [155] Tao F, Xiao B, Qi Q L, et al. Digital twin modeling[J]. *Journal of Manufacturing Systems*, 2022, 64: 372-389.
- [156] Mengü D, Ozcan A. All-optical phase recovery: diffractive computing for quantitative phase imaging[J]. *Advanced Optical Materials*, 2022, 10(15): 2270058.
- [157] Sakib Rahman M S, Ozcan A. Computer-free, all-optical reconstruction of holograms using diffractive networks[J]. *ACS Photonics*, 2021, 8(11): 3375-3384.
- [158] Luo Y, Zhao Y F, Li J X, et al. Computational imaging without a computer: seeing through random diffusers at the speed of light [J]. *eLight*, 2022, 2(1): 4.
- [159] Pinkard H, Phillips Z, Babakhani A, et al. Deep learning for single-shot autofocus microscopy[J]. *Optica*, 2019, 6(6): 794-797.
- [160] Ren Z B, Xu Z M, Lam E Y. End-to-end deep learning framework for digital holographic reconstruction[J]. *Advanced Photonics*, 2019, 1(1): 016004.
- [161] Ding H, Li F J, Meng Z, et al. Auto-focusing and quantitative phase imaging using deep learning for the incoherent illumination microscopy system[J]. *Optics Express*, 2021, 29(17): 26385-26403.
- [162] Wu X, Wu Z, Shanmugavel S C, et al. Physics-informed neural network for phase imaging based on transport of intensity equation[J]. *Optics Express*, 2022, 30(24): 43398-43416.
- [163] O'Connor T, Shen J B, Liang B T, et al. Digital holographic deep learning of red blood cells for field-portable, rapid COVID-19 screening[J]. *Optics Letters*, 2021, 46(10): 2344-2347.
- [164] Wu Y C, Luo Y L, Chaudhari G, et al. Bright-field holography: cross-modality deep learning enables snapshot 3D imaging with bright-field contrast using a single hologram[J]. *Light: Science & Applications*, 2019, 8: 25.
- [165] Rubin M, Stein O, Turko N A, et al. TOP-GAN: stain-free cancer cell classification using deep learning with a small training set[J]. *Medical Image Analysis*, 2019, 57: 176-185.
- [166] Chen T Q, Rubanova Y, Bettencourt J, et al. Neural ordinary differential equations[EB/OL]. (2018-06-19)[2025-08-06]. <https://arxiv.org/abs/1806.07366>.
- [167] Belbute-Peres F de A, Smith K A, Allen K R, et al. End-to-end differentiable physics for learning and control[EB/OL]. [2025-08-06]. <https://papers.nips.cc/paper/2018/file/842424a1d0595b76ec4fa03c46e8d755-Paper.pdf>.
- [168] Gharoun H, Momenifar F, Chen F, et al. Meta-learning approaches for few-shot learning: a survey of recent advances[J]. *ACM Computing Surveys*, 2024, 56(12): 1-41.
- [169] Fang Y Q, Yap P T, Lin W L, et al. Source-free unsupervised domain adaptation: a survey[J]. *Neural Networks*, 2024, 174: 106230.
- [170] Guan H, Yap P T, Bozoki A, et al. Federated learning for medical image analysis: a survey[J]. *Pattern Recognition*, 2024, 151: 110424.
- [171] Jeong H, Chun S Y, Lee J. MOST: MR reconstruction optimization for multiple downStream tasks via continual learning [C]//2024 ISMRM & ISMRT Annual Meeting, May 4-9, 2024, Toronto, ON, Canada. Concord: ISMRM, 2024.

Paradigm Shift in Quantitative Phase Imaging: From Physical Modeling to Physics-Driven Deep Learning (Invited)

Lu Linpeng^{1,2,3,4}, Huang Xingyu^{1,2,3}, Zhou Shun^{1,2,3}, Jin Yanbo^{1,2,3}, Li Zhuoshi^{1,2,3},
Sun Jiasong^{1,2,3,4}, Chen Qian^{1,2,3,4**}, Zuo Chao^{1,2,3,4*}

¹Smart Computational Imaging Lab, School of Electronic and Optical Engineering, Nanjing University of Science and Technology, Nanjing 210094, Jiangsu, China;

²Smart Computational Imaging Research Institute (SCIRI) of Nanjing University of Science and Technology, Nanjing 210019, Jiangsu, China;

