

## 机器学习预测多折射率层有源光纤的模场特性

安毅<sup>1</sup>, 蒋敏<sup>1,2</sup>, 陈潇<sup>1</sup>, 李俊<sup>1</sup>, 栗荣涛<sup>1,3,4</sup>, 黄良金<sup>1,3,4\*</sup>, 潘志勇<sup>1,3,4</sup>, 冷进勇<sup>1,3,4</sup>, 姜宗福<sup>1,3,4</sup>, 周朴<sup>1\*\*</sup><sup>1</sup>国防科技大学前沿交叉学科学院, 湖南长沙 410073;<sup>2</sup>国防科技大学试验训练基地, 陕西西安 710106;<sup>3</sup>国防科技大学南湖之光实验室, 湖南长沙 410073;<sup>4</sup>国防科技大学高能激光技术湖南省重点实验室, 湖南长沙 410073

**摘要** 高功率光纤激光是当前我国激光科学技术领域的前沿热点,而稀土掺杂的有源光纤是高功率光纤激光器的核心器件。与常规有源光纤不同,多折射率层有源光纤的纤芯和包层之间增加了一个或多个辅助折射率层,展现出了特殊的模场特性,有望进一步提升高功率光纤激光的输出功率。利用传统方法分析不同结构参数下多折射率层有源光纤的模场特性时,通常需要耗费较长的时间求解麦克斯韦方程组。笔者首次引入机器学习算法来预测多折射率层有源光纤的模场特性。该方法仅需要数据空间中 0.1% 的样本,就可以学习多折射率层有源光纤结构参数与其模场特性之间的复杂映射关系,进而实现无须求解麦克斯韦方程组的快速精准预测。该方法的平均预测误差小于 0.6%,预测速度相比传统方法提升了约 7000 倍,为多折射率层有源光纤的模场特性分析提供了新思路。

**关键词** 光纤光学; 人工智能; 机器学习; 光纤激光; 有源光纤; 多折射率层光纤; 模场特性

中图分类号 TP181

文献标志码 A

DOI: 10.3788/CJL230476

## 1 引言

高功率光纤激光器<sup>[1-3]</sup>具有转换效率高、结构紧凑、可柔性操作等突出优势,在先进制造和大科学装置中都有重要应用,是当前我国激光科学技术领域的前沿热点<sup>[4]</sup>。稀土掺杂的有源光纤<sup>[5-7]</sup>是高功率光纤激光器的核心器件,通常由掺杂稀土离子的纤芯和纯石英包层组成。常规有源光纤在输出功率提升上面临的主要限制因素是非线性效应<sup>[8-9]</sup>和模式不稳定效应<sup>[10]</sup>。为了抑制非线性效应,研究人员通常会增大光纤的纤芯直径,以增加模场面积,但是当纤芯直径增大时,光纤的高阶模式难以被有效抑制,不利于提高模式不稳定效应的阈值。

多折射率层有源光纤为高功率光纤激光器的功率提升提供了新方案。与常规的有源光纤不同,多折射率层有源光纤的纤芯和包层之间增加了一个或多个辅助折射率层。这种特殊的光纤结构可以通过改变辅助折射率层的参数灵活地调控光纤的模场,有望在增大模场面积的同时抑制高阶模,从而进一步提升高功率光纤激光器的输出功率。

评估多折射率层有源光纤的功率提升潜力需要分析它在不同结构参数下的模场特性。分析模场特性

时,通常需要借助以有限差分法<sup>[11]</sup>、有限元法<sup>[12]</sup>和传输矩阵法<sup>[13]</sup>为代表的传统计算方法,这些方法的本质是求解麦克斯韦方程组。其中:有限差分法和有限元法需要将光纤的横截面分成有限个单元网格进行求解,分割的网格数目越多,计算时间就越长;传输矩阵法需要根据电场和磁场在光纤相邻折射率层上的边界连续条件得到光纤的特征方程,计算时间取决于特征方程的复杂程度。总体而言,这些传统方法的计算过程耗时较长,不利于光纤模场特性的快速分析。另外,在对多折射率层有源光纤进行优化设计时,需要分析大量的具有不同结构参数的多折射率层光纤的模场特性,而传统方法无法在短时间内完成计算过程,影响了多折射率层有源光纤优化设计的效率。

近年来,人工智能与激光技术的交叉融合为激光的相关研究带来了全新的方法和视角<sup>[14-17]</sup>。其中,以人工神经网络为代表的机器学习算法<sup>[18]</sup>在计算成像<sup>[19-22]</sup>、光通信<sup>[23]</sup>、光学设计<sup>[24]</sup>等诸多光学领域备受关注。为了解决具体的问题,深层神经网络和浅层神经网络在与光纤相关的工作中都得到了广泛应用。具体而言,深层神经网络更适合用于二维图像输入的情况<sup>[25-27]</sup>,已被用于光纤成像<sup>[28-29]</sup>、光纤通信<sup>[30]</sup>、光纤模式分解<sup>[31-33]</sup>、光纤光束质量评价<sup>[34]</sup>等领域;而架构更简单、层数较少

收稿日期: 2023-01-30; 修回日期: 2023-03-02; 录用日期: 2023-03-15; 网络首发日期: 2023-03-25

基金项目: 国家自然科学基金(61805280)、国防科技大学学校科研计划(ZK19-07)、脉冲功率激光技术国家重点实验室主任基金(SK12020ZR07)、湖南省研究生科研创新项目资助(CX20210018)

通信作者: \*hlj203@nudt.edu.cn; \*\*zhoupu203@163.com

的浅层神经网络更适合用于一维参数输入的情况<sup>[35]</sup>。研究人员已经采用浅层神经网络开展了光子晶体光纤<sup>[36-37]</sup>、悬芯光纤<sup>[38]</sup>等特殊光纤模场特性的预测工作,并取得了较好的预测效果。但相关工作仅考虑了基模的模场特性,未对高阶模式的模场特性进行预测。

本文首次利用浅层神经网络对多折射率层有源光纤的模场特性进行预测。该浅层神经网络仅需要数据空间中 0.1% 的样本即可学习多折射率层有源光纤结构参数与模场特性之间的复杂映射关系,进而实现模场特性的快速精准预测,而不需要求解麦克斯韦方程组。本研究工作为多折射率层有源光纤模场特性的快速分析提供了新思路。

## 2 基本原理及方法

### 2.1 多折射率层有源光纤及模场特性

多折射率层有源光纤的典型代表有部分掺杂光纤<sup>[39-41]</sup>、M 型光纤<sup>[42-44]</sup>、基座型光纤<sup>[45-47]</sup>、单沟壑光纤<sup>[48-50]</sup>等,相应的光纤横截面结构和折射率分布如图 1 所示,其中阴影部分代表稀土掺杂区域。与图 1(a)所示的常

