

SHAP 驱动的 NOLM 锁模光纤激光器智能参数优化研究

刘喆¹⁾ 冯征¹⁾ 王斐然¹⁾²⁾³⁾ 张海洋¹⁾²⁾³⁾ 张云婕¹⁾²⁾³⁾ 严祥安¹⁾²⁾³⁾ 冯松¹⁾²⁾³⁾

方青⁴⁾ 韩小祥^{1)2)3)†)}

(1. 西安工程大学, 理学院, 西安 710048;

2. 柔性射线防护陕西省工程研究中心, 西安工程大学, 西安 710048;

3. 西安市核防护纺织装备技术重点实验室, 西安工程大学, 西安 710048;

4. 昆明理工大学, 理学院, 昆明 650500)

摘 要

针对非线性光学环形镜锁模光纤激光器参数空间复杂、输出特性难以精准调控的问题, 本文提出了一种融合 SHAP 可解释性分析与遗传算法的智能参数优化方法。首先, 采用四阶龙格-库塔相互作用表象法求解金兹堡-朗道方程对 NOLM 锁模激光器进行数值仿真, 系统探究了二阶色散系数、非线性折射率、小信号增益系数等关键参数对输出脉冲峰值功率、能量及宽度的影响, 构建了多维参数仿真数据集。随后建立了随机森林 (RF)、极端梯度提升 (XGB)、反向传播神经网络 (BPNN) 及一维卷积神经网络 (1D CNN) 四种代理模型进行预测性能分析, 结果表明 BPNN 和 1D CNN 具有更优的泛化能力和预测稳定性。在此基础上, 引入 SHAP 可解释性框架量化了各参数的贡献度, 揭示了非线性折射率与增益相关参数对输出特性的主导作用机制。最后结合遗传算法 (GA) 开展单目标与多目标寻优, 并利用 SHAP 特征筛选缩小参数空间。研究结果表明, 引入 SHAP 后的优化结果与未引入时基本持平, 这证明可在保证优化效果的前提下, 通过聚焦关键参数降低参数维度, 减少计算资源消耗。本研究系统构建了面向 NOLM 锁模光纤激光器的多代理模型评估体系, 并在此基础上进行 SHAP 驱动模型信任度验证与优化效率提升, 对激光器的参数优化具有较高的指导价值。

关键词: 非线性光学环形镜, 被动锁模光纤激光器, RK4IP 算法, SHAP 算法

PACS: 02.30.Jr, 02.60.-x, 42.65.-k, 42.81.-i

* 基金: 国家自然科学基金 (U2330109, 62405239, 61805212), 江苏省科技计划项目 (FZ20240945), 陕西省创新能力支撑计划 (2025QCY-KXJ-041), 云南省基础研究专项 (202501AS070048) 资助的课题。

† 通信作者. E-mail: hanxiaoxiang@xpu.edu.cn

1 引言

超短脉冲在光纤中传输时,会激发丰富的非线性光学效应,在光纤通信、超快光学、超连续谱产生、光学相干层析等领域具有重要应用^[1-4]。而超快脉冲激光器凭借其极窄脉冲宽度、宽光谱覆盖与高峰值功率的独特优势,在微纳加工、高速通信、精准医疗及前沿科学研究等领域展现出巨大的应用潜力^[5-7]。其中,以稀土掺杂光纤为增益介质的光纤激光器,因其结构紧凑、散热高效、光束质量优异及环境稳定性强等特性,已成为替代传统固体和气体激光系统的重要技术路径。锁模技术作为产生超短脉冲的核心手段,通过锁定谐振腔内各纵模的相位,实现相干叠加,从而输出高峰值功率脉冲^[8]。与依赖外部调制器的主动锁模相比,被动锁模技术利用腔内非线性效应实现脉冲的自启动,显著简化了系统结构,并降低了成本。在众多被动锁模方案中,非线性光学环形镜(Nonlinear Optical Loop Mirror, NOLM)因其全光纤集成、高损伤阈值及宽波段适用性而备受关注^[9,10]。NOLM 是一种基于光强诱导相位调制效应的全光纤器件,其概念于 1988 年由 Doran 等学者首次提出^[11],随后在 1990 年由 Fermann 等人提出非线性放大环形镜(Nonlinear Amplifying Loop Mirror, NALM)^[12]进一步拓展了其应用场景。该类器件以 2×2 光纤耦合器为核心,利用非对称分光结构使相向传输的光脉冲在环路中经历不同的非线性相移。当两束光在耦合器处重新干涉时,脉冲中心高强度部分因相移匹配而产生相长干涉实现透射,边缘弱光部分则因相位失配被抑制反射,从而模拟可饱和吸收体的锁模功能^[13,14]。尽管 NOLM 有效规避了半导体可饱和吸收镜(SESAM)的波长局限与功率损伤阈值限制^[15],其在动态稳定性控制及非线性精细调控方面仍面临挑战,这为引入智能化优化方法提供了契机。

近年来,人工智能与机器学习技术的迅猛发展为复杂物理系统的建模与优化开辟了新途径^[16]。在机器学习模型构建方面,随机森林(Random Forest, RF)作为一种基于决策树的集成学习方法,由 Leo Breiman 和 Adele Cutler 于 2001 年提出^[17],其通过构建多个决策树并结合预测结果,在保持非线性的同时显著降低方差、缓解过拟合的效果,以提高模型的泛化能力^[18];极端梯度提升(eXtreme Gradient Boosting, XGBoost)综合了梯度提升算法和决策树模型的优点,在提高精度和效率的同时防止过拟合^[19];反向传播神经网络(Back Propagation Neural

Network, BPNN) 的训练过程中分为正向传播和反向传播两个阶段, 正向传播用来计算预测误差, 反向传播用来调整各神经元的权重^[20]。随后采用梯度下降法迭代更新权重与偏置, 使误差函数沿梯度方向下降, 直至模型输出与期望输出之间的误差收敛至最小值或满足终止条件^[21-23]; 一维卷积神经网络 (One-Dimensional Convolutional Neural Network, 1D CNN) 则充分利用卷积操作对局部特征的提取能力, 通过层级间的交互作用共同形成了完整的卷积神经网络体系^[24]。遗传算法 (Genetic Algorithm, GA) 是一种模拟自然选择和遗传机制的智能优化算法, 适用于单目标优化问题^[25], 最早由 Holland 在 20 世纪 70 年代提出^[26-27], 目前已广泛应用于函数优化及参数寻优。然而高性能机器学习模型固有的黑箱特性在一定程度上限制了其在科学领域的可信应用^[28]。为此, 可解释性分析方法应运而生^[29], 其中 SHAP (Shapley Additive Explanations) 方法由 Lundberg 和 Lee 提出^[30], 该框架通过量化特征贡献度, 为模型决策过程提供了透明化解释^[31-32]。本研究聚焦于 NOLM 锁模光纤激光器的性能优化, 将数值模拟与可解释机器学习相结合, 系统探究关键参数对输出脉冲特性的影响规律。