³Jiangsu Key Laboratory of Visual Sensing & Intelligent Perception, Nanjing 210094, Jiangsu, China;

⁴State Key Laboratory of Extreme Environment Optoelectronic Dynamic Measurement Technology and Instrument, Taiyuan 030051, Shanxi, China

Abstract

Significance Quantitative phase imaging (QPI) is a label-free, wave-optics modality that measures optical path length with high sensitivity and subcellular spatial resolution, and it is increasingly used in life sciences, materials

characterization, and biomedical diagnostics. Yet as systems adopt partially coherent illumination, high-NA optics, and multi-frame or tomographic acquisitions, conventional pipelines based on analytical forward models and iterative inversion face two persistent limits, i.e., restricted model expressiveness when assumptions are violated and high computational cost under real-time or high-throughput constraints, thereby narrowing deployability. Deep learning (DL) offers complementary strengths in representation and speed, but, when divorced from physics, can overfit dataset bias, depend heavily on labels, and lose physical consistency. To bridge these gaps, this review synthesizes physics-driven deep learning (PD-DL) for QPI, which embeds imaging physics into the learning process to couple analytical modeling with data-driven inference. Grounded in the manuscript's system overview, we contrast interferometric and non-interferometric QPI and their modeling boundaries (Figs. 1 and 4), outline the motivation and challenges of introducing DL into QPI (Fig. 2), and frame PD-DL as a unifying route toward physically consistent, data-efficient, and deployment-ready solutions.

Progress We organize state-of-the-art PD-DL by a hierarchy of physical-prior injection that aligns with the manuscript's figures: 1) physics-assisted supervised learning (PASL) at the data-construction layer, which uses digital twins, measurement-consistent simulation, or physics-guided surrogate labels to raise supervision quality and distribution coverage (representative implementations in Figs. 9–11); 2) physics-embedded inference networks (PEINs) at the structural-modeling layer, which integrate differentiable optical operators (e.g., TIE/WOTF propagators, pupil filters) and optimization unrolling (e.g., ADMM-style unfolding) into the network so that parameter co-learning (defocus, pixel size, aberrations) and interpretability are preserved (Figs. 12 and 13); 3) physics-regularized learning (PRL) at the objective-constraint layer, which encodes consistency with the (possibly nonlinear) forward model directly in the loss to enable weak/self-supervision and residual-map diagnostics (Figs. 14 and 15). We connect these pathways to training data and model design (Fig. 6), summarize supervision strategies, information-regulation mechanisms, and system adaptability, and provide a comparative matrix that aligns speed, robustness, interpretability, and maintenance cost (Table 1). Methodologically, PD-DL explains why and when physics at the input, structure, or objective level compresses the solution space and improves generalization (Fig. 3). In terms of application, we highlight two representative directions consistent with the main text: in biomedicine, label-free cytometry and pathology-adjacent workflows leverage PD-DL to stabilize reconstruction across batches/instruments and to derive traceable biophysical readouts; in industrial inspection, online metrology for micro-optics, thin films, and wafer/defect screening benefits from parameter co-learning to accommodate drift/vibration and from physics-residual gating for self-calibration and anomaly flagging, while simulation augments long-tail defect libraries. The overall classification and cross-links among PASL/PEIN/PRL are summarized in the manuscript's PD-DL overview (Fig. 8).

Conclusions and Prospects PD-DL for QPI is converging from three separate tracks into multi-path fusion under a unified physical-control framework, coupling PASL's simulation support, PEIN's structural modeling, and PRL's physics-consistent objectives into a closed-loop, end-to-end pipeline that spans data generation, network design, and objective enforcement. Looking forward, we distill three priorities that echo the paper's challenges and trends: 1) 3D and multiple-scattering modeling, extending differentiable optics to tomographic optics and strongly scattering regimes with learned scattering priors and fast solvers; 2) data efficiency and reliability, advancing digital twins, weak/self-supervision, and continual/domain-adaptive learning with uncertainty estimation and calibration monitoring; 3) deployment and standardization, pursuing lightweight, hardware-aware architectures and interoperable toolchains for edge/real-time operation, together with benchmarks and physics-based quality metrics. These directions align with the manuscript's challenges/trends and future prospects (Figs. 16 and 17), and aim to deliver QPI systems that are physically consistent, robust across domains, and practical for high-throughput biomedical and industrial use.

Key words computational imaging; quantitative phase imaging; physical modeling; deep learning; physics-driven deep learning