规光纤不同,图 1(b)所示的部分掺杂光纤<sup>[39-41]</sup>在掺杂区域和包层之间增加了一层与掺杂区域具有相同折射率的非掺杂层。由于与掺杂区域重合度高的模式可获得更高的增益,因此,部分掺杂光纤这一设计有利于实现基模的高增益、高阶模的低增益,进而实现对高阶模的抑制。图 1(c)所示的 M 型光纤<sup>[42-44]</sup>因折射率剖面形状类似于字母“M”而得名,该光纤纤芯中心的折射率低于纤芯其余部分的折射率,其主要优势是具有较大的模场面积,能够抑制非线性效应。图 1(d)所示的基座型光纤<sup>[45-47]</sup>通过在高折射率纤芯的外围增加具有较高折射率的辅助环层,不仅提高了稀土掺杂浓度,还在一定程度上抑制了高阶模。图 1(e)所示的单沟壑光纤<sup>[48-50]</sup>的基本结构是纤芯外围环绕低折射率的沟壑层和高折射率的环形层,能够同时提供大的模场面积和强的高阶模抑制能力。可以看到,在这几种典型的多折射率层有源光纤中,单沟壑光纤的折射率层数最多,结构较为复杂,具有一定的代表性。本文将以单沟壑光纤作为多折射率层有源光纤的典型研究对象,利用机器学习算法预测其基模和高阶模的模场特性。

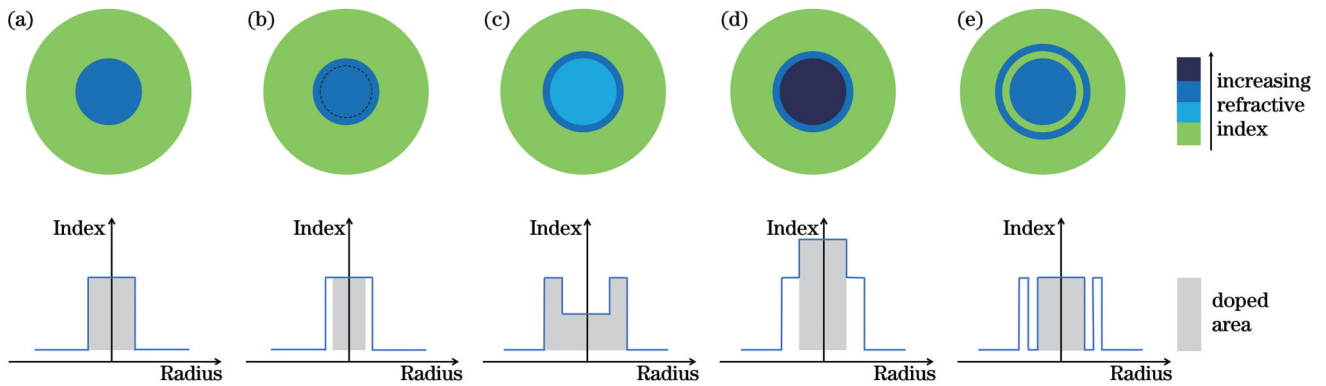


图 1 常规光纤和几种典型多折射率层有源光纤的横截面结构及折射率分布示意图。(a)常规光纤;(b)部分掺杂光纤;(c)M 型光纤;(d)基座型光纤;(e)单沟壑光纤

Fig. 1 Schematics of the cross-section structure and refractive index distribution for conventional and several typical multi-layer active fibers. (a) Conventional fiber; (b) confine doped fiber; (c) M-type fiber; (d) pedestal fiber; (e) single trench fiber

本文关注的模场特性主要包括等效折射率、模场面积、重叠因子等参数,其中:等效折射率( $n_{\text{eff}}$ )可以用于区分不同的模式,同时也是求解模场分布时最基础和最关键的参数;模场面积( $A_{\text{eff}}$ )和重叠因子( $\Gamma$ )分别与模场的整体分布情况及其在掺杂区域的分布情况有关。模场面积( $A_{\text{eff}}$ )和重叠因子( $\Gamma$ )的定义分别为

$$A_{\text{eff}} = \frac{\left( \iint |E|^2 dx dy \right)^2}{\iint |E|^4 dx dy}, \quad (1)$$

$$\Gamma = \frac{\iint_{\text{doped}} |E|^2 dx dy}{\iint |E|^2 dx dy}, \quad (2)$$

式中: $E$ 是基模或高阶模的模场分布;下标“doped”表示仅在掺杂区域积分。根据光纤的弱导近似条件<sup>[31]</sup>,多折射率层有源光纤中的模式应为线偏振(LP)模式。

本文中的基模指的是  $LP_{01}$  模,高阶模指的是  $LP_{11}$  模。这是因为  $LP_{11}$  模在所有高阶模中占据主导地位,是影响光纤激光功率提升的最主要的高阶模式。一般认为:当基模的模场面积增大时,光纤的非线性效应阈值将提高;当基模的重叠因子较高而高阶模的重叠因子显著低于基模时,高阶模将得到抑制<sup>[48]</sup>。因此,以等效折射率  $n_{\text{eff}}$ 、模场面积  $A_{\text{eff}}$ 、重叠因子  $\Gamma$  为代表的模场特性是评估多折射率层有源光纤激光功率提升潜力的重要指标。

### 2.2 机器学习预测模场特性的方法

利用机器学习算法预测多折射率层有源光纤在不同结构参数下模场特性的方法如图 2 所示。该方法可分为三步,分别是数据生成、网络训练和快速预测。

在数据生成步骤中,采用传统方法生成训练样本。

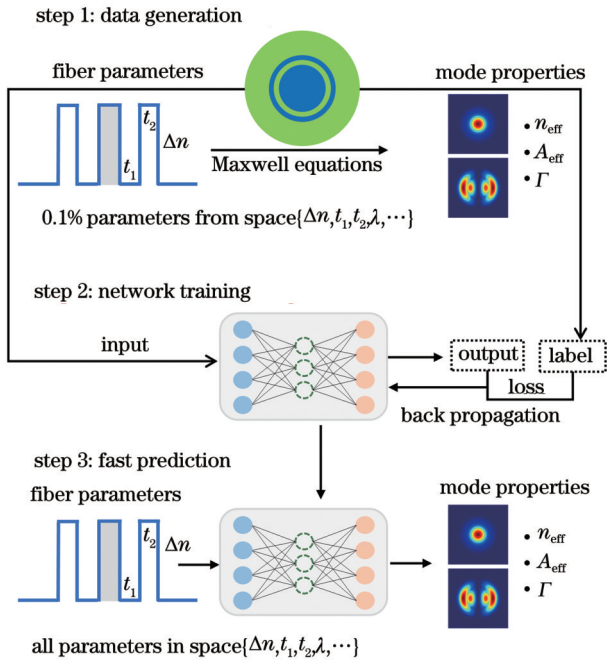


图 2 机器学习预测多折射率层有源光纤模场特性的示意图  
Fig. 2 Schematic of machine learning approach to predict mode properties of multi-layer active fibers