本文构建了一种融合 SHAP 可解释性分析的多预测模型。首先, 基于四阶龙格-库塔相互作用表象法 (Runge-Kutta 4th Order Interaction Picture, RK4IP) 对 NOLM 锁模光纤激光器开展数值仿真, 系统分析二阶色散系数、非线性折射率、小信号增益系数、增益光纤饱和功率、增益光纤长度及增益光纤带宽等关键参数对输出脉冲峰值功率、脉冲能量及脉冲宽度的影响, 构建涵盖多维参数空间的仿真数据集。随后, 构建 RF、XGB、BPNN 及 1D CNN 四种机器学习预测模型, 通过集成学习方法建立多机理预测模型, 系统评估各模型对三种脉冲输出特性的预测性能。在此基础上, 引入 SHAP 可解释性框架量化各输入参数的贡献度, 揭示关键特征的主导作用机制。最后, 结合 GA 分别以最大化峰值功率、最大化脉冲能量及最小化脉冲宽度为目标开展参数寻优, 同时利用 SHAP 筛选关键参数来缩小寻优空间以提升 GA 效率与稳定性。本研究可为 NOLM 锁模光纤激光器的高效设计、参数调控与智能优化提供理论依据与方法支撑, 为发展可解释、高性能的智能超快激光系统奠定基础^[33-34]。

2 原理

2.1 NOLM 被动锁模光纤激光器

本研究采用的 NOLM 锁模激光器结构如图 1 (a) 所示, 该激光器包含一段增益光纤^[35]、三段单模光纤^[36]、一个输出光耦合器 (OC)、一个波分复用器 (WDM)、一个隔离器 (ISO) 以及一个以 2×2 耦合器构成的 NOLM。输入光经一个分光比为 50 : 50 的耦合器分为两束强度相等、传播方向相反的光, 这两束光随后在 Sagnac 环中相向传输。由于强度不同, 两束光累积的非线性相位偏移各异。传输一圈后, 两束光在重新返回耦合器的过程中出现了干涉现象, 相位差导致相消干涉。在脉冲功率的横向分布上, 中心区域因自相位调制效应积累较大的非线性相移, 使透射率显著提高; 而边缘区域非线性相移较小, 几乎不经历透射增强, 等效于被反射抑制, 最终形成类似可饱和吸收的作用机制。

为更好的描述光孤子在光纤激光器中的传输状态, 在光纤增益、损耗、色散以及非线性效应等多种物理效应共同作用下, 基于 NLSE 引入增益项, 推导出的方程即为如下金兹堡-朗道方程 (GLE) :

$$\begin{aligned} \frac{\partial A}{\partial z} = & \frac{g_{ss} - \alpha}{2} A - \left(\sum_{k \geq 2} \beta_n \frac{i^{n-1}}{n!} \frac{\partial^n}{\partial T^n} \right) A + i\gamma \left(1 + \frac{1}{\omega_0} \frac{\partial}{\partial T} \right) \\ & \times A \left[|A|^2 + \int_0^\infty h_R(\tau) |A(z, T-t)|^2 d\tau \right] \end{aligned} \quad (1)$$

其中 A 为光场包络函数, 是光脉冲传播距离 z 与传播时间 T 的相关函数; α 是光纤损耗系数; γ 是非线性系数; β_n 是泰勒展开的高阶色散参数; g_{ss} 为增益光纤的小信号增益系数; ω_0 为中心频率; h_R 为拉曼响应函数。当脉冲宽度小于 5 ps 时, 拉曼散射引起的自频移效应很小, h_R 可视为 0, 此时更高阶色散的作用也可忽略不计。

2.2 RK4IP 的介绍与原理

本研究基于 GLE 建立 NOLM 锁模光纤激光器的理论框架, 采用 RK4IP 对脉冲在谐振腔中的演化过程进行数值求解。该方法沿脉冲传输路径依次模拟其通过各光学元件的过程, 完整再现脉冲在谐振腔内往返传播的非线性与色散协同演化, 直至迭代收敛至稳定自洽解, 从而准确描述锁模脉冲的建立动力学及其稳态输出特性。RK4IP 通过相互作用表象变换将色散和非线性算子统合在一起, 通过四阶龙格-库塔格式对非线性部分进行积分, 从而在保证高精度的同时提高计算

效率^[37]。首先对（1）式两边通过傅里叶变换为如下形式：

$$\frac{\partial A}{\partial z} = (\hat{D} + \hat{N})A \quad (2)$$

其中 $\hat{D}$ 是线性差分算符，代表谐振腔中的线性作用，包括了增益和损耗、群速度色散、增益色散等， $\hat{N}$ 为包含自相位调制及拉曼效应等的非线性算子。矢量方程（2）即为 NLSE 在频域中的表现形式。设 $A' = \exp(-\hat{D}z)A$ ，将场变换到相互作用表象，得到：

$$\frac{\partial A'}{\partial z} = \exp(-\hat{D}z)\hat{N}(\exp(\hat{D}z)A') \quad (3)$$

由于方程（3）与 GLE 均为非线性薛定谔类方程，可以用 RK4IP 求解。在实际的光纤激光器系统中，光孤子在光纤中传输同时受到色散效应与非线性效应，在分步傅里叶法数值分析方法中，采用分布式计算，即沿光纤的长度方向，光脉冲每传输一段光纤长度 h ，色散和非线性效应对光脉冲的作用交替发生。光脉冲从光纤 z 处传输到 $z+h$ 处的过程中 RK4IP 的具体迭代方案如以下方程所示^[38]：

$$\begin{aligned} A_1(z, \omega) &= \exp\left(\frac{h}{2}\hat{D}\right)A(z, \omega), \\ k_1 &= \exp\left(\frac{h}{2}\hat{D}\right)\left[h\hat{N}(A(z, \omega))\right]A(z, \omega), \\ k_2 &= h\hat{N}(A_1 + k_1/2)[A_1 + k_1/2], \\ k_3 &= h\hat{N}(A_1 + k_2/2)[A_1 + k_2/2], \\ k_4 &= h\hat{N}\left(\exp\left(\frac{h}{2}\hat{D}\right)(A_1 + k_3)\right)\times \exp\left(\frac{h}{2}\hat{D}\right)[A_1 + k_3], \\ A_1(z+h, \omega) &= \exp\left(\frac{h}{2}\hat{D}\right)\left[A_1 + k_1/6 + k_2/6 + k_3/3\right] + k_4/6 \end{aligned} \quad (4)$$

