

# 中国激光

## 神经网络在超快光学中的应用

朱孝先<sup>1,2,3</sup>, 高亦谈<sup>1,3</sup>, 王一鸣<sup>1,2,3</sup>, 王佶<sup>3</sup>, 赵昆<sup>1,3\*</sup>, 魏志义<sup>1,2,3</sup>

<sup>1</sup>中国科学院物理研究所北京凝聚态物理国家研究中心, 北京 100190;

<sup>2</sup>中国科学院大学, 北京 100049;

<sup>3</sup>松山湖材料实验室, 广东 东莞 523808

**摘要** 近年来随着计算机性能的提高, 机器学习中的神经网络发展迅速, 在诸多领域中得到了成功的应用。在超快光学中, 基于神经网络技术的一些应用在过去几年中也受到了越来越多的关注, 例如脉冲表征、光纤激光器的锁模、多模光纤传播动力学、非线性动力学的预测以及脉冲传播等。综述了神经网络在超快光学中已经实现的一些应用, 包括实验过程中激光器的自调谐、超快传播动力学的表征和控制以及实验数据的处理和物理规律的发掘, 展望了未来应用前景并分析了面临的挑战。

**关键词** 激光光学; 超快光学; 神经网络; 实验控制; 数据处理

中图分类号 O437

文献标志码 A

DOI: 10.3788/CJL230572

### 1 引言

机器学习是人工智能的核心, 是使计算机智能化的根本途径。机器学习是一门多领域交叉学科, 涉及概率论、统计学、逼近论、凸分析、算法复杂度理论等, 其算法被广泛应用于工程和科学的许多领域, 在分类、模式识别、预测、系统参数优化以及基于观测数据构建复杂动力学模型方面具有显著的优势。随着计算机性能的提高, 机器学习技术迅速发展。如谷歌公司开发的“AlphaGo”在人机对战中击败了职业围棋选手<sup>[1]</sup>, 人工智能研究实验室 OpenAI 开发的“ChatGPT”<sup>[2]</sup>可以通过学习和理解人类的语言来进行对话, 还能与人互动, 甚至能完成撰写邮件、论文、文案及翻译等任务。

根据学习方式, 机器学习可以分为监督学习、无监督学习、强化学习等。监督学习通过建立数据样本和已知结果之间的联系, 提取特征值和映射关系, 通过不断学习和训练, 对新的数据进行结果预测, 该方法通常用于分类和回归。无监督学习在没有目标值的情况下选取样本数据, 利用神经网络自动寻找样本数据的内在规律, 该方法在数据预处理、数据降维、主成分分析等方面发挥了巨大作用。强化学习是以“试错”的方式进行学习, 利用与环境进行交互获得的反馈来指导行为, 目的是使智能体获得最佳的正反馈结果。机器学习的算法包括逻辑回归、支持向量机、决策树、随机森林和神经网络等。常见的基本神经网络包括全连接神

经网络(FCNN)、卷积神经网络(CNN)、循环神经网络(RNN)、生成对抗神经网络(GAN)、深度置信网络(DBN)等, 这些网络可以处理不同的任务, 如对数据按标签进行分类、提取图像的局部特征、生成新的同类数据等。它们可以独立工作, 也可以组合使用。

在超快光学领域, 许多现象是非线性和多维的, 因此对噪声敏感。机器学习中的神经网络具有从大量数据中学习特征及寻找非线性规律的能力, 甚至可以仅基于复杂时间序列的分析, 确定潜在的物理模型和控制方程。基于这个优势, 神经网络在光学领域中有很好的应用前景。本文回顾了神经网络在超快光学中已经实现的一些具体成果, 将其分为实验参数优化和实验数据处理两部分, 分别介绍了神经网络在其中的作用, 并对神经网络在光学中的发展方向及应用前景进行了展望。

### 2 超快实验过程控制

利用机器学习中的神经网络技术可以找到系统状态变量之间的关系而无须求解复杂的数学和物理方程, 为探索非线性动力系统提供了新的途径。神经网络技术得到的非线性模型也可用于设计和控制激光特性。超快实验中脉冲的优化可能涉及多个参数, 这些参数以复杂的方式相互关联。与其他形式的手动或部分自动化控制方法相比, 神经网络在复杂系统的参数优化方面具有显著优势。

收稿日期: 2023-03-01; 修回日期: 2023-04-02; 录用日期: 2023-04-28; 网络首发日期: 2023-05-08

基金项目: 国家自然科学基金(92150103, 61690221)、中国科学院稳定支持基础研究领域青年团队计划(YSBR-059)、国家重点研发计划(2017YFB0405202)

通信作者: \*zhaokun@iphy.ac.cn

## 2.1 超快光纤激光器的自调谐

超快激光器在许多光学领域中是重要工具,包括材料加工<sup>[3-4]</sup>、生物成像<sup>[5-6]</sup>、光学频率测量<sup>[7-10]</sup>、高分辨率原子钟<sup>[11-12]</sup>、信号处理<sup>[13-14]</sup>、光谱展宽<sup>[15]</sup>、阿秒光学<sup>[16]</sup>、测距<sup>[17-18]</sup>和天文学<sup>[19-20]</sup>等。啁啾脉冲放大产生的高功率飞秒脉冲在关于飞秒相干控制的几次诺贝尔奖成果中发挥了核心作用<sup>[21-22]</sup>。

超快激光器中脉冲的特性由一系列非线性色散和耗散效应决定。以光纤激光器为例,根据参数(偏振、泵浦功率、光谱滤波和损耗等)的选择,同一激光器可以表现出完全不同的特性,如连续波激光、类噪声脉冲产生、Q开关、锁模、多脉冲和束缚态等<sup>[23-24]</sup>。为实现激光器的稳定运行或达到特定参数,需要根据激光器的输出参数进行反馈,但输出参数与控制参数之间的非线性关系使得激光器的操作非常复杂,这给控制和优化激光参数带来了挑战。

自调谐光学系统在锁模光纤激光器等技术中的应用越来越重要。为了得到合适的控制规律,维持目标输出参数的稳定性,这种自调整范式需要智能算法。目前自优化或自调谐激光器的反馈回路通常使用高级搜索或遗传算法,以某些特定的适应度或目标函数作为参考准则,实现了不同状态下的自调谐和自设置,或按照需求产生不同持续时间和能量的脉冲<sup>[25-31]</sup>。但遗传算法对初始种群的选择很敏感,这可能导致适应度函数收敛到局部最优而非全局最优,不利于应对超快激光中常见的多稳态动力学情况;另一个缺点是其收

敛时间相对较长,需要几分钟甚至几小时。

Pu 等<sup>[32]</sup>的研究结果表明,模仿人类逻辑的算法有可能将激光锁定在所需的操作状态,并在不到 1 s 的时间内从扰动状态恢复到锁定状态。这种算法结合了人类和机器的优点,由高级 Rosenbrock 搜索、随机碰撞恢复和各区域的识别组成。高级 Rosenbrock 搜索算法将被动锁模光纤激光器从自由运行状态引导到理想的运行状态,随机碰撞恢复将激光器从环境干扰导致的被动分离状态恢复到期望的运行状态,它们都学习人类在偏振调谐过程中锁定模式的方法。如图 1(a)所示,类人算法从高级 Rosenbrock 搜索开始,在确定锁定所需的区域后,专注于基于识别的监测;随机碰撞恢复尝试将激光拉回锁定区域,如果恢复成功,类人算法将返回监控状态,否则重新启动高级 Rosenbrock 搜索来锚定一个新的期望点。图 1(b)展示了实时智能锁模光纤激光器,其中反馈控制面板由一个模数转换器(ADC)、一个现场可编程门阵列(FPGA)和 4 个数模转换器(DAC)构成。ADC 用于监测波形。FPGA 作为计算中心,使用高级 Rosenbrock 搜索算法搜索所需的区域。DAC 将指令从 FPGA 转换为直流电压并作用于调谐偏振的电极化控制器(EPC)。由于采用了类人算法,从自由运行状态到基本锁模状态的锁模时间最短仅为 0.22 s。可以预见,利用神经网络技术识别模式,结合实时测量技术的最新进展<sup>[25, 33]</sup>,可以帮助人们更好地理解和控制超快激光动力学过程,从而构建具有更好鲁棒性的激光系统。