将多折射率层有源光纤的纤芯直径设置为  $20\ \mu\text{m}$ , 纤芯与纯石英包层之间的折射率差记为  $\Delta n$ , 沟壑层和环形层的厚度分别记为  $t_1$  和  $t_2$ , 工作波长记为  $\lambda$ 。变量  $\Delta n, t_1, t_2, \lambda$  组成了多折射率层有源光纤结构参数的数据取值空间, 相应的取值范围和步长如表 1 所示。定义的结构参数取值空间共有约  $40^4 (= 2.56 \times 10^6)$  种可能的参数值组合。随机生成 0.1% 的数据, 即 2560 组结构参数, 将其作为训练样本的结构参数。在计算结构参数对应的模场特性时, 需要利用传统方法求解麦克斯韦方程组。相比有限差分法<sup>[11]</sup>和有限元法<sup>[12]</sup>, 传输矩阵法<sup>[13]</sup>无须对光纤的横截面进行网格剖分便可求解, 因而是传统方法中求解速度更快的一种方法。本文利用传输矩阵法求解麦克斯韦方程组, 得到基模和高阶模的  $n_{\text{eff}}, A_{\text{eff}}$  和  $\Gamma$  等模场参数。计算这些训练样本对应的模场参数的总耗时约为 31 min。

表 1 多折射率层有源光纤结构参数的取值范围和步长  
Table 1 Varying range and step of structural parameters for multi-layer active fibers

Fiber parameter	Range	Step
$\Delta n$	0.0008–0.0016	0.00002
$t_1 / \mu\text{m}$	0.25–10	0.25
$t_2 / \mu\text{m}$	0.25–10	0.25
$\lambda / \mu\text{m}$	0.8–1.2	0.01

在网络训练步骤中, 将包含光纤结构参数和模场特性的训练样本输入浅层神经网络, 使网络学习结构参数与模场特性之间的复杂的映射关系。本文采用的浅层神经网络包含一个输入层、一个隐藏层和一个输

出层。网络隐藏层中包含 50 个神经元节点, 输入层和输出层分别有 4 个和 6 个节点, 输入和输出层的节点数目与结构参数、模场特性参数的数目一致。训练过程中需要对浅层神经网络进行多次训练。在第一次训练时, 随机生成网络节点连接路径上权重值系数的初始值, 利用初始的权重值系数处理训练样本的结构参数, 并在输出层得到网络的输出值, 进而根据输出值与对应的标签值之间的损失函数以反向传播的方式更新神经网络的权重值系数, 并将其用于下一次的训练中。如此迭代, 神经网络的权重值系数不断更新, 损失函数不断减小, 直至网络收敛。本文采用均方误差 (MSE)<sup>[31]</sup> 作为网络的损失函数。需要指出的是, 为了使网络具有更高的预测精度, 需要对样本标签进行一定的处理, 本文第 3 部分将对此进行具体说明。

网络训练完成之后, 便可以用于模场特性的快速预测。在这一步骤中, 只需要将待分析的多折射率层有源光纤的结构参数输入神经网络中, 神经网络就可以通过训练后的权重值系数直接对结构参数进行处理, 预测得到相应的模场特性参数, 而无须求解麦克斯韦方程组。

### 3 结果与讨论

本文所有计算结果均是在一台配备了 i7-8700 CPU 和 GTX 1080 GPU 的台式计算机上获得的。训练样本中模场特性参数  $n_{\text{eff}}$  的变化范围约为 1.448~1.455,  $A_{\text{eff}}$  的变化范围约为 300~1300  $\mu\text{m}^2$ ,  $\Gamma$  的变化范围约为 0~1。如果直接将这些模场特性参数作为训练样本的标签, 就会影响网络的预测精度, 下面对此进行说明。

考虑两种情形: 第一种是将  $n_{\text{eff}}, A_{\text{eff}}$  和  $\Gamma$  直接作为样本标签对网络进行训练, 将该网络记为 NN'; 第二种是将  $n_{\text{eff}}$  减去 1.448 后除以 0.007, 将  $A_{\text{eff}}$  除以 1000, 然后与  $\Gamma$  一起作为标签, 这种预处理方式可以使标签中的各个参数的取值具有相近的变化范围, 将该网络记为 NN。训练神经网络后利用 NN 进行预测, 此时只需要对输出值进行预处理的逆运算 ( $n_{\text{eff}}$  对应的输出值乘以 0.007 后与 1.448 相加,  $A_{\text{eff}}$  对应的输出值乘以 1000) 便可以得到模场特性参数的预测值。

NN 和 NN' 训练过程中损失函数 MSE 的变化如图 3 所示。可以看到, NN 和 NN' 均在约 200 次训练后达到收敛状态, NN 最终的 MSE 可以达到  $2.5 \times 10^{-5}$ , NN' 最终的 MSE 约为 6.7。两个网络训练 200 次的总时间均为 18 s。

利用训练后的 NN 和 NN' 对多折射率层有源光纤进行模场特性参数的预测。对于给定的结构参数, 还需要借助传统方法求解模场特性参数的基准值, 以评价网络的预测精度。注意到数据空间中 共有  $2.56 \times 10^6$  种结构参数的取值组合, 求解所有结构参数对应的模场特性参数的基准值显然是费时费力的。为了在一

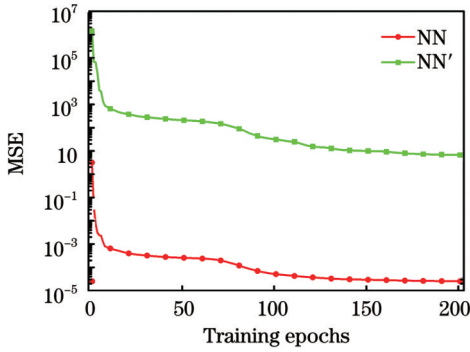
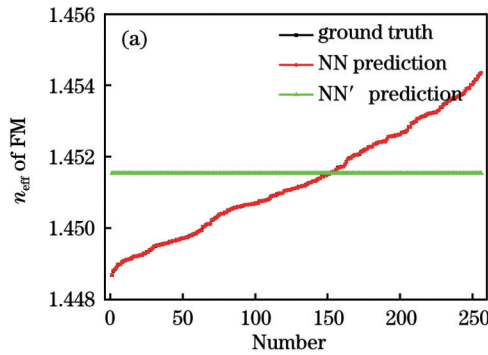