NLSE 的最终解可通过 RK4IP 迭代方案对各步长进行四阶局部精度积分获得。在此基础上，借助色散与非线性的向量算子，在相互作用表象中利用四阶龙格-库塔方法直接求解矢量方程（3），随后经由迭代格式（4）完成 GLE 的求解。采用矢量形式 RK4IP 算法求解 GLE 时，各步长 h 内不同偏振方向场振幅的迭代运算可实现同步更新，从而提升求解精度与合理性。此外，由于求解在频域中完成，频率相关量可直接由频域表达式计算，有效减少了计算时间与操作步骤。

2.3 SHAP 原理

SHAP 方法基于合作博弈论和 Shapley 值理论，通过分解模型预测结果，将每个特征的贡献值相加，得到最终预测值与基线值的差异。SHAP 算法的主要目标是公平地量化各个特征在模型预测中所起的作用。这种解释方法将所有特征视为对模型预测的贡献者，并计算各特征的贡献值，其总和即为 SHAP 方法下的预测值。该方法具备良好的模型通用性，可对 LightGBM、NGBoost、CatBoost、XGBoost 等多种梯度提升模型及传统机器学习模型进行解释分析^[39]。

在机器学习特征解释中，将每个特征视为参与博弈的“玩家”，模型预测值视为“总收益”。特征 i 的 Shapley 值计算公式为：

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} [f(S \cup \{i\}) - f(S)] \quad (5)$$

其中 F 表示所有特征的集合， S 表示不包含特征 i 的特征子集， $f(S)$ 表示基于特征子集 S 的模型预测值。该公式考虑了特征在所有可能组合中的边际贡献，并加权平均得到公平的贡献分配。

SHAP 算法通过构建可解释的机器学习框架，为复杂模型的决策过程提供了清晰的解读视角，能够将复杂的机器学习模型预测转化为直观的特征贡献度分析，便于不同算法间的比较分析。在解释过程中，SHAP 不仅可量化各输入参数的贡献大小，还能明确区分其对输出结果的正向促进或负向抑制作用。此外通过 SHAP 交互值分析，可以进一步分析不同参数之间的协同或拮抗关系，揭示参数间的耦合作用机制。如图 1（b）所示，本研究的数据集输入为二阶色散系数 β_2 、非线性折射率 n_2 、小信号增益系数 g_{ss} 、增益光纤饱和功率 P_{sat} 、增益光纤长度 L_{AF} 和增益带宽 $\Delta\lambda$ 。输出参数为脉冲的峰值功率，脉冲能量和脉冲宽度。图 1（c）为本研究训练数据集所使用的代理模型，包括 RF、XGB、BPNN 和 1D CNN。图 1（d）为本研究的寻优策略，包括直接优化和引入 SHAP 的优化两种方法。




图 1 NOLM 被动锁模光纤激光器脉冲特性预测与优化示意图 (a) NOLM 激光器结构图; (b) 数据集输入、输出参数选取; (c) 训练数据集所使用的代理模型; (d) 寻优算法思路: 1. 直接优化, 2. 引入 SHAP 进行优化

Figure 1 Schematic diagram of pulse characteristic prediction and optimization for a NOLM passively mode-locked fiber laser: (a) Structural diagram of the NOLM laser; (b) Selection of input and output parameters for the dataset; (c) Surrogate model used for the training dataset; (d) Optimization approach: 1. Direct optimization, 2. SHAP-driven optimization.

3 分析

3.1 激光器模拟仿真

NOLM 被动锁模激光器脉冲的模拟参数如下: NOLM 总长度为 1.5 m, 增益光纤饱和功率为 23.50 dBm, 带宽为 80 nm, 长度为 1.0 m, 非线性折射率为 $2.6 \times 10^{-16} \text{ cm}^2/\text{W}$, 脉冲中心波长为 1030 nm, 二阶色散系数为 $20.2 \text{ ps}^2/\text{km}$, 小信号增益为 37.50 dB, 单模光纤长度 2 m, NOLM 耦合比为 0.3, 输出耦合比为 0.4。以上述参数进行目标激光器的模拟仿真, 当噪声脉冲在腔内传播若干圈后, 最终得到输出稳定的锁模脉冲峰值功率为 1.81 kW, 脉冲能量为 37.0 nJ, 脉冲宽度为 20.92 ps, 如图 2 所示, 图 2 (a) 至 (f) 分别为 NOLM 锁模光纤激光器的时域演化过程、光谱演化过程、孤子演化 3D 图、脉冲特征参数的变化曲线、稳态孤子在谐振腔内演化的时域图和光谱图。由图 2 (a) 可见初始噪声脉冲经过约 30 圈循环后, 时域谱趋于稳定。图 2 (b) 可见初始噪声脉冲经过约 60 圈循环后,

光谱趋于稳定。图 2 (c) 为孤子时域演化的 3D 图，可见脉冲时域曲线逐渐由杂乱状态演化为光滑的双曲正割曲线。图 2 (d) 为脉冲宽度、脉冲能量、光谱宽度与峰值功率的演化过程，可见脉冲宽度、脉冲能量、峰值功率的值在 30 圈左右基本趋于稳定，与图 2 (a) 一致。而光谱宽度在经历一段时间的波动后，于 60 圈附近趋于稳定，与图 2 (b) 一致。图 2 (e) 展示了第 100 圈时孤子在谐振腔不同位置的时域演化过程，可见孤子在 AF 段中能量逐渐累积，当入射光经 2×2 耦合器分为顺时针与逆时针两束，在由 SMF 构成的环形腔中反向传播，孤子脉冲会因自相位调制在两条路径中积累不同的非线性相移，导致两束光在耦合器处发生干涉，从而实现脉冲的窄化。图 2 (f) 为光谱在谐振腔中不同位置的演化过程，可见光谱在 1030 nm 附近形成稳定的主峰，表明孤子脉冲在腔内已经实现了稳定的锁模状态。




图 2 脉冲演化过程图 (a) 时域演化过程; (b) 光谱演化过程; (c) 孤子演化 3D 图; (d) 脉冲特征参数的变化曲线; (e) 稳态孤子在谐振腔内演化的时域图; (f) 稳态孤子演化光谱图

Figure 2 Pulse evolution process diagram. (a) Time-domain evolution process; (b) Spectral evolution process; (c) 3D diagram of soliton evolution; (d) Variation curves of pulse characteristic parameters; (e) Time-domain diagram of steady-state soliton evolution within the resonator cavity;

(f) Spectral diagram of steady-state soliton evolution.