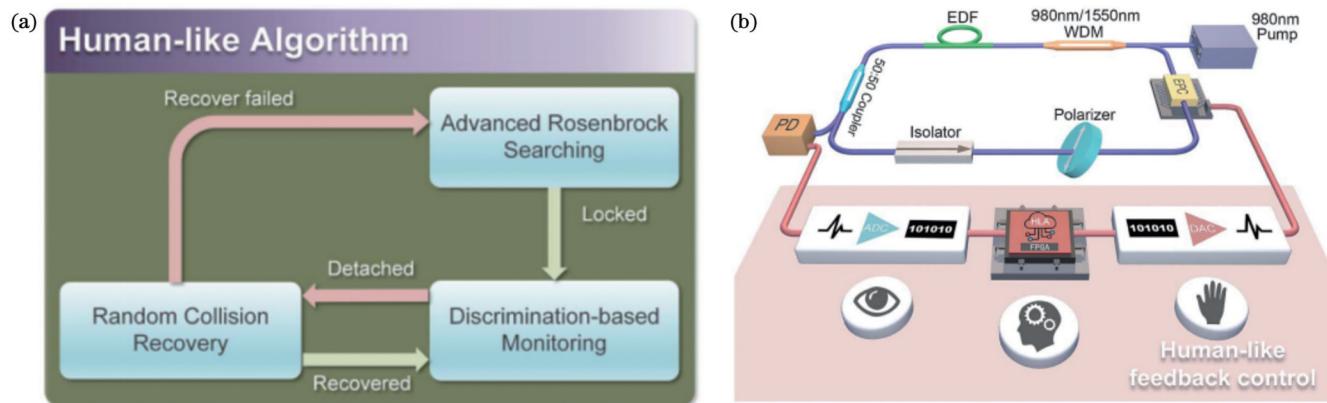


图 1 基于类人算法的智能可编程锁模光纤激光器<sup>[32]</sup>。(a)类人算法原理图;(b)实时智能锁模光纤激光器

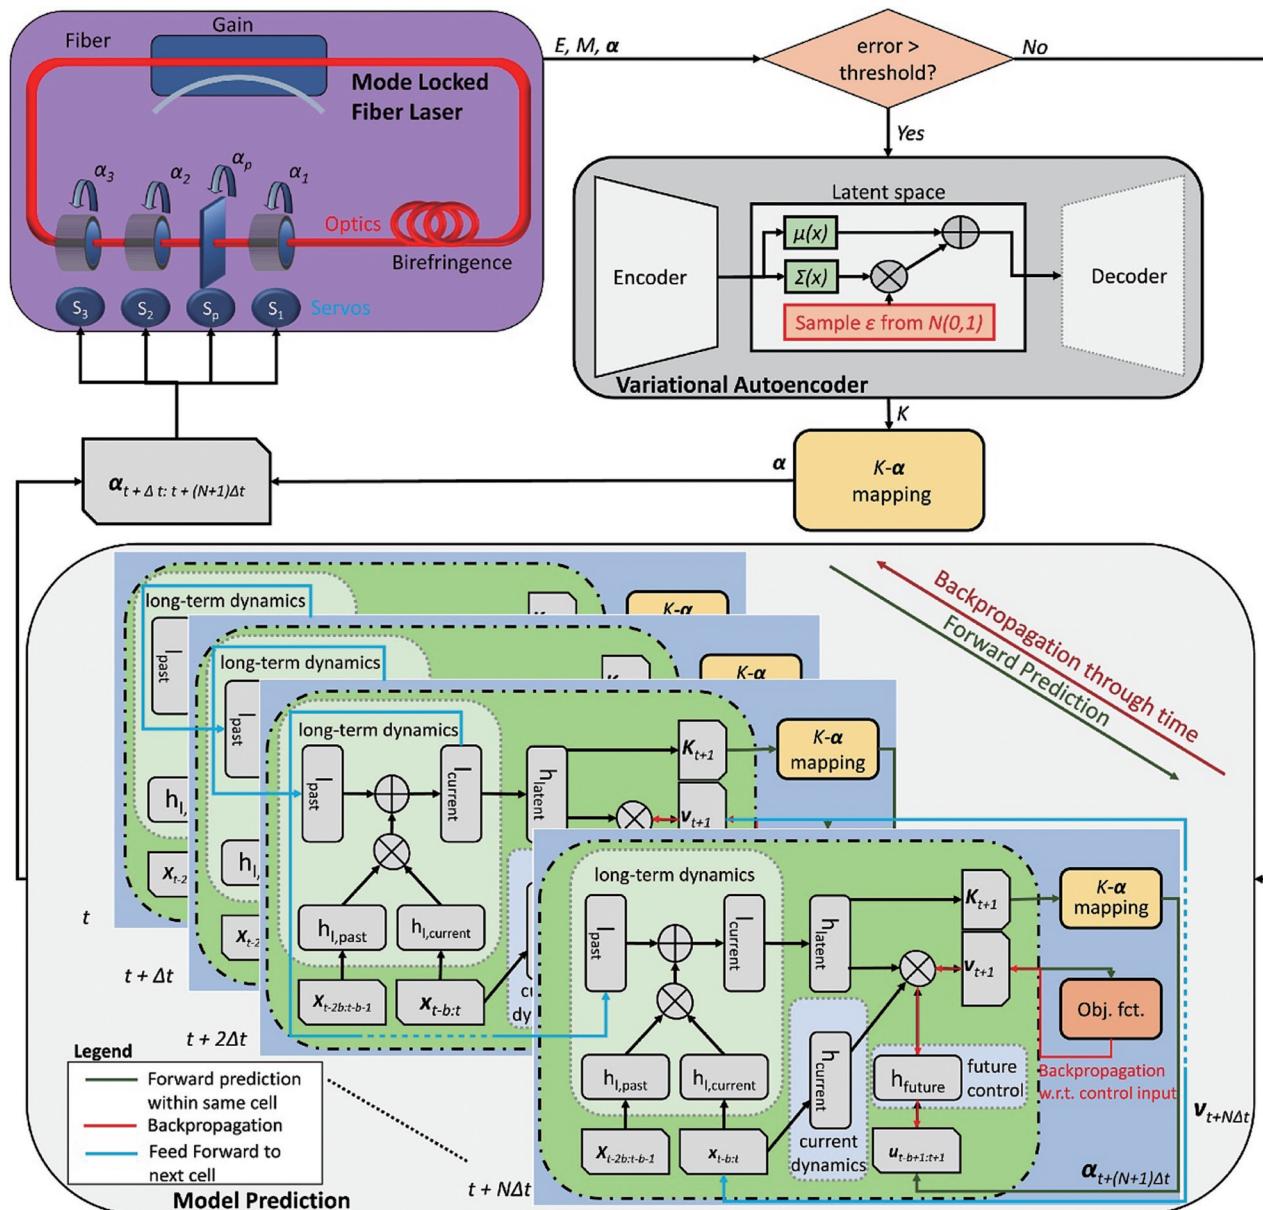
Fig. 1 Intelligent programmable mode-locked fiber laser based on human-like algorithm<sup>[32]</sup>. (a) Schematic of human-like algorithm; (b) real-time intelligent mode-locked fiber laser

Baumeister 等<sup>[34]</sup>通过集成深度学习(DL)架构与模型预测控制(MPC)来实现自调谐锁模光纤激光器。这种 DL-MPC 算法不仅可以学习未知双折射的模型,还可以建立激光器的动力学模型并寻找适当的控制规律,以在双折射随机漂移的情况下保持稳定的高能量脉冲。DL-MPC 算法由一个内环和一个外环组成(图 2)。内环包括变分自动编码器(VAE)和 K- $\alpha$  映射,外环包括模型预测(MP)-RNN 网络。MP-RNN 预测激光器

的 N 个未来状态和相应的控制输入。通过优化这些控制输入来最大化目标函数。如果预测误差超过一定的阈值,则使用内环来稳定系统。该算法可以快速建立双折射预测模型,并调用深度学习模块为新参数配置生成接近最优的解。模拟表明,该算法能够在系统受到扰动后立即恢复稳定的锁模。

## 2.2 相干动力学的控制

少周期脉冲具有超宽的光谱,可以用于物质相互

图 2 DL-MPC 原理图<sup>[34]</sup>Fig. 2 Schematic of DL-MPC<sup>[34]</sup>

作用过程中的光谱学测量。在少周期激光脉冲产生过程中,需要将脉冲压缩至接近傅里叶变换极限脉宽。基于光纤非线性现象的脉冲整形已成为一种对光信号的光谱和时间特性进行定制的重要工具,可以产生抛物线、三角形和矩形等各种光学波形的超短脉冲<sup>[35-40]</sup>。然而,为实现所需的脉冲特性而明确非线性激光系统的最佳参数十分困难。对于光纤激光器,非线性频谱整形既取决于输入脉冲条件,又取决于光纤特性。通常遗传算法可解决非线性优化问题,能优化特定波段的光谱强度<sup>[41]</sup>或明确入射超短脉冲<sup>[42]</sup>的光谱相位,也可优化光纤的色散和非线性系数,从而最大限度地拓宽中红外相干超连续谱的带宽<sup>[43]</sup>。然而,遗传算法需要大量的计算时间,遍历具有足够多可能模式的相空间才能找到解决方案。神经网络可以提取和优化由色散元件和非线性元件组成的脉冲整形系统的参数,生