图 3 NN 和 NN' 训练过程中损失函数 MSE 的变化  
Fig. 3 Variation of MSE during training process for NN and NN'

一定程度上表征网络的预测精度,本文在结构参数的取



值空间中随机生成 256 组数据,利用传输矩阵法求解这些结构参数对应的模场特性参数,形成神经网络的测试集。需要说明的是,测试集不包含在训练集中,以更充分地检验神经网络的训练效果。传输矩阵法求解 256 组测试样本模场特性参数的总时间为 177 s。

NN 和 NN' 对测试集基模 (FM) 和高阶模 (HOM) 的  $n_{\text{eff}}$  的预测结果分别如图 4(a) 和图 4(b) 所示。为了便于比较,分别按 FM 和 HOM 的  $n_{\text{eff}}$  基准值从小到大的顺序进行编号,并绘制相应的预测值。从图 4 中可以看到,NN 的预测值与基准值近乎重合,而 NN' 对所有测试样本预测的  $n_{\text{eff}}$  始终是一个常数。显然,NN' 并不能准确预测多折射率层有源光纤的模场特性。所以,对标签的预处理是非常有必要的。下文将主要讨论 NN 预测模场特性的精度。




图 4 NN 和 NN' 对测试集基模 (FM) 和高阶模 (HOM) 的  $n_{\text{eff}}$  的预测结果。(a) 基模; (b) 高阶模  
Fig. 4 Predicted  $n_{\text{eff}}$  results of fundamental mode (FM) and high-order-mode (HOM) for the testing samples through NN and NN'.  
(a) FM; (b) HOM

为了展示 NN 预测的精度,首先给出三组典型测试样本的预测结果。在选取这三组典型样本时,按照 FM 的  $A_{\text{eff}}$  基准值从小到大的顺序对测试样本进行编号,然后选择第 85、第 170、第 255 组测试样本,并将这三组样本分别记为 A、B、C 组样本。三组测试样本的结构参数  $\{\Delta n, t_1, t_2, \lambda\}$  分别为  $\{0.00112, 9 \mu\text{m}, 5.5 \mu\text{m}, 1.02 \mu\text{m}\}$ 、 $\{0.00104, 1.75 \mu\text{m}, 4.75 \mu\text{m}, 0.9 \mu\text{m}\}$  和  $\{0.00084, 2.75 \mu\text{m}, 10 \mu\text{m}, 0.98 \mu\text{m}\}$ , 其对应的 FM 和 HOM 的强度分布如图 5 所示。可以看到,由于结构参数不同, A、B、C 组样本的 FM 向纤芯外围扩散的程度不同,而 HOM 也呈现出不同的分布形态。




图 5 三组测试样本 A、B、C 的 FM 和 HOM 的强度分布  
Fig. 5 Intensity distributions of FM and HOM for the three testing samples A, B, and C

图 6 给出了 NN 对 A、B、C 三组测试样本的模场特性参数的预测值与基准值的比较结果。可以看到,尽管三组测试样本呈现出了图 5 所示的不同的强度分布,但 NN 对 FM 和 HOM 的  $n_{\text{eff}}$ 、 $A_{\text{eff}}$  和  $\Gamma$  的预测值均与基准值十分接近。这一结果说明了 NN 对这三组典型测试样本模场特性预测的准确性。

将所有测试样本的预测值与基准值绘制于图 7 中,以进一步说明 NN 预测模场特性的精度。为了便于比较,对每种模场特性参数分别按其基准值从小到大的顺序进行编号,并绘制相应的预测值。由图 7(a)~(c) 可以看到,对于 FM 的  $n_{\text{eff}}$ 、 $A_{\text{eff}}$  和  $\Gamma$ , 预测值与基准值十分接近,预测值曲线与基准值曲线近乎重合。由图 7(d)~(f) 可以看到,对于 HOM 的  $n_{\text{eff}}$ 、 $A_{\text{eff}}$  和  $\Gamma$ , 预测值与基准值也十分接近,预测值曲线与基准值曲线同样趋于重合。NN 预测所有测试样本模场特性的总时间为 23 ms。

图 6 和图 7 中对 NN 得到的预测值与传统方法得到的基准值之间的比较形象地说明了 NN 预测多折射率层有源光纤模场特性的准确性。为了定量表征预测的精度,定义预测误差 ( $P_e$ ) 为预测值与基准值之间的绝对误差与模场特性参数数值变化区间长度的比值,即