为探究输入参数与 NOLM 被动锁模激光器输出参数的关系，采用控制变量法，固定其他参数，逐一分析二阶色散系数 β_2 、非线性折射率 n_2 、小信号增益系数 g_{ss} 、增益光纤饱和功率 P_{sat} 、增益光纤长度 L_{AF} 及增益带宽 $\Delta\lambda$ 对输出脉冲峰值功率和能量的影响，并通过数值仿真，展示了各参数对脉冲峰值功率及脉冲能量的独立作用机制，如图 4 所示。在本研究所设置的参数空间范围内，不同物理参数对脉冲输出特性的调控作用存在显著差异。当二阶色散系数 β_2 从 $11.2 \text{ ps}^2/\text{km}$ 增至 $29.2 \text{ ps}^2/\text{km}$ （步长 $3 \text{ ps}^2/\text{km}$ ）时，峰值功率由 1.87 kW 线性下降至 1.73 kW ，而脉冲能量仅从 37.8 nJ 下降至 35.5 nJ ，归因于色散增强导致脉冲展宽，但对总能量的积累影响有限。非线性折射率 n_2 从 $2.3 \times 10^{-16} \text{ cm}^2/\text{W}$ 增加至 $2.9 \times 10^{-16} \text{ cm}^2/\text{W}$ （步长 $0.1 \times 10^{-16} \text{ cm}^2/\text{W}$ ）时，峰值功率由 1.99 kW 降至 1.65 kW ，脉冲能量从 36.1 nJ 升至 37.7 nJ ，其原因为非线性相移拓宽了光谱，经光谱滤波效应后降低了峰值功率，有利于能量积累。小信号增益系数 g_{ss} 从 36 dB 增至 39 dB （步长 0.5 dB ）时，峰值功率从 15.5 kW 增至 18.8 kW ，而脉冲能量由 20.2 nJ 显著增至 58.4 nJ 。类似地，增益光纤饱和功率 P_{sat} 从 22 dBm 增至 25 dBm （步长 0.5 dBm ）及增益光纤长度 L_{AF} 从 0.7 m 增至 1.3 m （步长 0.1 m ）时，峰值功率和脉冲能量均呈正相关，其中峰值功率分别增至 1.87 kW 和 1.88 kW ，脉冲能量分别增至 54.6 nJ 和 54.8 nJ ，表明减弱增益饱和与延长增益光纤长度有助于能量积累。相比之下，增益光纤带宽 $\Delta\lambda$ 从 50 nm 增至 110 nm 时，峰值功率仅从 1.84 kW 微降至 1.80 kW ，脉冲能量从 36.1 nJ 略增至 37.3 nJ ，影响较弱。综上所述，在所考察的参数空间内，各参数对输出特性的影响呈现差异化特征：二阶色散系数的增大使峰值功率降低，但对脉冲能量的影响较小；非线性折射率的增大会抑制峰值功率，同时有助于脉冲能量的提升；小信号增益系数、增益光纤饱和功率及增益光纤长度对峰值功率和脉冲能量均具有显著调控作用，但其效果受增益饱和效应的制约；增益光纤带宽对各输出指标的影响则较为微弱。




图 3 各项参数与输出脉冲的峰值功率和能量关系 (a) 二阶色散系数; (b) 非线性折射率; (c) 小信号增益系数; (d) 增益光纤饱和功率; (e) 增益光纤长度; (f) 增益光纤带宽与输出脉冲关系

Figure 3 Relationships between various parameters and the peak power and energy of the output pulse: (a) Second-order dispersion coefficient; (b) Nonlinear refractive index; (c) Small-signal gain coefficient; (d) Saturation power of the gain fiber; (e) Length of the gain fiber; (f) Bandwidth of the gain fiber versus output pulse characteristics.

3.2 代理模型分析

针对 NOLM 被动锁模激光器的锁模预测, 本研究构建并评估了四种不同类型的代理模型: RF、XGB、BPNN 及 1D CNN。各模型的预测性能结果如表 1 所示。其中 RPD(Ratio of Performance to Deviation)为测试集样本标准差与 RMSE 的比值, 用于衡量模型的分辨力与预测稳定性。通常 $RPD \geq 3.0$ 表示模型预测能力优异, $RPD \geq 5.0$ 表示极佳。

本研究通过均匀随机采样方法生成 500 组参数组合, 涵盖 6 个输入参数, 具体参数空间如 3.1 节中所示。各参数在指定范围内独立服从均匀分布, 确保参数空间的广泛覆盖。将全部 500 组样本按 8:2 的比例随机划分为训练集 (400 组) 和测试集 (100 组), 由于未额外进行交叉验证, 为保证结果可重复性, 采用固定随机种子进行划分。其中训练集用于代理模型训练与遗传算法优化中的适应度评估, 测试集用于模型性能的独立验证。

针对不同机器学习所使用的代理模型，其超参数设置如下：RF 采用 100 棵决策树集成，最大深度限制为 10 层，内部节点分裂所需最小样本数为 5，叶子节点最少样本数为 2。该配置在模型复杂度与泛化能力之间取得了良好平衡，避免了单棵决策树的过拟合风险。XGB 模型采用 500 棵决策树集成，最大深度设为 8 层，学习率为 0.05，并引入行采样（样本比例 0.8）、列采样（树级、层级样本比例均为 0.8）以及正则化参数 $L1 = 0.1$ 、 $L2 = 1.0$ ，以更有效地控制模型复杂度并提升预测精度。BPNN 采用 4 层全连接架构，包含三个隐藏层，神经元数量分别为 16、8 和 4，输出层为单神经元回归头。隐藏层均采用 ReLU 激活函数以缓解梯度消失问题。模型采用 Adam 优化器，初始学习率设为 0.001，训练轮数为 150 轮，批大小为 32，并使用 10% 的验证集进行早停监控（耐心值为 20 轮）。1D CNN 由两个卷积层和两个全连接层交替构成。第一卷积层包含 8 个滤波器，第二卷积层包含 4 个滤波器，卷积核大小均为 2。特征图经 Flatten 展平后接入 8 神经元和 4 神经元的全连接层，最终输出单值预测结果。所有隐藏层均采用 ReLU 激活，采用 Adam 优化器（学习率 0.001），训练 120 轮，批大小 32。上述模型均采用 Min-Max 归一化对输入特征和目标变量进行 [0,1] 区间缩放，以加速训练收敛并消除量纲影响。所有模型的损失函数均设为均方误差。