成具有所需脉宽和啁啾特性的任意波形<sup>[44]</sup>。

Farfan 等<sup>[45]</sup>展示了自适应神经网络算法(aNN)控制脉冲整形器并加速脉冲优化的过程,如图 3(a)所示。在该算法中,神经网络构建促动器与信号强度之间关系的逆模型,以 1600 个目标强度值作为输入,输出相应的 39 个促动器值。该神经网络选择了三层结构,每层 400 个节点,外加 39 个节点的输出层,并选择了带反向传播的缩放共轭梯度下降法作为训练方法。在每次优化开始时,脉冲优化器算法加载这个训练好的神经网络并将其作为通用模型,通过在每次迭代中使用新数据进行额外的网络训练来完善模型。这种方法结合了批量训练和在线训练,aNN 能够基于存储的通用模型和关于当前行为的新存储数据,从一个更有利的起点开始,动态地适应系统响应,从而平衡泛化能力和准确性。aNN 按照图 3(a)所示的顺序进行迭

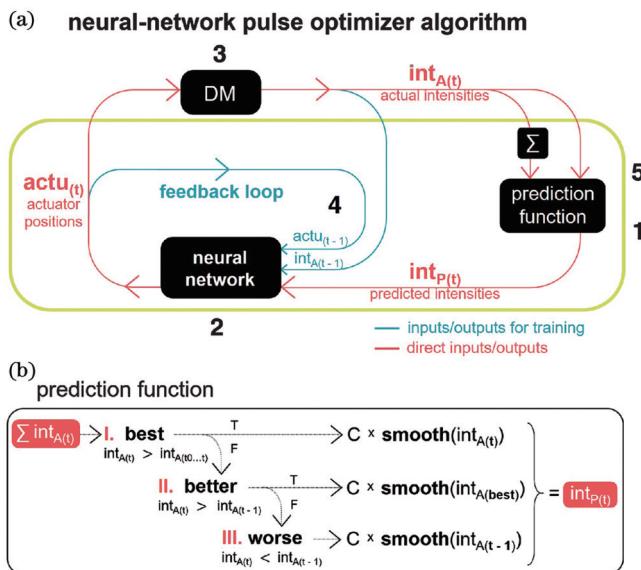


图 3 自适应神经网络算法示意图<sup>[45]</sup>。(a) aNNA 的迭代步骤;  
(b) 预测函数

Fig. 3 Schematic of adaptive neural network algorithm<sup>[45]</sup>.

(a) aNNA iteration sequence; (b) prediction function

代:1)来自非谐振响应信号的400个二进制强度值被发送给算法,由预测函数进行处理,生成理想目标信号;2)以目标信号作为神经网络的输入,神经网络输出促动器位置,即期望到达的目标位置;3)该算法通过控制选定的促动器、调节可变形反射镜(DM)来调制入射激光脉冲,激光脉冲与样品相互作用,产生新的非谐振响应信号以控制系统;4)网络接收新的信号强度,反馈对应的促动器位置,并将其作为新的数据点进行训练;5)得到的信号也成为下一个迭代的输入,用于预测下一个目标信号。评估的结果指定了“预测函数”,如图3(b)所示,该函数旨在为下一次选择生成理想的目标信号。预测函数规则如下:1)如果新的信号是最好的信号,则根据新的信号生成目标信号;2)如果信号不是最优的,但优于前一信号,则由前一最优信号(由算法存储)生成目标信号;3)如果新信号比前一个信号差,则使用前一个信号来生成目标信号。利用该算法对所选实验信号进行放大和平滑处理,以优化信号质量。与传统的优化算法相比,NNA可以加速脉冲压缩,其收敛速度比传统的遗传算法快100倍<sup>[45]</sup>,从而提高了超快光谱实验的实际效率。

### 3 超快光学实验数据的处理

对超快光学实验产生的数据进行处理是一项极具挑战性的工作。传统的数据处理需要过滤噪声的影响,求解含时薛定谔方程或使用迭代算法,这个过程非常繁琐并且极其耗时。机器学习中的神经网络基于严格的数学,事实上,通用逼近定理<sup>[46-48]</sup>表明,具有线性输出层和足够数量隐藏单元的神经网络能够学习任何阿贝尔函数。因此神经网络在超快光学实验数据的处

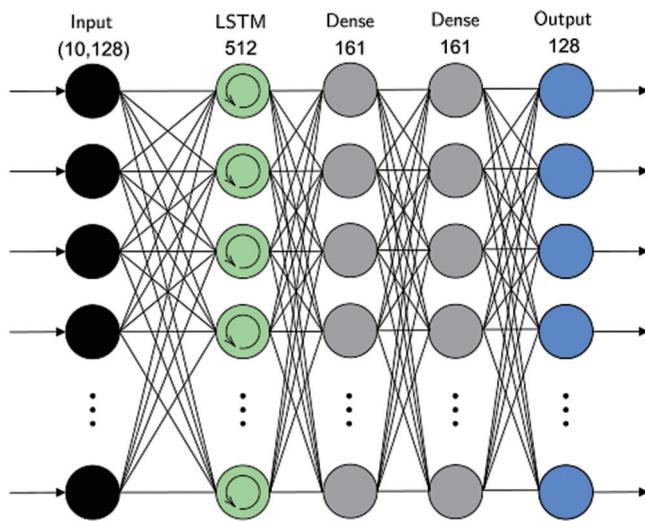
理中有着广泛的应用,可以处理含有噪声的实验数据<sup>[49]</sup>,或从实验数据中提取信息<sup>[50]</sup>。神经网络为高效分析和处理超快实验数据提供了一种与物理原理结合的新方法。

#### 3.1 超快激光传播动力学

超快激光的传播动力学现象很难理解和预测,这主要是由于在传播介质<sup>[51]</sup>中会出现复杂的非线性效应,如克尔效应<sup>[52]</sup>和电离效应<sup>[53-54]</sup>等。脉冲在介质中的传播通常采用非线性薛定谔方程(NLSE)来模拟,该方程没有精确的解析解。而当利用数值方法模拟时,在保证精度的情况下,需要花费大量的时间,因此可以使用神经网络来处理这些问题。

Gautam 等<sup>[55]</sup>详细比较了6种不同的神经网络,即全连接神经网络、级联神经网络(CaNN)、卷积神经网络、长短期记忆网络(LSTM)、双向 LSTM(BiLSTM)和门控循环单元(GRU),通过评估网络性能来确定各个网络最合适的选择,以实现对 NLSE 的映射。结果表明,在准确性、计算成本和训练速度方面,FCNN 的性能优于其他所有网络结构。与 FCNN 相比,CNN 感受野更小,权值共享给训练数据施加了移位不变性的约束,因此 CNN 学习前向映射的能力比 FCNN 差。另一方面,与 FCNN 相比,RNN(LSTM、BiLSTM 和 GRU)的参数共享机制对数学方程性能的学习没有积极的影响,而 CaNN 有更多的连接数量,其额外的复杂性增加了计算成本。此外,利用训练后的网络还可以预测色散和非线性参数以及重建高非线性光纤传播产生的畸变传输脉冲的时域面貌。Liu 等<sup>[56]</sup>基于多层感知器(MLP),采用预分类方案对直接轨迹和分散轨迹的数据进行分类,实现了强场物理中费曼路径积分的计算。这种方法克服了现有方法固有的蛮力计算的缺点,获得了强场物理中隐藏的物理信息,为阿秒测量中超快电子动力学现象的探索提供了一种有力的手段。