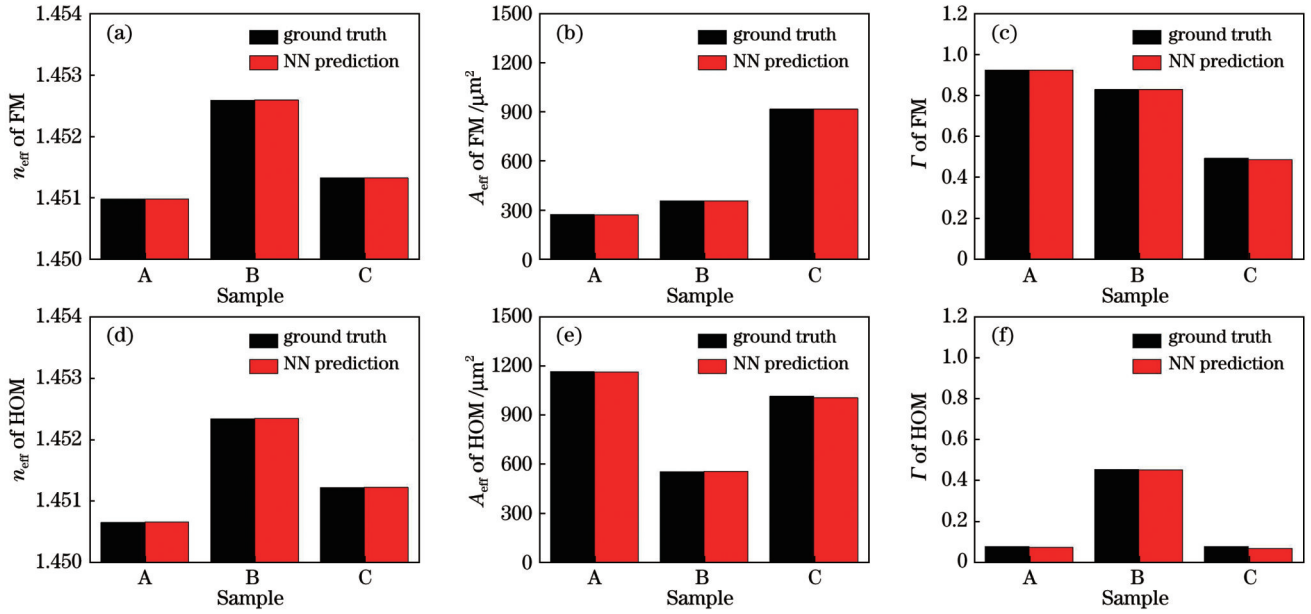


图 6 NN 对三组测试样本 A、B、C 的预测值与基准值的比较

Fig. 6 Comparison between NN predicted values and ground truths for the three testing samples A, B, and C

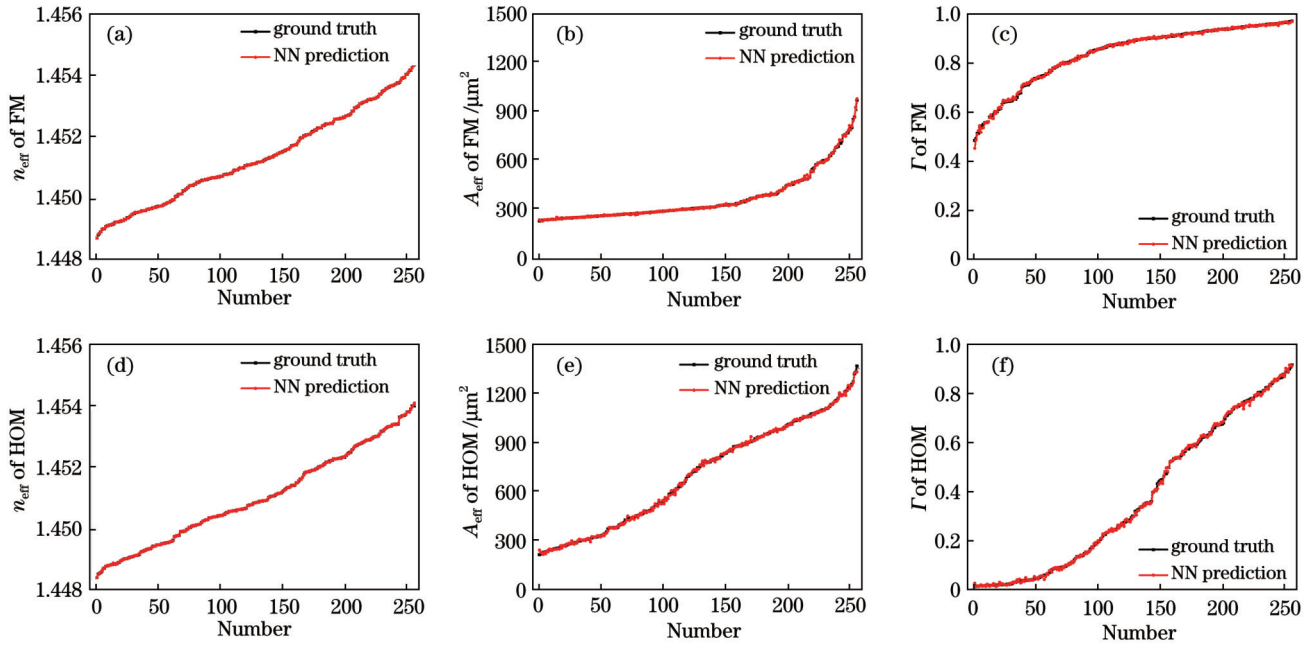


图 7 NN 对所有测试样本的预测值与基准值的比较

Fig. 7 Comparison between NN predicted values and ground truths for all the testing samples

$$P_E(n_{\text{eff}}) = \frac{|n_{\text{eff, predict}} - n_{\text{eff, ground truth}}|}{0.007}, \quad (3)$$

$$P_E(A_{\text{eff}}) = \frac{|A_{\text{eff, predict}} - A_{\text{eff, ground truth}}|}{1000}, \quad (4)$$

$$P_E(\Gamma) = \frac{|\Gamma_{\text{predict}} - \Gamma_{\text{ground truth}}|}{1}. \quad (5)$$

式(3)~(5)采用固定值而不是每个测试样本的基准值作为分母,这主要是为了更充分地评价预测是否准确。如果采用基准值作为分母,预测误差一方面会因等效折射率的基准值过大而整体过小,不足以通过

误差值甄别预测不准确的情形;另一方面也会在重叠因子的基准值过小(例如小于 0.05)时数十倍地放大误差,不足以反映预测准确的情形。根据式(3)~(5)所示的定义,可以求得所有测试样本的预测误差,预测误差的平均值列于表 2 中。可以看到,NN 预测多折射率

表 2 测试样本的平均预测误差

Table 2 Averaged prediction error for the testing samples			
Mode	$P_E(n_{\text{eff}}) / \%$	$P_E(A_{\text{eff}}) / \%$	$P_E(\Gamma) / \%$
FM	0.05	0.27	0.30
HOM	0.08	0.56	0.47

层有源光纤模场特性的平均预测误差小于 0.6%，从而从定量的角度验证了本文所提方法的准确性。

实际应用中通常关注光纤在不同工作波长下的模场特性。为此,设定多折射率层有源光纤的 $\Delta n$ 、 $t_1$ 、 $t_2$ 分别为 0.0012、5  $\mu\text{m}$ 、5  $\mu\text{m}$ ,利用 NN 分析该光纤在不同

工作波长下的模场特性数据,并将分析结果与传输矩阵法得到的基准值进行对比,结果如图 8 所示。可以看出 NN 对该测试光纤在不同工作波长下模场特性的预测结果均与基准值十分接近,再次验证了 NN 预测的准确性。