在峰值功率预测任务中，不同代理模型的泛化能力差异明显。其中，BPNN 在测试集上取得了 $R^2 = 0.951$ 、 $RPD = 4.560$ ，且训练集与测试集性能差距较小，表明其具有最强的泛化能力和预测稳定性。相比之下，XGB 在训练集上拟合效果极佳（ $R^2 = 0.981$ ），但测试集 R^2 下降至 0.866，RPD 仅为 2.739，训练与测试性能差距明显，存在显著的过拟合倾向。1D CNN 在峰值功率预测中整体表现较弱，训练与测试集 R^2 均低于 0.85，虽无明显过拟合，但预测能力有限。在脉冲能量预测方面，RF 与 XGB 在训练集上均表现出极高拟合精度（ $R^2 > 0.99$ ），但在测试集上性能均出现不同程度下降。以 RF 为例，其训练集 RPD 高达 10.76，而测试集 RPD 降至 5.033，相对下降明显，说明模型存在一定的过拟合现象。BPNN 与 1D CNN 则表现出良好的泛化一致性，测试集 R^2 均保持在 0.98 以上，RPD 均高于 7.3，说明二者具备较强的分辨力与稳定预测能力，未出现过拟合迹象。在脉冲宽度预测中，1D CNN 表现最优，测试集 R^2 高达 0.996，RPD 达到 15.941，显示出极高的预测精度与模型分辨力。BPNN 同样表现优异，测试集 R

²为 0.994, RPD 为 13.361。相比之下, RF 与 XGB 在测试集上的 R^2 均低于 0.91, RPD 分别仅为 3.433 和 3.142, 预测能力相对有限。

综合上述分析, XGB 在多个预测任务中均表现出明显的过拟合倾向, RF 在部分任务中也存在一定过拟合; 而 BPNN 与 1D CNN 在不同参数预测中均展现出较好的泛化一致性与预测可靠性, 其中 BPNN 在峰值功率预测中泛化能力最强, 1D CNN 则在脉冲宽度预测中表现最为突出。

表 1 预测效果评价指标结果

Table 1. Results of the prediction performance evaluation metrics							
参数	模型	数据组	R^2	RMSE	MAE	MAPE	RPD
峰值功率(W)	RF	训练集	0.9440	52.74	30.96	0.0208	4.226
		测试集	0.8228	84.16	52.73	0.0331	2.379
	XGB	训练集	0.9809	30.83	19.12	0.0123	7.230
		测试集	0.8664	73.09	50.83	0.0312	2.739
	BPNN	训练集	0.9511	49.28	32.82	0.0208	4.526
		测试集	0.9513	44.15	32.64	0.0200	4.560
	1D CNN	训练集	0.8303	91.80	67.05	0.0425	2.428
		测试集	0.8442	78.92	60.29	0.0359	2.542
	RF	训练集	0.9914	1736.9	1276.3	0.0426	10.76
		测试集	0.9594	3706.5	2944.6	0.0901	5.033
脉冲能量(pJ)	XGB	训练集	0.9925	1616.7	1072.8	0.0407	11.57
		测试集	0.9531	3979.5	3181.7	0.1011	4.620
	BPNN	训练集	0.9824	2479.1	1892.9	0.0622	7.549
		测试集	0.9813	2515.6	1916.8	0.0527	7.310
	1D CNN	训练集	0.9839	2376.2	1866.2	0.0614	7.934
		测试集	0.9823	2446.2	1964.5	0.0598	7.644
	RF	训练集	0.9794	1.12	0.80	0.0500	6.975
		测试集	0.9097	2.49	1.92	0.0864	3.433
	XGB	训练集	0.9866	0.91	0.55	0.0401	8.638
		测试集	0.8969	2.67	1.92	0.0862	3.142
脉冲宽度(ps)	BPNN	训练集	0.9841	0.99	0.61	0.0496	7.942
		测试集	0.9940	0.64	0.49	0.0251	13.36
	1D CNN	训练集	0.9887	0.83	0.47	0.0416	9.440
		测试集	0.9957	0.55	0.40	0.0216	15.94

3.3 遗传算法寻优

为了寻找参数空间中的更优解，本研究基于遗传算法进行全局寻优。该算法在六维可调参数空间内实现高效搜索，获得目标优化的最优参数组合。为获得综合性能最优的参数配置，本研究首先针对峰值功率、脉冲能量与脉冲宽度，以 RF、XGB、BPNN 及 1D CNN 为代理模型分别进行多目标寻优，主要用于展示不同代理模型在综合性能指标下的寻优能力，用于筛选适配本系统非线性映射的最优代理模型。

在遗传算法的寻优设置中，算法采用模拟二进制交叉（分布指数 20）、多项式变异（变异概率 0.1，分布指数 20）、锦标赛选择（规模=3），并启用精英保留策略，保证每代最优个体完整保留。算法统一采用滑动窗口收敛判定（窗口长度=15），避免迭代初期随机震荡造成伪收敛。为适配不同目标的优化稳定性，差异化设置收敛判据。对于峰值功率优化，设置收敛容忍度 2%，最小收敛代数 10 代。对于脉冲能量优化，能量数值波动敏感，采用严格收敛判据（容忍度 0.5%，最小收敛代数 30 代）。对于脉冲宽度优化，锁模约束严苛，采用高精度判据（容忍度 0.2%，最小收敛代数 20 代）。上述参数设置确保了各优化任务在收敛可靠性与计算效率之间的合理平衡。

算法初始化随机生成规模为 50 的种群，经过 100 代迭代与四个随机种子的遍历，最终输出一组在定义域内且具有最高适应度值的参数组合，适应度是遗传算法中衡量参数组合优劣的量化指标，值越大表示该参数组合越优。适应度函数采用加权归一化方式构建，其中峰值功率与脉冲能量为正向优化指标，以对应物理边界内的上限值为基准进行归一化；脉冲宽度为负向优化指标，以对应物理边界内的下限值为基准进行归一化处理。