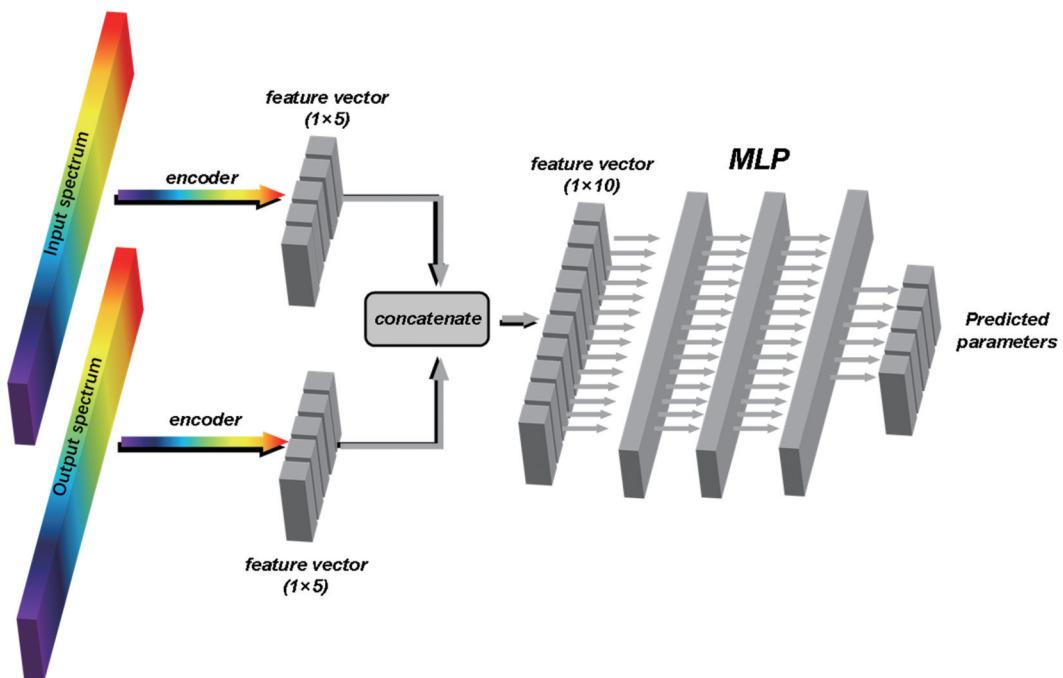
研究非线性脉冲传播动力学中的时间依赖性非常重要,其中特定时刻或特定传播距离的时域和频域强度剖面取决于早期传播过程<sup>[57]</sup>。具有长短期记忆单元结构的递归神经网络绕过了控制传播模型的直接数值求解,有可能在高阶孤子压缩和超连续谱产生等诸多场景中准确预测超短脉冲的非线性传播动力学现象<sup>[58]</sup>。除了这些单一目标的非线性传播动力学研究外,递归神经网络在光纤激光器的复杂多目标非线性传播动力学现象预测方面也有显著的潜力<sup>[59]</sup>。2022年,Martins 等<sup>[60]</sup>使用两种 RNN 来模拟光脉冲在高度非线性单模光纤中的传播问题,LSTM 和 CLSTM 网络都给出了低误差结果,其中 LSTM 误差更小(图 4)。结果表明,所提出的两种 RNN 可以预测光脉冲的传播,LSTM 能够以最小的误差模拟初始脉冲参数和光纤长度对脉冲形状的影响。这项研究有助于更好地理解构建用于非线性光脉冲传播建模的 RNN,以及分析峰值功率和非线性对预测误差的影响。

图 4 LSTM 结构示意图<sup>[60]</sup>Fig. 4 Schematic of LSTM architecture<sup>[60]</sup>

脉冲在具有正常群速度色散的光纤中传播时非线性过程通常对初始脉冲条件敏感,因此可以通过控制初始脉冲的时域波形和相位,将常规激光脉冲非线性地塑造成特定波形<sup>[35]</sup>。然而,由于所涉及的自由度通常很广,预测非线性脉冲成形行为可能需要大量计算,特别是在处理逆问题时。Boscolo 等<sup>[61]</sup>使用基于神经网络的监督学习模型来预测脉冲在具有正常和反常色散的光纤中非线性传播时的时域和频域强度分布。所采用的基于贝叶斯正则化反向传播算法的前馈神经网络包括三个隐藏层,每个隐藏层有 14 个神经元。对于大部分脉冲形状,神经网络算法的预测结果与 NLSE 传播模型的结果一致。该网络能够再现脉冲在正常色

散区传播时的时频分布。通过对输出进行变形采样,该网络还能够解析在反常色散下传播的时域脉冲的压缩细节及其更复杂的频谱结构;经过适当训练后网络能从脉冲形状和频谱中检索出传播长度、孤子阶数以及光纤的色散状态。

获得足够的光谱宽度是产生少周期脉冲的重要步骤。常用的光谱展宽方式包括空心光纤展宽和薄片组展宽等<sup>[15, 62-68]</sup>,展宽效果取决于光在介质中的传播动力学过程。在薄片组展宽超连续光谱产生过程中,不同的入射脉冲参数会导致不同的光谱展宽结果。例如,当提高脉冲能量或减小脉冲宽度时,随着激光强度的增大,输出频谱从原始的高斯分布的对称展宽逐步变为不对称展宽。因此,通过引入非线性积分对光谱展宽情况进行分析,进而可以对不同光谱展宽阶段进行界定。B 积分和 P 积分<sup>[69-70]</sup>能够定量反映脉冲传播过程中的克尔效应强度与电离强度,在解析脉冲与介质相互作用的物理现象方面得到广泛的应用,并且能够作为一种参量用于分析、量化和优化光谱展宽过程,以获得优质的少周期脉冲光源。然而,若要通过非线性积分实时调控少周期脉冲的产生,需要在实验中实时获得积分值。因此 Gao 等<sup>[70]</sup>提出了基于多层感知器(MLP)网络的非线性积分预测,如图 5 所示。它利用无监督学习的编码器将一维光谱数据编码成  $1 \times 5$  的特征矩阵,并将其导入主 MLP 网络中,可输出初始脉冲能量、光斑半径、脉宽及 B 积分和 P 积分的值。将数值模拟结果应用到神经网络的训练中,预测结果很好。这不仅为实时表征输入脉冲参数提供了一种新方法,而且为超连续谱产生过程的优化提供了指导。

图 5 MLP 神经网络结构模型<sup>[70]</sup>Fig. 5 Structure model of MLP neural network<sup>[70]</sup>

### 3.2 超快脉冲信息提取

超快光学中脉冲信息的测量对于激光参数的优化以及后续实验的开展至关重要。但超短脉冲宽度在实验上很难直接测量,通常需要设计复杂的光学测量系统,以自相关或者互相关的方式间接测量,并利用反演算法从测量结果中提取脉冲信息。虽然基于 NLSE 的模型或基于强场近似的简化模型通常能够在一定程度上再现实验测量结果,但其逆过程没有数学解析式。表征超短脉冲的一种流行技术是频率分辨光学开关(FROG)<sup>[71]</sup>,它通过创建一个二维强度图(称为 FROG 行迹图),可完全表征超短光脉冲的振幅和相位。基于 FROG 行迹图重建脉冲需要利用反演算法,比如基于广义投影算法的 PCGPA、LSGPA 等,这类算法的计算非常耗时<sup>[72-73]</sup>。此外,遗传算法也被成功地应用于 FROG 行迹图的检索<sup>[74-75]</sup>,但检索时间仍然需要数分钟。

近年来,在相干成像、散射介质成像和超分辨率成像<sup>[76-80]</sup>等领域中,深度神经网络被用于解决此类逆问题,其在脉冲重建方面也显示出不错的应用前景。利用神经网络在 FROG 行迹图中重建短脉冲的第一次尝试可以追溯到 20 世纪 90 年代中期<sup>[81]</sup>。2018 年,Zahavy 等<sup>[82]</sup>通过使用深度神经网络(DNN),从理论和实验上演示了超短光脉冲的重建,数值模拟结果表明,训练过的网络在低信噪比测量方面优于其他先进的技术。这个算法被称为 DeepFROG,如图 6 所示,它由两

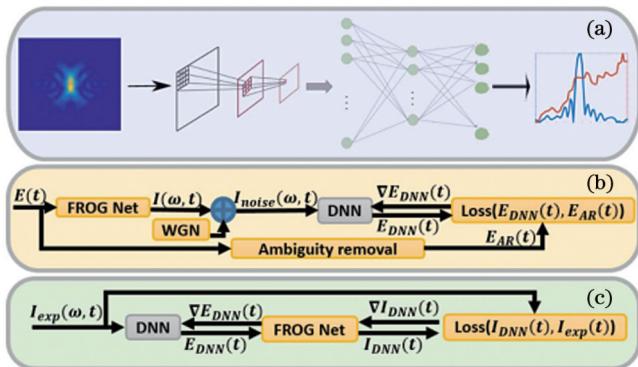


图 6 DeepFROG 结构示意图<sup>[82]</sup>。(a) 将 FROG 轨迹映射为脉冲的 DNN 架构;(b) 监督培训程序;(c) 无监督的培训程序

Fig. 6 Schematics of DeepFROG architecture<sup>[82]</sup>. (a) DNN architecture for mapping FROG traces into complex pulses; (b) supervised training procedure; (c) unsupervised training procedure

个网络组成,通过差分编程软件实现。第一个神经网络是 FROGNet,是理论公式支配的测量系统,它使用差分构建块,可提供测量系统及其梯度的有效评估。第二个网络是 CNN,它接收 FROG 行迹图并输出重建脉冲的实部和虚部向量。权重经过优化后的 CNN 函数可以接近 FROGNet 函数的逆映射。2021 年,Xu 等<sup>[83]</sup>利用卷积神经网络对瞬态光栅(TG)-FROG 的行迹图进行了反演,结构如图 7 所示。其中 CNN 包括 4 个卷积层和 2 个神经元个数分别为 512 和 1024 的全连接层,基于模拟数据实现了对飞秒脉冲的重建。