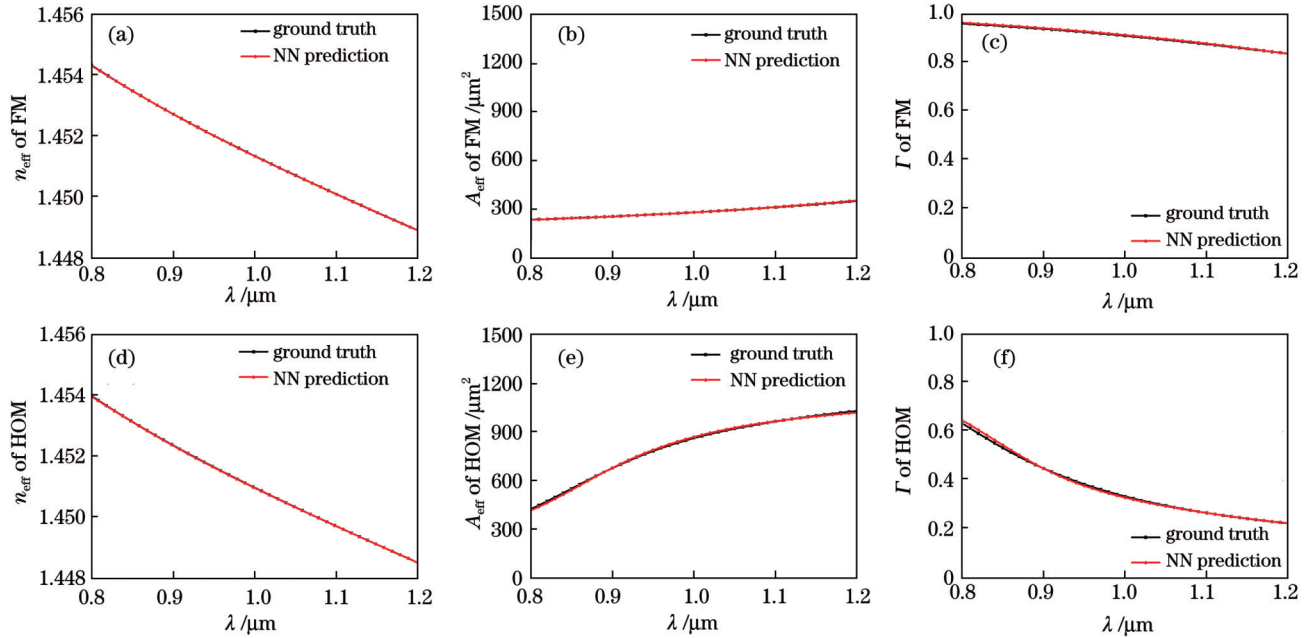


图 8 NN 对光纤测试样本在不同工作波长下模场特性的预测值与基准值的比较

Fig. 8 Comparison between NN predicted mode properties and ground truths for the testing sample under different working wavelengths

除了可对模场特性进行精准预测外,NN 更大的优势在于它更快的预测速度。前文已经指出,传输矩阵法在所有传统方法中具有相对较快的计算速度,其计算 256 组测试样本的模场特性参数的总耗时为 177 s,而 NN 预测这些测试样本模场特性的总耗时仅为 23 ms。相比传输矩阵法,NN 预测模场特性的速度提高了约 7000 倍。这意味着,如果对本文定义的数据取值空间中的  $2.56 \times 10^6$  组结构参数求解相应的模场特性参数,传统方法至少需要连续计算 20 d,而 NN 仅需要计算 4 min。毫无疑问,机器学习算法的引入大幅提高了多折射率层有源光纤模场特性预测的速度。这种新方案不仅可以在短时间内仿真得到不同结构参数下光纤的模场特性,进而辅助光纤的优化设计,还可以针对不同工作波长等应用场景对实际制备的光纤进行快速评估。

## 4 结 论

本文提出了利用机器学习预测多折射率层有源光纤模场特性的新方案。该方案仅需要数据取值空间中 0.1% 的样本,就可以准确学习多折射率层光纤结构参数与其模场特性之间的复杂映射关系,平均预测误差可以控制在 0.6% 以内。相比传统方法,机器学习方案的预测速度提高了约 7000 倍,具有显著优势,可以辅助光纤的优化设计以及对制备的光纤进行快速评估。

## 参 考 文 献

- [1] Nilsson J, Payne D N. High-power fiber lasers[J]. Science, 2011, 332(6032): 921-922.
- [2] Zervas M N, Codemard C A. High power fiber lasers: a review[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2014, 20(5): 219-241.
- [3] 周朴,冷进勇,肖虎,等.高平均功率光纤激光的研究进展与发展趋势[J].中国激光,2021,48(20):2000001.  
Zhou P, Leng J Y, Xiao H, et al. High average power fiber lasers: research progress and future prospect[J]. Chinese Journal of Lasers, 2021, 48(20): 2000001.
- [4] 唐华,沈咏,龙丽媛.国家自然科学基金视角下我国激光科学技术发展的分析和展望[J].中国激光,2023,50(2):0200001.  
Tang H, Shen Y, Long L Y. Analysis and prospects for development of laser science and technology in China from the perspective of national science foundation of China[J]. Chinese Journal of Lasers, 2023, 50(2): 0200001.
- [5] 邵冲云,于春雷,胡丽丽.面向空间应用耐辐照有源光纤研究进展[J].中国激光,2020,47(5):0500014.  
Shao C Y, Yu C L, Hu L L. Radiation-resistant active fibers for space applications[J]. Chinese Journal of Lasers, 2020, 47(5): 0500014.
- [6] Chen X, Yao T F, Huang L J, et al. Functional fibers and functional fiber-based components for high-power lasers[J]. Advanced Fiber Materials, 2023, 5(1): 59-106.
- [7] 王小林,文瑜钧,张汉伟,等.变纤芯直径掺镱光纤激光器:现状与趋势[J].中国激光,2022,49(21):2100001.  
Wang X L, Wen Y J, Zhang H W, et al. Ytterbium-doped core-diameter-variable fiber laser: current situation and develop tendency [J]. Chinese Journal of Lasers, 2022, 49(21): 2100001.
- [8] Kobayakov A, Sauer M, Chowdhury D. Stimulated Brillouin scattering in optical fibers[J]. Advances in Optics and Photonics,