对于 NOLM 被动锁模光纤激光器系统，峰值功率、脉冲能量和脉冲宽度是三个核心性能指标，其权重设置是结合参数可调区间、系统优化敏感度与超快激光工程应用优先级确定。首先，峰值功率与脉冲能量的权重各 0.4，合计 0.8。二者是决定超快激光非线性变换效率、微纳加工阈值、材料作用强度的核心决定性指标。在本文参数空间内，峰值功率（1.5~2.2 kW）与脉冲能量（20~140 nJ）动态变化范围大、对系统参数敏感度高，是提升激光器综合输出性能的首要优化目标。其次，脉冲宽度的权重为 0.2。在本研究 NOLM 锁模约束条件下，脉宽可调区间仅为 10~65 ps，参数可调裕度远小于能量类指标。同时，在满足窄脉冲锁模

输出的前提下，脉宽进一步压缩的工程边际收益有限，系统优先保障能量输出能力更符合实际应用需求。在满足物理约束的搜索范围内开展全局寻优，寻优结果如表 2 所示。其中 RF 模型的适应度为 0.819，表明该模型对参数与输出之间复杂非线性关系的拟合能力相对有限；XGB 模型的适应度为 0.867，说明基于梯度提升决策树的集成学习策略能够更有效地捕捉参数空间中的非线性映射关系；BPNN 模型的适应度达到 0.927，表明其多层非线性变换结构能够更精细地刻画输入参数与输出响应之间的内在关联；1D CNN 模型取得了最高的适应度值 0.968，该模型通过卷积提取参数局部特征，结合深层网络结构，有效引导遗传算法收敛至全局最优参数组合附近。

表 2 多目标寻优及对应参数设置

Table 2. Global parameter combination optimization and corresponding output parameters									
预测算法	β_2 (ps ² /km)	n_2 ($\times 10^{-16}$ cm ² /W)	g_{ss} (dB)	P_{sat} (dBm)	L_{AF} (m)	$\Delta\lambda$ (nm)	Peak Power (W)	Pulse Energy (nJ)	Pulse duration (ps)
RF	17.6465	2.5421	38.4318	24.9365	1.284	80.4560	1928.35	100.2522	52.97
XGB	18.6472	2.8600	38.8298	24.9748	1.225	103.4815	1798.66	104.9051	61.99
BPNN	22.6461	2.8998	38.9982	24.9950	1.297	92.3847	2202.89	118.0970	40.90
1D CNN	26.7962	2.4569	38.9982	24.9950	1.297	100.6097	2143.77	117.5785	59.38

为了分别实现对峰值功率、脉冲能量和脉冲宽度的定向优化，本研究将数据集划分为 80% 的训练集和 20% 的测试集后，以 RF、XGB、BPNN 及 1D CNN 为代理模型分别采用遗传算法进行单目标优化。单目标优化分别针对峰值功率、脉冲能量、脉冲宽度三个独立目标，单目标优化的结果则用于后续的 SHAP 分析，以揭示不同输出特性下各输入参数的重要性与贡献方向。为体现降维后搜索空间缩减所带来的计算效率优势，第二阶段在关键参数筛选、无效参数固定的降维参数空间内开展精细寻优。由于变量维度降低、参数约束更严格、寻优空间显著缩小，无需全域大范围搜索，因此采用轻量化 GA 配置：种群规模 30、最大迭代 60、收敛容忍度 1.0%、滑动窗口 15、最小收敛代数 30。交叉、变异、选择、精英保留策略与第一阶段完全一致。该配置在保证收敛精度的前提下，大幅降低二次精细优化的计算成本，实现精度与效率的平衡，从而得到表 3 所示的参数组合，再令这些参数组合通过 NOLM 被动锁模激光器谐振腔内进行 300 圈循环，得到针对不同性能指标的脉冲最优结果。对比表 2 与表 3 可见，经不同代理模型结合遗传算法的优化效果存在明显差异。在峰值功率优化中，1D CNN 模型表现最优，

输出功率达 2148.43 W。在脉冲能量优化中，BPNN 与 1D CNN 模型结果一致，脉冲能量均达 137.3251 nJ。在脉冲宽度优化中，XGB 模型最优，获得 11.07 ps 的最小脉冲宽度。通过对不同代理模型所获得的寻优参数进行对比，可以发现 BPNN 与 1D CNN 在对峰值功率和脉冲能量的参数寻优中，对于 g_{ss} 、 P_{sat} 及 L_{AF} 三组参数所寻优的结果一致，因为二者均为前馈式监督学习网络，且训练均基于反向传播与梯度下降优化。

表 3 不同代理模型的算法寻优

Table 3. Global parameter combination optimization and corresponding output parameters										
预测算法		β_2 (ps ² /km)	n_2 ($\times 10^{-16}$ cm ² /W)	g_{ss} (dB)	P_{sat} (dBm)	L_{AF} (m)	$\Delta\lambda$ (nm)	Peak Power (W)	Pulse Energy (nJ)	Pulse duration (ps)
峰值 功率	RF	11.4092	2.3135	38.9908	24.9033	1.114	62.0781	2119.63	95.4847	46.03
	XGB	11.7623	2.3105	38.7356	24.9945	1.075	55.4216	2118.80	86.8059	41.87
	BPNN	11.2911	2.3028	38.9982	24.9950	1.297	50.0007	2133.29	118.9603	56.75
	1D CNN	11.2911	2.3028	38.9982	24.9950	1.297	78.5876	2148.43	119.0599	57.19
脉冲 能量	RF	18.3389	2.5525	38.7533	24.9530	1.285	80.4052	1923.70	109.6891	58.07
	XGB	20.5196	2.8754	38.8330	24.8686	1.244	102.355	1785.10	104.8742	61.90
	BPNN	26.2668	2.8998	38.9982	24.9950	1.297	109.869	2054.35	137.3251	62.74
	1D CNN	26.1258	2.8998	38.9982	24.9950	1.297	109.869	2054.35	137.3251	62.74
脉冲 宽度	RF	11.2911	2.7508	36.4811	22.9402	1.087	77.7171	1569.95	25.4391	16.46
	XGB	26.7948	2.4690	36.0745	22.1436	1.107	83.4286	1330.81	14.8872	11.07
	BPNN	28.4219	2.4080	36.3627	22.6153	1.177	105.775	1668.06	23.8087	14.38
	1D CNN	14.9268	2.8196	37.0751	22.8299	0.877	107.040	1571.23	21.3490	15.00

3.4 SHAP 分析

本文分别以 RF、XGB、BPNN 及 1D CNN 四种代理模型为基础，通过 SHAP 可解释性分析框架对模型进行特征重要性评估与决策机制的可视化，可得不同输入参数对 NOLM 被动锁模激光器峰值功率、脉冲能量及脉冲宽度三大输出特性的影响规律。在 SHAP 可解释性分析框架的基础上，本研究将遗传算法的优化目标分别设为峰值功率最大化、脉冲能量最大化与脉冲宽度最小化，依次进行了三组独立寻优。