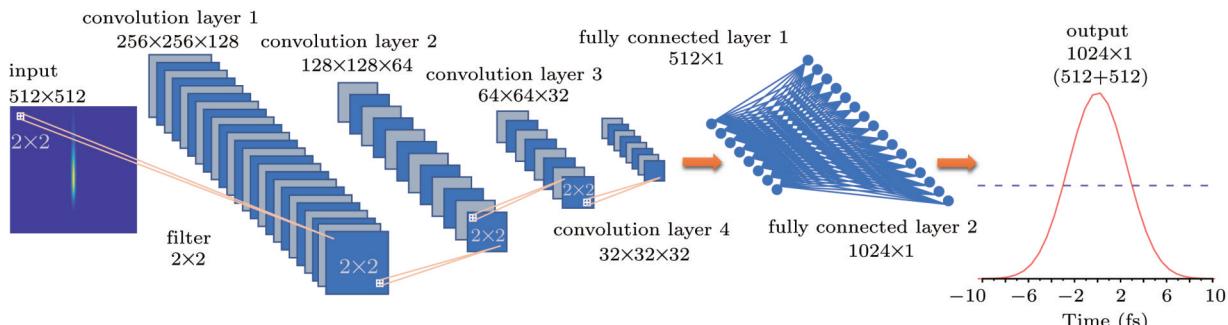


图 7 CNN 结构图<sup>[83]</sup>

Fig. 7 Structural diagram of CNN<sup>[83]</sup>

阿秒泵浦探测实验可以用来研究超短时间尺度下的电子动力学过程<sup>[84]</sup>。对阿秒脉冲的表征常用频率分辨光学开关(FROG-CRAB)方法<sup>[85]</sup>。它与 FROG 类似,是一种通过迭代实现的最小化算法,通过对测量得到的阿秒条纹行迹图进行反演计算来获取阿秒脉冲的光谱相位<sup>[85]</sup>。由于可以很容易地用光栅光谱仪测量脉冲的功率谱,一旦光谱相位已知,阿秒脉冲就可以完全表征。当将该方法应用于阿秒条纹时,需要采用中心动量近似(CMA),这降低了反演精度<sup>[86]</sup>。其他几种替代方法避免了这种近似<sup>[86-88]</sup>。2019 年,Yu 等<sup>[89]</sup>使用遗传算法,结合自相关算法,实现了阿秒脉冲的反演。然而,不管是遗传算法还是其他最小化方案,其计算过程

是相当耗时的。同年 White 等<sup>[90]</sup>提出利用神经网络从阿秒条纹图中提取相位的方法,不需要中心动量近似,通过监督学习和无监督学习可分别准确反演模拟计算得到的条纹行迹和实验测得的条纹行迹的相位。其主要优势在于一旦经过适当的训练,该方法可以在毫秒量级下基于条纹行迹图反演得到相位。次年 Zhu 等<sup>[91]</sup>提出了一种基于条件变分生成网络(CVGN)的脉冲反演算法。CVGN 根据给定的条纹行迹图对脉冲轮廓的分布进行建模,因此能够评估反演得到的脉冲的不确定性。如图 8 所示,当峰值信噪比大于 6 时,条纹图的脉冲重构一致性较高,为今后基于神经网络的阿秒脉冲反演提供了参考。此外,Brunner 等<sup>[92]</sup>也利用深度

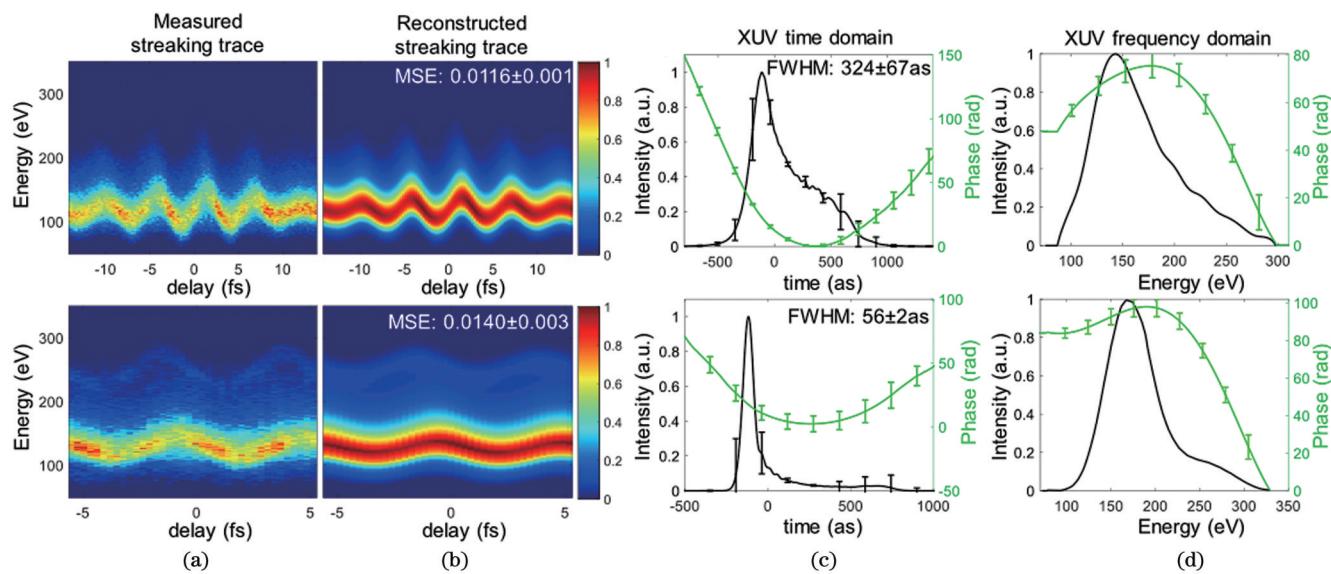


图 8 用 CVGN 检索两条实验测得的阿秒条纹<sup>[91]</sup>。(a)测量的阿秒条纹;(b)重建的阿秒条纹;反演得到的(c)时域和(d)频域的阿秒脉冲曲线

Fig. 8 Retrieval of two experimental attosecond streaking traces with CVGN<sup>[91]</sup>. (a) Measured attosecond streaking traces; (b) reconstructed attosecond streaking traces; retrieved attosecond pulse curves in (c) time and (d) frequency domains

神经网络,基于阿秒条纹图中的一条或多条轨迹完全重建了近红外矢量势和电子波包,同时将计算时间缩短了几个数量级。

### 3.3 神经网络应用在复杂系统

机器学习中的神经网络技术可以应用到更复杂的超快系统中,例如多维系统和混沌系统。Teğin 等<sup>[93]</sup>使用深度神经网络分析了多模光纤中的多维系统属性,研究了泵浦脉冲的输入空间光束轮廓与多模光纤输出光谱之间的关系。Comin 等<sup>[94]</sup>将神经网络与遗传算法相结合,通过控制激光脉冲整形来操纵等离子体纳米天线近场,实现了等离子体纳米天线中二次谐波热点切换。神经网络在异常波和极端事件触发的相干呼吸结构测量中也有重要应用<sup>[95-96]</sup>。

### 3.4 物理规律参与的数据发掘

物理、生物或工程系统获得的数据量有时不够充分,得出结论和作出决策面临挑战。在这种小数据体系下,许多机器学习技术缺乏鲁棒性,无法提供任何收敛保证。为了训练神经网络在少量输入和输出数据中准确识别非线性映射,将其中原则性物理定律、经验验证的规则及相关领域的专业知识作为先验知识进行正则化处理,并编码到学习算法中,通过放大算法所获得的数据信息,能够将解的空间限制在可管理的区域内。目前已经有一些研究利用结构化先验信息来构建物理规律参与的效率更高的学习机器<sup>[97-102]</sup>。Raissi 等<sup>[98]</sup>利用机器学习中的神经网络,基于零散数据,发现了由偏微分方程表示的物理世界的封闭数学模型,即利用“物理信息神经网络”分析动态数据样本,自动识别控制物理系统的封闭数学模型或非线性微分方程。此外,Raissi 等<sup>[103]</sup>还使用深度神经网络直接处理非线性问

题,利用自动微分基于输入坐标和模型参数区分神经网络,以构建可以获得物理信息的神经网络。总之这种规律、经验和神经网络的集成成为模型构建、预测建模、非线性控制和强化学习策略的方法引入了一种潜在的变革性技术,将推动物理知识学习机的发展。