- 2010, 2(1): 1-59.
- [9] Liu W, Ma P F, Lü H B, et al. General analysis of SRS-limited high-power fiber lasers and design strategy[J]. Optics Express, 2016, 24(23): 26715-26721.
- [10] Jauregui C, Stihler C, Limpert J. Transverse mode instability[J]. Advances in Optics and Photonics, 2020, 12(2): 429-484.
- [11] Fallahkhair A, Li K S, Murphy T E. Vector finite difference modesolver for anisotropic dielectric waveguides[J]. Journal of Lightwave Technology, 2008, 26(11): 1423-1431.
- [12] Cucinotta A, Selleri S, Vincetti L, et al. Holey fiber analysis through the finite-element method[J]. IEEE Photonics Technology Letters, 2002, 14(11): 1530-1532.
- [13] Garcia S, Gasulla I. Universal characteristic equation for multi-layer optical fibers[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2020, 26(4): 4300111.
- [14] 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.
- [15] 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(1): 1-8.
- [16] Wei X M, Jing J C, Shen Y C, et al. Harnessing a multi-dimensional fibre laser using genetic wavefront shaping[J]. Light: Science & Applications, 2020, 9(1): 1-10.
- [17] Jiang M, Wu H S, An Y, et al. Fiber laser development enabled by machine learning: review and prospect[J]. Photonix, 2022, 3(1): 16.
- [18] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [19] Barbastathis G, Ozcan A, Situ G H. On the use of deep learning for computational imaging[J]. Optica, 2019, 6(8): 921-943.
- [20] 伍俊龙, 郭正华, 陈先锋, 等. 基于深度学习的光场成像三维测量方法研究[J]. 中国激光, 2020, 47(12): 1204005.  
Wu J L, Guo Z H, Chen X F, et al. Three-dimensional measurement method of light field imaging based on deep learning [J]. Chinese Journal of Lasers, 2020, 47(12): 1204005.
- [21] 左超, 冯世杰, 张翔宇, 等. 深度学习下的计算成像: 现状、挑战与未来[J]. 光学学报, 2020, 40(1): 0111003.  
Zuo 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.
- [22] 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.
- [23] Lohani S, Knutson E M, O'Donnell M, et al. On the use of deep neural networks in optical communications[J]. Applied Optics, 2018, 57(15): 4180-4190.
- [24] Jiang J Q, Chen M K, Fan J A. Deep neural networks for the evaluation and design of photonic devices[J]. Nature Reviews Materials, 2021, 6(8): 679-700.
- [25] Wang X Y, Wu T Y, Dong C, et al. Integrating deep learning to achieve phase compensation for free-space orbital-angular-momentum-encoded quantum key distribution under atmospheric turbulence[J]. Photonics Research, 2021, 9(2): B9-B17.
- [26] Wang W H, Zhao X, Jiang Z X, et al. Deep learning-based scattering removal of light field imaging[J]. Chinese Optics Letters, 2022, 20(4): 041101.
- [27] Saba A, Gigli C, Ayoub A B, et al. Physics-informed neural networks for diffraction tomography[J]. Advanced Photonics, 2022, 4(6): 066001.
- [28] Borhani N, Kakkava E, Moser C, et al. Learning to see through multimode fibers[J]. Optica, 2018, 5(8): 960-966.
- [29] 孟球, 胡海峰, 胡金洲, 等. 基于深度学习的多模光纤散射介质成像重建[J]. 中国激光, 2020, 47(12): 1206005.  
Meng L, Hu H F, Hu J Z, et al. Image reconstruction of multimode fiber scattering media based on deep learning[J]. Chinese Journal of Lasers, 2020, 47(12): 1206005.
- [30] 胡进坤, 郭晓洁, 李建平, 等. 基于深度学习的多模光纤通信系统的模式与模群识别[J]. 光学学报, 2022, 42(4): 0406004.  
Hu J K, Guo X J, Li J P, et al. Deep learning-based recognition of modes and mode groups in multimode optical fiber communication system[J]. Acta Optica Sinica, 2022, 42(4): 0406004.
- [31] An Y, Huang L J, Li J, et al. Learning to decompose the modes in few-mode fibers with deep convolutional neural network[J]. Optics Express, 2019, 27(7): 10127-10137.
- [32] Yan B R, Zhang J Y, Wang M G, et al. Degenerated mode decomposition with convolutional neural network for few-mode fibers[J]. Optics & Laser Technology, 2022, 154: 108287.
- [33] 田梓辰, 裴丽, 王建帅, 等. 基于深度学习的环芯光纤精确模式分解方法[J]. 光学学报, 2023, 43(4): 0406003.  
Tian Z C, Pei L, Wang J S, et al. Accurate mode decomposition for ring core fibers based on deep learning[J]. Acta Optica Sinica, 2023, 43(4): 0406003.
- [34] An Y, Li J, Huang L J, et al. Deep learning enabled superfast and accurate  $M^2$  evaluation for fiber beams[J]. Optics Express, 2019, 27(13): 18683-18694.
- [35] 马泽航, 龚睿, 李彬, 等. 基于机器学习的光纤多参量探测[J]. 光学学报, 2022, 42(20): 2006003.  
Ma Z H, Gong R, Li B, et al. Optical fiber multi-parameter measurement based on machine learning[J]. Acta Optica Sinica, 2022, 42(20): 2006003.
- [36] Chugh S, Gulistan A, Ghosh S, et al. Machine learning approach for computing optical properties of a photonic crystal fiber[J]. Optics Express, 2019, 27(25): 36414-36425.
- [37] Jabin M A, Fok M P. Prediction of 12 photonic crystal fiber optical properties using MLP in deep learning[J]. IEEE Photonics Technology Letters, 2022, 34(7): 391-394.
- [38] Yuan S Y, Chen S C, Yang J L, et al. Efficient calculation of optical properties of suspended-core fiber via a machine learning algorithm[J]. Applied Optics, 2022, 61(19): 5714-5721.
- [39] 张志伦, 张芳芳, 林贤峰, 等. 国产部分掺杂光纤实现 3 kW 全光纤激光振荡输出[J]. 物理学报, 2020, 69(23): 234205.  
Zhang Z L, Zhang F F, Lin X F, et al. Home-made confined-doped fiber with 3-kW all-fiber laser oscillating output[J]. Acta Physica Sinica, 2020, 69(23): 234205.
- [40] Wu H S, Li R X, Xiao H, et al. First demonstration of a bidirectional tandem-pumped high-brightness 8 kW level confined-doped fiber amplifier[J]. Journal of Lightwave Technology, 2022, 40(16): 5673-5681.
- [41] 黄良金, 吴函烁, 李瑞显, 等. 用于 10 kW 级高光束质量激光输出的国产部分掺杂光纤[J]. 强激光与粒子束, 2022, 34(11): 111002.  
Huang L J, Wu H S, Li R X, et al. Homemade confined-doped fiber for 10 kW level fiber laser output with good beam quality[J]. High Power Laser and Particle Beams, 2022, 34(11): 111002.
- [42] Hautakorpi M, Kaivola M. Modal analysis of M-type-dielectric-profile optical fibers in the weakly guiding approximation[J]. Journal of the Optical Society of America A, 2005, 22(6): 1163-1169.
- [43] Jain D, George M A, Harris B, et al. Approximate modal cut-off wavelengths and the V-parameter for M-type optical fibers and its novel applications[J]. Journal of Lightwave Technology, 2021, 39(13): 4478-4488.
- [44] 林贤峰, 张志伦, 邢颖滨, 等. 基于 M 型掺铋光纤的近单模 2 kW 光纤放大器[J]. 物理学报, 2022, 71(3): 034205.  
Lin X F, Zhang Z L, Xing Y B, et al. Near-single-mode 2-kW fiber amplifier based on M-type ytterbium-doped fiber[J]. Acta Physica Sinica, 2022, 71(3): 034205.
- [45] Yoo S, Webb A S, Boyland A J, et al. Linearly polarized ytterbium-doped fiber laser in a pedestal design with aluminosilicate inner cladding[J]. Laser Physics Letters, 2011, 8(6): 453-457.
- [46] Saha M, Das Chowdhury S, Shekhar N K, et al. Yb-doped pedestal silica fiber through vapor phase doping for pulsed laser applications[J]. IEEE Photonics Technology Letters, 2016, 28(9): 1022-1025.