图 4 分别给出了四种代理模型针对峰值功率、脉冲能量及脉冲宽度的 SHAP

特征重要性条形图和贡献图。该图以双坐标形式直观反映特征对模型输出的贡献机制：横轴为 SHAP 值，其正负表示该特征对预测结果的推动方向，正值使输出增大，负值使输出减小，绝对值大小表征贡献强度；纵轴按特征重要性由上至下排列，括号内百分比为该特征 SHAP 绝对值均值占全部特征 SHAP 绝对值总和的比例，用于定量表征相对重要性。图中颜色映射表示特征值大小，暖色代表高特征值，冷色代表低特征值。依据纵轴排列顺序与百分比，可判断特征重要性排序。依据 SHAP 值的正负分布，可判断特征对输出的贡献方向。结合颜色分布与 SHAP 值位置，可揭示高/低特征值的影响模式。依据 SHAP 值的横向离散程度，可判断该特征对输出结果的影响幅度。

SHAP 分析结果可知，四种代理模型的特征重要性整体趋势一致，模型预测行为均由少数关键输入参数主导。对于图 4 的峰值功率来说，四种代理模型中非线性折射率 n_2 均为最重要的影响因素，其贡献度分别为 36.9 % (RF)、29.3 % (XGB)、26.2 % (BPNN)、24.0 % (1D CNN)；其次是小信号增益系数 g_{ss} ，分别为 23.8 %、22.2 %、23.1 %、22.4 %；饱和功率 P_{sat} 、二阶色散系数 β_2 与增益光纤长度 L_{AF} 影响较弱，且贡献度在 RF 与 XGB 中基本持平；而增益光纤带宽 $\Delta\lambda$ 的贡献度最低，分别为 1.2 % (RF)、1.6 % (XGB)、2.8 % (BPNN)、2.3 % (1D CNN)，对峰值功率输出的影响可基本忽略。图 4 (e) 与 (f) 分别为 1D CNN ($R^2 = 0.9651$) 对贡献最高的参数 g_{ss} 与 n_2 所绘制的 SHAP 依赖图，由图可知在参数空间内， g_{ss} 对峰值功率的输出为正相关， n_2 则为负相关，此结果与图 3 (b)、(c) 所体现的参数关系亦相符合。




图4 关于峰值功率的 SHAP 特征重要性条形图及特征贡献图

Figure 4 SHAP feature importance bar charts and feature contribution plots for peak power

对于图 5 的脉冲能量预测，重要性排名前三的特征分别为 g_{ss} , L_{AF} 与 P_{sat} ，其中 g_{ss} 在四种代理模型中贡献度占比较高，分别为 38.2 % (RF)、35.8 % (XGB、BPNN)、34.7 % (1D CNN)； L_{AF} 与 P_{sat} 的贡献度较为接近，均在 30 % 左右，表明模型预测主要由这三个关键特征主导；而 β_2 , n_2 与 $\Delta\lambda$ 的贡献度均较低，仅在 0.5 % 到 2.5 % 之间，说明这三者对脉冲能量输出的影响可基本忽略。图 5 (e) 与 (f) 分别为 1D CNN ($R^2 = 0.9874$) 对贡献最高的参数 g_{ss} 与 L_{AF} 所绘制的 SHAP 依赖图，可知在参数空间内， g_{ss} 与 L_{AF} 对脉冲能量的输出均为正相关，此结果与图 3 (c)、(e) 所体现的参数关系亦相符合。




图 5 关于脉冲能量的 SHAP 特征重要性条形图及特征贡献图

Figure 5 SHAP feature importance bar charts and feature contribution plots for pulse energy

对于图 6 所示的脉冲宽度预测，输出同样主要由 g_{ss} , L_{AF} , P_{sat} 这三个关键特征驱动，其中 g_{ss} 的贡献度 36.2 % (RF)、33.1 % (XGB)、32.8 % (BPNN)、32.9 % (1D CNN)， L_{AF} 与 P_{sat} 的贡献度均在 25 % 到 30 % 之间； n_2 的贡献度相对较弱，处于 4.7 % (RF) 到 8.6 % (BPNN、1D CNN) 左右； β_2 与 $\Delta\lambda$ 的贡献度均较低，在四类模型中均不超过 2.5%，表明这二者对脉冲能量输出的影响可基本忽略。图 6 (e) 与 (f) 分别为 1D CNN ($R^2 = 0.9921$) 对贡献最高的参数 g_{ss} 与 L_{AF} 所绘制的 SHAP 依赖图，可知在参数空间内， g_{ss} 与 L_{AF} 对脉冲宽度的影响均为正相关，此结果与图 3 (c)、(e) 所体现的参数关系亦相符合。




图 6 关于脉冲宽度的 SHAP 特征重要性条形图及特征贡献图

Figure 6 SHAP feature importance bar charts and feature contribution plots for pulse width

在此基础上，本研究引入 SHAP 特征贡献度，固定贡献度小于 5 % 的参数为 NOLM 锁模激光器未经优化的初始数值，如在峰值功率的寻优中将 $\Delta\lambda$ 固定为 80.0 nm；在脉冲能量的寻优中固定 β_2 为 20.2 ps²/km、 n_2 为 2.6×10^{-16} cm²/W、 $\Delta\lambda$ 为 80.0 nm；脉冲宽度则固定 β_2 为 20.2 ps²/km、 $\Delta\lambda$ 为 80.0 nm。随后再次使用遗传算法进行寻优，从而得到表 4 所示结果。

表 4 不同代理模型结合 SHAP 的算法寻优

Table 4. Genetic algorithm optimization combining different surrogate models with SHAP									
预测算法	β_2 (ps ² /km)	n_2 ($\times 10^{-16}$ cm ² /W)	g_{ss} (dB)	P_{sat} (dBm)	L_{AF} (m)	$\Delta\lambda$ (nm)	Peak Power (W)	Pulse Energy (nJ)	Pulse Duration (ps)
峰值 功率	RF	22.3627	2.3124	38.4784	24.2531	1.244 0	2112.08	82.4549	39.96
	XGB	22.3742	2.3478	38.4632	24.1805	1.242 0	2079.82	80.5657	39.64
	BPNN	28.7495	2.3028	38.9747	24.5556	1.268 0	2131.86	103.8569	49.75
	1D CNN	12.2729	2.4871	38.1657	24.9338	1.294 0	1972.55	94.2799	48.81
脉冲 能量	RF			38.8136	24.6247	1.289 0	1886.93	103.6015	55.93
	XGB	20.2	2.6	38.7866	24.6803	1.274 0	1891.46	105.2533	56.6
	BPNN	(固定)	(固定)	38.9982	24.9950	1.297 0	1969.66	118.7327	63.84
	1D CNN			38.9982	24.9950	1.297 0	1969.66	118.7327	63.84
脉冲 宽度	RF		2.6213	37.3023	23.0546	0.900	1644.75	24.6034	15.7
	XGB	20.2	2.5642	37.4962	22.7155	0.839	1570.58	21.2939	13.65
	BPNN	(固定)	2.5801	36.3341	23.1390	1.073	1621.24	23.8643	15.26
	1D CNN		2.5876	36.2918	23.3446	1.062	1629.59	24.8626	15.5