## 4 展望与挑战

超快光学系统通常是复杂的、非线性的和多维的,其动力学现象对内部参数和外部扰动都非常敏感。这些系统的设计和优化通常基于物理模型、数值模拟和试错。随着系统复杂性的增加,这些方法逐渐无法满足要求。迄今为止,机器学习在超快光学领域中的应用大多基于遗传算法或前馈架构。虽然这些应用带来了开创性的成果,但仍有一些重要的方法尚未被充分利用。神经网络的优点是经过训练后可以在没有人为干预的情况下执行所有的计算,这为神经网络技术在具有更高自由度的更复杂系统中的应用提供了可能。

神经网络在处理超快光学系统问题方面仍有发展的潜力。一方面,计算机硬件算力提升,可以高效地处理海量数据,并支持更复杂的神经网络。另一方面,算法的进步也使得神经网络能处理更复杂的问题。神经网络与遗传算法的结合或者不同类型神经网络的组合可以共同发挥机器学习的潜力,在理解和优化非线性系统方面取得更多进展。此外,无监督学习在没有标记的情况下可推断和揭示数据集中隐藏的内部结构,这对实验数据处理有重要意义。然而,目前神经网络在超快光学中的应用也存在挑战和不足。首先,神经网络是一种数学计算工具,缺乏对其物理意义的解释,虽然目前已有一些工作将物理规律融入算法中,但基于训

练收敛的结果直观得到其中的物理规律仍然面临巨大挑战, 基于海量数据提取并总结出解析形式或者概念性的物理规律是神经网络和人工智能下一步研究方向之一。其次, 神经网络的训练结果严重依赖于训练数据的数量和质量, 但是物理实验室中的实验条件通常只能提供有限的数据, 虽然可以通过理论仿真得到训练数据, 但仿真计算所能提供的数据有限, 且缺少实验环境下的噪声和扰动, 算法的泛化性和鲁棒性受到挑战, 因此在降低对数据量依赖的同时提高神经网络训练过程的有效性也是下一步研究方向之一。此外, 处理不同问题时需要设计不同的神经网络, 但神经网络的参数选择往往是根据训练结果进行调试和迭代, 其过程具有经验依赖性和不确定性, 这增加了使用难度和成本。

机器学习中的神经网络在超快光学中有着广泛的应用, 相关成果层出不穷。随着神经网络算法的进步和超快光学技术的发展, 超快光学研究将向着更智能、更方便、更自动化、能够更准确揭示物理规律的方向发展。

## 参 考 文 献

- [1] Silver D, Schrittwieser J, Simonyan K, et al. Mastering the game of go without human knowledge[J]. *Nature*, 2017, 550(7676): 354-359.
- [2] Brown T B, Mann B, Ryder N, et al. Language models are few-shot learners[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems, December 6-12, 2020, Vancouver, BC, Canada. New York: ACM Press, 2020: 1877-1901.
- [3] Sugioka K, Cheng Y. Ultrafast lasers: reliable tools for advanced materials processing[J]. *Light: Science & Applications*, 2014, 3 (4): e149.
- [4] Fermann M E, Galvanauskas A, Sucha G. Ultrafast lasers: technology and applications[M]. Boston: CRC Press, 2002.
- [5] Sibbett W, Lagatsky A A, Brown C T A. The development and application of femtosecond laser systems[J]. *Optics Express*, 2012, 20(7): 6989-7001.
- [6] Xu C, Wise F W. Recent advances in fibre lasers for nonlinear microscopy[J]. *Nature Photonics*, 2013, 7(11): 875-882.
- [7] Udem T, Holzwarth R, Hänsch T W. Optical frequency metrology [J]. *Nature*, 2002, 416(6877): 233-237.
- [8] Jones D J, Diddams S A, Ranka J K, et al. Carrier-envelope phase control of femtosecond mode-locked lasers and direct optical frequency synthesis[J]. *Science*, 2000, 288(5466): 635-640.
- [9] Reichert J, Holzwarth R, Udem T, et al. Measuring the frequency of light with mode-locked lasers[J]. *Optics Communications*, 1999, 172(1/2/3/4/5/6): 59-68.
- [10] Diddams S A, Jones D J, Ye J, et al. Direct link between microwave and optical frequencies with a 300 THz femtosecond laser comb[J]. *Physical Review Letters*, 2000, 84(22): 5102-5105.
- [11] Bloom B J, Nicholson T L, Williams J R, et al. An optical lattice clock with accuracy and stability at the 10-18 level[J]. *Nature*, 2014, 506(7486): 71-75.
- [12] Nemitz N, Ohkubo T, Takamoto M, et al. Frequency ratio of Yb and Sr clocks with  $5 \times 10^{-17}$  uncertainty at 150 seconds averaging time[J]. *Nature Photonics*, 2016, 10(4): 258-261.
- [13] Ghelfi P, Laghezza F, Scotti F, et al. A fully photonics-based coherent radar system[J]. *Nature*, 2014, 507(7492): 341-345.
- [14] Khilo A, Spector S J, Grein M E, et al. Photonic ADC: overcoming the bottleneck of electronic jitter[J]. *Optics Express*, 2012, 20(4): 4454-4469.
- [15] He P, Liu Y Y, Zhao K, et al. High-efficiency supercontinuum generation in solid thin plates at 0.1 TW level[J]. *Optics Letters*, 2017, 42(3): 474-477.
- [16] Chini M, Zhao K, Chang Z H. The generation, characterization and applications of broadband isolated attosecond pulses[J]. *Nature Photonics*, 2014, 8(3): 178-186.
- [17] Lee J, Kim Y J, Lee K, et al. Time-of-flight measurement with femtosecond light pulses[J]. *Nature Photonics*, 2010, 4(10): 716-720.
- [18] Coddington I, Swann W C, Nenadovic L, et al. Rapid and precise absolute distance measurements at long range[J]. *Nature Photonics*, 2009, 3(6): 351-356.
- [19] Li C H, Benedict A J, Fendel P, et al. A laser frequency comb that enables radial velocity measurements with a precision of  $1 \text{ cm s}^{-1}$ [J]. *Nature*, 2008, 452(7187): 610-612.
- [20] Steinmetz T, Wilken T, Araujo-Hauck C, et al. Laser frequency combs for astronomical observations[J]. *Science*, 2008, 321(5894): 1335-1337.
- [21] Scherer N F, Knee J L, Smith D D, et al. Femtosecond photofragment spectroscopy: the reaction  $\text{ICN} \rightarrow \text{CN} + \text{I}$ [J]. *The Journal of Physical Chemistry*, 1985, 89(24): 5141-5143.
- [22] Zewail A H. Laser femtochemistry[J]. *Science*, 1988, 242(4886): 1645-1653.
- [23] Richardson D J, Nilsson J, Clarkson W A. High power fiber lasers: current status and future perspectives[J]. *Journal of the Optical Society of America B*, 2010, 27(11): B63-B92.
- [24] Fermann M E, Hartl I. Ultrafast fibre lasers[J]. *Nature Photonics*, 2013, 7(11): 868-874.
- [25] Pu G Q, Yi L L, Zhang L, et al. Intelligent control of mode-locked femtosecond pulses by time-stretch-assisted real-time spectral analysis[J]. *Light: Science & Applications*, 2020, 9: 13.
- [26] Winters D G, Kirchner M S, Backus S J, et al. Electronic initiation and optimization of nonlinear polarization evolution mode-locking in a fiber laser[J]. *Optics Express*, 2017, 25(26): 33216-33225.
- [27] Woodward R I, Kelleher E J R. Genetic algorithm-based control of birefringent filtering for self-tuning, self-pulsing fiber lasers[J]. *Optics Letters*, 2017, 42(15): 2952-2955.
- [28] Pu G Q, Yi L L, Zhang L, et al. Genetic algorithm-based fast real-time automatic mode-locked fiber laser[J]. *IEEE Photonics Technology Letters*, 2020, 32(1): 7-10.
- [29] Woodward R I, Kelleher E J R. Towards ‘smart lasers’: self-optimisation of an ultrafast pulse source using a genetic algorithm [J]. *Scientific Reports*, 2016, 6: 37616.
- [30] Andral U, Fodil R S, Amrani F, et al. Fiber laser mode locked through an evolutionary algorithm[J]. *Optica*, 2015, 2(4): 275-278.
- [31] Andral U, Buguet J, Si Fodil R, et al. Toward an autosetting mode-locked fiber laser cavity[J]. *Journal of the Optical Society of America B*, 2016, 33(5): 825-833.
- [32] Pu G Q, Yi L L, Zhang L, et al. Intelligent programmable mode-locked fiber laser with a human-like algorithm[J]. *Optica*, 2019, 6 (3): 362-369.
- [33] Kokhanovskiy A, Bednyakova A, Kuprikov E, et al. Machine learning-based pulse characterization in figure-eight mode-locked lasers[J]. *Optics Letters*, 2019, 44(13): 3410-3413.
- [34] Baumeister T, Brunton S L, Kutz J N. Deep learning and model predictive control for self-tuning mode-locked lasers[J]. *Journal of the Optical Society of America B*, 2018, 35(3): 617-626.
- [35] Boscolo S, Finot C. Shaping light in nonlinear optical fibers[M]. Hoboken: John Wiley & Sons, Inc., 2017.
- [36] Hammani K, Kibler B, Fatome J, et al. Nonlinear spectral shaping and optical rogue events in fiber-based systems[J]. *Optical Fiber Technology*, 2012, 18(5): 248-256.
- [37] Mollenauer L F, Stolen R H, Gordon J P. Experimental observation of picosecond pulse narrowing and solitons in optical