- [47] Liu R, Yan D P, Fan Z J, et al. Fabrication and 1046 nm laser behaviors of Yb-doped phosphosilicate binary fiber with a pedestal structure[J]. *Optical Materials Express*, 2020, 10(2): 464-471.
- [48] Jain D, Jung Y, Nunez-Velazquez M, et al. Extending single mode performance of all-solid large-mode-area single trench fiber [J]. *Optics Express*, 2014, 22(25): 31078-31091.
- [49] Zhang H H, Zhang W L, Wang Z, et al. Decoherence of fiber light sources using a single-trench fiber[J]. *Chinese Physics B*, 2020, 29(12): 124210.
- [50] An Y, Yang H, Chen X, et al. Seeing the strong suppression of higher order modes in single trench fiber using the  $S^2$  technique[J]. *Optics Letters*, 2023, 48(1): 61-64.

## Machine Learning Predicting Mode Properties for Multi-Layer Active Fibers

An Yi<sup>1</sup>, Jiang Min<sup>1,2</sup>, Chen Xiao<sup>1</sup>, Li Jun<sup>1</sup>, Su Rongtao<sup>1,3,4</sup>, Huang Liangjin<sup>1,3,4\*</sup>,  
Pan Zhiyong<sup>1,3,4</sup>, Leng Jinyong<sup>1,3,4</sup>, Jiang Zongfu<sup>1,3,4</sup>, Zhou Pu<sup>1\*\*</sup>

<sup>1</sup>College of Advanced Interdisciplinary Studies, National University of Defense Technology, Changsha 410073, Hunan, China;

<sup>2</sup>Test Center, National University of Defense Technology, Xi'an 710106, Shaanxi, China;

<sup>3</sup>Nanhu Laser Laboratory, National University of Defense Technology, Changsha 410073, Hunan, China;

<sup>4</sup>Hunan Provincial Key Laboratory of High Energy Laser Technology, National University of Defense Technology, Changsha 410073, Hunan, China

### Abstract

**Objective** Recently, high-power fiber lasers (HPFLs) have become a popular topic in laser science and technology. Rare earth-doped active fibers are key components of HPFL. In contrast to common active fibers, one or more auxiliary refractive index layers are added between the core and cladding of multi-layer active fibers. These types of fibers exhibit special mode properties; therefore, they are expected to further enhance the output power of HPFLs. Evaluating the mode properties of multilayer active fibers under different fiber structural parameters is important because the corresponding results reveal the relationship between the structural parameters and fiber properties, indicate which structural parameter has the best performance, and provide guidance for fiber design. Traditional methods, such as finite difference, finite element, and transfer matrix methods, have been adopted to evaluate the mode properties of such fibers. However, these traditional approaches typically require a long time to repeatedly solve Maxwell's equations under different structural parameters. Doubtlessly, a faster approach to evaluating multilayer active fibers would be vital. In this study, we used machine learning to predict the mode properties of multilayer active fibers for the first time. This new approach can achieve fast and accurate predictions without solving Maxwell's equations.

**Methods** We introduce a shallow neural network (NN) to learn the mapping from input structural parameters to output mode properties. The structural parameters include the refractive index difference between the core and cladding, thickness of the auxiliary layers, and working wavelength. The mode properties included the effective index, mode field area, and power-filling factor of the fundamental mode (FM) and higher-order mode (HOM). The NN approach can be divided into three steps: data generation, network training, and rapid evaluation (Fig. 2). In the data generation step, 0.1% of the training samples in the defined data space (Table 1) were generated using the transfer matrix method. An NN with one hidden layer is trained using the mean square error (MSE) loss function between the label and output in the network training step. After training, the NN can quickly and accurately predict the mode properties of the multilayer active fibers.

**Results and Discussions** We trained the shallow NN for 200 epochs, and the MSE was finally close to  $2.5 \times 10^{-5}$ . The total training time was approximately 18 s. To test the accuracy of the trained NN, 256 testing samples were randomly generated. Three typical samples with different mode field distributions (Fig. 5) were used to test the accuracy of the trained NN, and the predicted mode properties agreed well with the ground truths (Fig. 6). The predicted mode properties for all testing samples were then collected and compared to the corresponding ground truths (Fig. 7). The predicted values remained very close to the ground truths. In addition to the randomly generated testing samples, we successfully utilized an NN to predict the mode properties under different wavelengths (Fig. 8), aiming at a special multilayer active fiber with a fixed refractive index difference and auxiliary layer thickness. The accuracy and cost of the NN approach were analyzed statistically. The averaged prediction error of the mode properties was less than 0.6% (Table 2), indicating the high accuracy of this shallow NN. Besides, the total time required to evaluate 256 samples was approximately 177 s for the traditional method and 23 ms for the NN approach. That is, NN takes only 0.09 ms to complete the evaluation for one sample, which is 7000 times faster than traditional methods.

**Conclusions** In this study, we used machine learning for the first time to achieve a fast and accurate prediction of the mode properties of multilayer active fibers. This method requires only 0.1% of the samples in the data space to learn the complex mapping between the fiber's structural parameters and mode properties. Thus, fast and accurate prediction can be achieved without solving Maxwell's equations. The average prediction error of this method is less than 0.6%, and the prediction speed is 7000 times higher than that of the traditional method, providing a new way to evaluate the mode properties of multilayer active fibers.

**Key words** fiber optics; artificial intelligence; machine learning; fiber laser; active fiber; multilayer fiber; mode properties