- fibers[J]. Physical Review Letters, 1980, 45(13): 1095-1098.
- [38] Finot C, Dudley J M, Kibler B, et al. Optical parabolic pulse generation and applications[J]. IEEE Journal of Quantum Electronics, 2009, 45(11): 1482-1489.
- [39] Boscolo S, Latkin A I, Turitsyn S K. Passive nonlinear pulse shaping in normally dispersive fiber systems[J]. IEEE Journal of Quantum Electronics, 2008, 44(12): 1196-1203.
- [40] Kutuzyan A A, Mansuryan T G, Esayan G L, et al. Dispersive regime of spectral compression[J]. Quantum Electronics, 2008, 38(4): 383-387.
- [41] Wetzel B, Kues M, Roztocki P, et al. Customizing supercontinuum generation via on-chip adaptive temporal pulse-splitting[J]. Nature Communications, 2018, 9: 4884.
- [42] Michaeli L, Bahabad A. Genetic algorithm driven spectral shaping of supercontinuum radiation in a photonic crystal fiber[J]. Journal of Optics, 2018, 20(5): 055501.
- [43] Zhang W Q, Shahraam A V, Monro T M. A genetic algorithm based approach to fiber design for high coherence and large bandwidth supercontinuum generation[J]. Optics Express, 2009, 17(21): 19311-19327.
- [44] Finot C, Gukov I, Hammami K, et al. Nonlinear sculpturing of optical pulses with normally dispersive fiber-based devices[J]. Optical Fiber Technology, 2018, 45: 306-312.
- [45] Farfan C A, Epstein J, Turner D B. Femtosecond pulse compression using a neural-network algorithm[J]. Optics Letters, 2018, 43(20): 5166-5169.
- [46] Cybenko G. Approximation by superpositions of a sigmoidal function[J]. Mathematics of Control, Signals and Systems, 1989, 2(4): 303-314.
- [47] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators[J]. Neural Networks, 1989, 2(5): 359-366.
- [48] Hornik K, Stinchcombe M, White H. Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks[J]. Neural Networks, 1990, 3(5): 551-560.
- [49] Giri S K, Saalmann U, Rost J M. Purifying electron spectra from noisy pulses with machine learning using synthetic Hamilton matrices[J]. Physical Review Letters, 2020, 124(11): 113201.
- [50] Shvetsov-Shilovski N I, Lein M. Deep learning for retrieval of the internuclear distance in a molecule from interference patterns in photoelectron momentum distributions[J]. Physical Review A, 2022, 105(2): L021102.
- [51] Oliari V, Goossens S, Häger C, et al. Revisiting efficient multi-step nonlinearity compensation with machine learning: an experimental demonstration[J]. Journal of Lightwave Technology, 2020, 38(12): 3114-3124.
- [52] Essiambre R J, Kramer G, Winzer P J, et al. Capacity limits of optical fiber networks[J]. Journal of Lightwave Technology, 2010, 28(4): 662-701.
- [53] Cerullo G, De Silvestri S. Ultrafast optical parametric amplifiers[J]. Review of Scientific Instruments, 2003, 74(1): 1-18.
- [54] Agostini P, Breger P, L' Huillier A, et al. Giant stark shifts in multiphoton ionization[J]. Physical Review Letters, 1989, 63(20): 2208-2211.
- [55] Gautam N, Choudhary A, Lall B. Comparative study of neural network architectures for modelling nonlinear optical pulse propagation[J]. Optical Fiber Technology, 2021, 64: 102540.
- [56] Liu X W, Zhang G J, Li J E, et al. Deep learning for feynman's path integral in strong-field time-dependent dynamics[J]. Physical Review Letters, 2020, 124(11): 113202.
- [57] Genty G, Salmela L, Dudley J M, et al. Machine learning and applications in ultrafast photonics[J]. Nature Photonics, 2021, 15(2): 91-101.
- [58] Salmela L, Tsipinakis N, Foi A, et al. Predicting ultrafast nonlinear dynamics in fibre optics with a recurrent neural network[J]. Nature Machine Intelligence, 2021, 3(4): 344-354.
- [59] Tikan A, Bielawski S, Szwaj C, et al. Single-shot measurement of phase and amplitude by using a heterodyne time-lens system and ultrafast digital time-holography[J]. Nature Photonics, 2018, 12(4): 228-234.
- [60] Martins G R, Silva L C B, Segatto M E V, et al. Design and analysis of recurrent neural networks for ultrafast optical pulse nonlinear propagation[J]. Optics Letters, 2022, 47(21): 5489-5492.
- [61] Boscolo S, Finot C. Artificial neural networks for nonlinear pulse shaping in optical fibers[J]. Optics & Laser Technology, 2020, 131: 106439.
- [62] Nisoli M, De Silvestri S, Svelto O. Generation of high energy 10 fs pulses by a new pulse compression technique[J]. Applied Physics Letters, 1996, 68(20): 2793-2795.
- [63] Matsubara E, Yamane K, Sekikawa T, et al. Generation of 2.6 fs optical pulses using induced-phase modulation in a gas-filled hollow fiber[J]. Journal of the Optical Society of America B, 2007, 24(4): 985-989.
- [64] Wirth A, Hassan M T, Grgurăš I, et al. Synthesized light transients[J]. Science, 2011, 334(6053): 195-200.
- [65] Suda A, Hatayama M, Nagasaka K, et al. Generation of sub-10-fs, 5-mJ-optical pulses using a hollow fiber with a pressure gradient[J]. Applied Physics Letters, 2005, 86(11): 111116.
- [66] Bohman S, Suda A, Kanai T, et al. Generation of 5.0 fs, 5.0 mJ pulses at 1 kHz using hollow-fiber pulse compression[J]. Optics Letters, 2010, 35(11): 1887-1889.
- [67] Voronin A A, Zheltikov A M, Ditmire T, et al. Subexawatt few-cycle lightwave generation via multipetawatt pulse compression[J]. Optics Communications, 2013, 291: 299-303.
- [68] Lu C H, Tsou Y J, Chen H Y, et al. Generation of intense supercontinuum in condensed media[J]. Optica, 2014, 1(6): 400-406.
- [69] Perry M D, Ditmire T, Stuart B C. Self-phase modulation in chirped-pulse amplification[J]. Optics Letters, 1994, 19(24): 2149-2151.
- [70] Gao Y T, Wang X Z, Zhu X X, et al. Quantification and analysis of the nonlinear effects in spectral broadening through solid medium of femtosecond pulses by neural network[J]. Physical Review Research, 2022, 4(1): 013035.
- [71] Trebino R. Frequency-resolved optical gating: the measurement of ultrashort laser pulses[M]. Boston: Springer, 2000.
- [72] Gagnon J, Goulielmakis E, Yakovlev V S. The accurate FROG characterization of attosecond pulses from streaking measurements [J]. Applied Physics B, 2008, 92(1): 25-32.
- [73] Kane D J. Principal components generalized projections: a review [J]. Journal of the Optical Society of America B, 2008, 25(6): A120-A132.
- [74] Nicholson J W, Omenetto F G, Funk D J, et al. Evolving FROGS: phase retrieval from frequency-resolved optical gating measurements by use of genetic algorithms[J]. Optics Letters, 1999, 24(7): 490-492.
- [75] Shu S F. Evolving ultrafast laser information by a learning genetic algorithm combined with a knowledge base[J]. IEEE Photonics Technology Letters, 2006, 18(2): 379-381.
- [76] Kamilov U S, Papadopoulos I N, Shoreh M H, et al. Learning approach to optical tomography[J]. Optica, 2015, 2(6): 517-522.
- [77] Rivenson Y, Wu Y C, Ozcan A. Deep learning in holography and coherent imaging[J]. Light: Science & Applications, 2019, 8: 85.
- [78] Borhani N, Kakkava E, Moser C, et al. Learning to see through multimode fibers[J]. Optica, 2018, 5(8): 960-966.
- [79] Li Y Z, Xue Y J, Tian L. Deep speckle correlation: a deep learning approach toward scalable imaging through scattering media [J]. Optica, 2018, 5(10): 1181-1190.
- [80] Liu T R, de Haan K, Rivenson Y, et al. Deep learning-based super-resolution in coherent imaging systems[J]. Scientific Reports, 2019, 9: 3926.
- [81] Krumbügel M A, Ladera C L, DeLong K W, et al. Direct ultrashort-pulse intensity and phase retrieval by frequency-resolved optical gating and a computational neural network[J]. Optics

- Letters, 1996, 21(2): 143-145.
- [82] Zahavy T, Dikopoltsev A, Moss D, et al. Deep learning reconstruction of ultrashort pulses[J]. Optica, 2018, 5(5): 666-673.
- [83] Xu S Y, Zhu X X, Wang J, et al. Convolutional neural network for transient grating frequency-resolved optical gating trace retrieval and its algorithm optimization[J]. Chinese Physics B, 2021, 30(4): 048402.
- [84] Leone S R, McCurdy C W, Burgdörfer J, et al. What will it take to observe processes in ‘real time’?[J]. Nature Photonics, 2014, 8 (3): 162-166.
- [85] Mairesse Y, Quéré F. Frequency-resolved optical gating for complete reconstruction of attosecond bursts[J]. Physical Review A, 2005, 71(1): 011401.
- [86] Chini M, Gilbertson S, Khan S D, et al. Characterizing ultrabroadband attosecond lasers[J]. Optics Express, 2010, 18(12): 13006-13016.
- [87] Zhao X, Wei H, Wu Y, et al. Phase-retrieval algorithm for the characterization of broadband single attosecond pulses[J]. Physical Review A, 2017, 95(4): 043407.
- [88] Keathley P D, Bhardwaj S, Moses J, et al. Volkov transform generalized projection algorithm for attosecond pulse characterization[J]. New Journal of Physics, 2016, 18(7): 073009.
- [89] Yu W W, Zhao X, Wei H, et al. Method for spectral phase retrieval of single attosecond pulses utilizing the autocorrelation of photoelectron streaking spectra[J]. Physical Review A, 2019, 99 (3): 033403.
- [90] White J, Chang Z H. Attosecond streaking phase retrieval with neural network[J]. Optics Express, 2019, 27(4): 4799-4807.
- [91] Zhu Z Y, White J, Chang Z H, et al. Attosecond pulse retrieval from noisy streaking traces with conditional variational generative network[J]. Scientific Reports, 2020, 10: 5782.
- [92] Brunner C, Duensing A, Schröder C, et al. Deep learning in attosecond metrology[J]. Optics Express, 2022, 30(9): 15669-15684.
- [93] Tegin U, Rahmani B, Kakkava E, et al. Controlling spatiotemporal nonlinearities in multimode fibers with deep neural networks[J]. APL Photonics, 2020, 5(3): 030804.
- [94] Comin A, Hartschuh A. Efficient optimization of SHG hotspot switching in plasmonic nanoantennas using phase-shaped laser pulses controlled by neural networks[J]. Optics Express, 2018, 26 (26): 33678-33686.
- [95] Dudley J M, Genty G, Mussot A, et al. Rogue waves and analogies in optics and oceanography[J]. Nature Reviews Physics, 2019, 1(11): 675-689.
- [96] Närhi M, Salmela L, Toivonen J, et al. Machine learning analysis of extreme events in optical fibre modulation instability[J]. Nature Communications, 2018, 9: 4923.
- [97] Raissi M, Perdikaris P, Karniadakis G E. Inferring solutions of differential equations using noisy multi-fidelity data[J]. Journal of Computational Physics, 2017, 335: 736-746.
- [98] Raissi M, Karniadakis G E. Hidden physics models: machine learning of nonlinear partial differential equations[J]. Journal of Computational Physics, 2018, 357: 125-141.
- [99] Owhadi H. Bayesian numerical homogenization[J]. Multiscale Modeling & Simulation, 2015, 13(3): 812-828.
- [100] Raissi M, Perdikaris P, Karniadakis G E. Numerical Gaussian processes for time-dependent and nonlinear partial differential equations[J]. SIAM Journal on Scientific Computing, 2018, 40(1): A172-A198.
- [101] Owhadi H, Scovel C, Sullivan T. Brittleness of Bayesian inference under finite information in a continuous world[J]. Electronic Journal of Statistics, 2015, 9(1): 1-79.
- [102] Brunton S L, Proctor J L, Kutz J N. Discovering governing equations from data by sparse identification of nonlinear dynamical systems[J]. Proceedings of the National Academy of Sciences of the United States of America, 2016, 113(15): 3932-3937.
- [103] 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.

## Application of Neural Network in Ultrafast Optics

Zhu Xiaoxian<sup>1,2,3</sup>, Gao Yitan<sup>1,3</sup>, Wang Yiming<sup>1,2,3</sup>, Wang Ji<sup>3</sup>, Zhao Kun<sup>1,3\*</sup>, Wei Zhiyi<sup>1,2,3</sup>

<sup>1</sup>Beijing National Laboratory for Condensed Matter Physics, Institute of Physics, Chinese Academy of Sciences, Beijing 100190, China;

<sup>2</sup>University of Chinese Academy of Sciences, Beijing 100049, China;

<sup>3</sup>Songshan Lake Materials Laboratory, Dongguan 523808, Guangdong, China

### Abstract

**Significance** Machine learning is a specialized study on computer simulation and learning human behavior for obtaining new knowledge and skills and on reorganizing existing knowledge structure and skill to continuously improve performance. It is the core of artificial intelligence and the fundamental way of making computers intelligent. Machine learning is a multi-disciplinary subject, involving probability theory, statistics, approximation theory, convex analysis, and algorithm complexity theory. Its algorithm is widely used in many fields of engineering and science, and has advantages in terms of classification, pattern recognition, prediction, system parameter optimization, and building complex dynamic models from observations.

Ultrafast optical systems are usually complex, nonlinear, and multidimensional, and their dynamics are extremely sensitive to internal parameters and external disturbances. The design and optimization of these systems are generally based on physical models, numerical simulation, and trial and error approach. Owing to the increase in system complexity, these methods have reached their limits. Thus far, the application of machine learning in ultra-fast optics is mostly based on genetic algorithms or feedforward architecture. Although these implementations have undoubtedly brought significant results, there are still some limitations that need to be resolved. The machine learning neural network technology can find relationships among the state variables of the systems, which provides a new way to explore nonlinear dynamic systems without solving complex mathematical and physical equations. The generated nonlinear model can also be used to design and control laser characteristics. Pulse optimization in ultrafast experiments may involve multiple parameters, which are interrelated in complex ways. This is a field where neural networks can significantly surpass

other forms of manual or partial automatic control. In addition, it is extremely challenging to process the data generated by ultrafast optical experiments. Traditional data processing requires to filter out the influence of noise. Solving the time-dependent Schrödinger equation or using iterative algorithm makes the process extremely cumbersome and time-consuming. The neural network is based on the mathematics, and provides a new method combined with physical principles for efficient analysis and processing of ultrafast experimental data. Therefore, neural network has a good application prospect in the field of optics.

**Progress** This review highlights the application of neural networks in ultrafast optics. Neural network plays an active role in the self-tuning and coherent dynamics control of ultrafast fiber lasers. In the processing of ultrafast optical experimental data, neural networks are applied to the study of ultrafast laser propagation dynamics, measurement of ultrafast pulse information, calculation of complex systems, and data mining involving physical laws.

**Conclusions and Prospects** Neural network has high application potential in ultrafast optical systems. On the one hand, the computing power of computer hardware is improved, which can efficiently process massive data and support more complex neural networks. On the other hand, the improvement in algorithm enables neural networks deal with more complex problems. The combination of neural networks and genetic algorithms or different types of neural networks can jointly explore the potential of machine learning and make more progress in understanding and optimizing nonlinear systems. In addition, the ability of unsupervised learning to infer and reveal hidden internal structures from datasets without labels is extremely important for noise-sensitive experimental data processing. However, there are also challenges in the application of neural networks in ultrafast optics. First, as a mathematical computing tool, neural network lacks the physical meaning. Although there have been works to integrate physical laws into the algorithms, it is still a challenge to intuitively obtain physical laws from the converged training results. Second, the training results of neural networks depend heavily on the quantity and quality of training data. However, sometimes the experimental conditions are limited and only a small amount of data can be obtained. Although training data can be obtained through theoretical simulation, the lack of noise and disturbance in the experimental environment challenges the generalization and robustness of the algorithms.

In summary, in the past few years, machine learning neural network has made significant progress in its application in ultrafast optics, and related achievements have emerged endlessly. With the progress of neural network algorithms and the development of ultrafast optics technology, we can expect that ultrafast optics study becomes more intelligent, more convenient, more automatic, and more accurate to reveal physical laws.

**Key words** laser optics; ultrafast lasers; neural network; experimental control; data processing