对比表 3 与表 4，将表 3 的全参数空间作为第一阶段寻优，表 4 的降维参数空间作为第二阶段寻优，得到表 5 的两阶段寻优对比，可以发现在引入 SHAP 特征筛选进行参数空间降维之后，遗传算法的寻优结果与全参数优化的结果在数值上非常接近。在峰值功率优化中，RF 与 BPNN 输出的性能保持率均在 99 % 以上，寻优所用时间均减少 63 % 以上；在脉冲能量优化中，各神经网络的性能保持率均在 86 % 以上，时间加速率也基本超过 60 %；在脉冲宽度优化中，XGB 的性能保持率为 81.1 %，其他三项以上均超过 94 % 以上。

表 5 两阶段寻优的结果及效率对比

Table 5. Comparison of results and efficiency of two-stage optimization									
预测算法	第一阶段 峰值功率 (W)	第二阶段 峰值功率 (W)	性能 保持 率(%)	第一阶段 平均收敛 代数	第二阶段 平均收敛 代数	加速 率 (%)	第一阶段 平均时间 (s)	第二阶段 平均时间 (s)	时间加 速率 (%)

RF	2119.63	2112.08	99.64	50	30	40	154.86	56.16	63.7
XGB	2118.8	2079.82	98.16	50	30	40	5.19	1.68	67.7
BPNN	2133.29	2131.86	99.93	50.2	30	40.3	320.19	116.21	63.7
1D CNN	2148.43	1972.55	91.81	72.5	30	58.6	325.7	114.97	64.7
预测算 法	第一阶段 脉冲能量 (nJ)	第二阶段 脉冲能量 (nJ)	性能 保持 率(%)	第一阶段 平均收敛 代数	第二阶段 平均收敛 代数	加速 率 (%)	第一阶段 平均时间 (s)	第二阶段 平均时间 (s)	时间加 速率 (%)
RF	109.6891	103.602	94.45	50	45.5	9	153.27	55.91	63.5
XGB	104.8742	105.253	99.64	50	33	34	4.96	1.93	61.1
BPNN	137.3251	118.733	86.46	94	60	36.2	322.33	116.05	64
1D CNN	137.3251	118.733	86.46	95.2	60	37	327.99	114.89	65
预测算 法	第一阶段 脉冲宽度 (ps)	第二阶段 脉冲宽度 (ps)	性能 保持 率(%)	第一阶段 平均收敛 代数	第二阶段 平均收敛 代数	加速 率 (%)	第一阶段 平均时间 (s)	第二阶段 平均时间 (s)	时间加 速率 (%)
RF	16.46	15.7	95.38	50	33.5	33	154.33	56.05	63.7
XGB	11.07	13.65	81.1	50	30	40	5.17	1.6	69.1
BPNN	14.38	15.26	94.23	50	30	40	319.83	116.55	63.6
1D CNN	15	15.5	96.77	50	30	40	325.46	115.19	64.6

上述结果表明，在引入 SHAP 分析进行关键参数筛选后，模型优化性能并未出现明显下降，各输出指标均保持在较高水平。可见基于 SHAP 特征重要性排序的参数降维策略，能够在保证优化精度的前提下，有效降低参数空间维度，减少遗传算法的搜索范围与计算开销，提升优化效率。因此，SHAP 可解释性分析不仅能够揭示激光器内部物理作用机制，也可为超快激光器的高效参数优化提供可靠依据。综上，多目标优化用于模型筛选与算法性能评估，单目标优化用于物理机理解耦、SHAP 参数归因与后续精细优化，二者互为补充，构成完整的“建模-寻优-解释-降维优化”研究框架。

4 结 论

本文围绕 NOLM 锁模光纤激光器的智能参数优化，结合 RK4IP 数值模拟、多机理机器学习代理模型、SHAP 可解释性分析及遗传算法，系统开展了两个阶段的脉冲特性预测与优化研究，其中多目标优化用于评估模型在综合任务中的表现；单目标优化则用于解耦不同物理量的响应机制，便于 SHAP 分析，两者互为补充，前者验证模型泛化能力，后者则应用于可解释性分析。在引入 SHAP 特征

筛选进行参数空间降维后,不同的神经网络预测算法对激光器的各项输出依然能维持较高的水平:峰值功率的性能保持率 81.1 %到 99.64 %,脉冲能量性能保持率 86.46 %到 99.64 %,脉冲宽度性能保持率 86.46 %到 96.77 %;同时在一定程度上提高计算效率,减少 60 %到 70 %的计算时间。综上说明,基于 SHAP 特征重要性排序的参数降维策略,能够在保证优化精度的前提下有效降低参数空间维度与计算成本。其次,SHAP 可解释性分析也揭示了各参数对输出特性的差异化贡献机制:非线性折射率与小信号增益系数主导峰值功率变化;小信号增益系数、增益光纤长度及饱和功率是决定脉冲能量与宽度的核心因素,而增益带宽与二阶色散系数的影响可忽略不计。综上结果表明,该策略在不损失优化性能的前提下,显著降低了参数空间维度与计算成本。本研究针对 NOLM 锁模光纤激光器搭建多代理模型综合评估框架,依托 SHAP 可解释性分析完成模型可信度校验,同步提升参数寻优效率,可为该类激光器的参数优化设计提供重要理论与工程指导。

参考文献

- [1] Dudley J, Taylor J 2010 *Supercontinuum Generation in Optical Fibers* (Cambridge: Cambridge University Press)
- [2] Agrawal G P 2010 *Principles and Applications of Nonlinear Fibre Optics* (Beijing: Electronic Industry Press) pp18-109 (in Chinese) [阿戈沃 G P 著 2010 非线性光纤光学原理及应用 (北京: 电子工业出版社) 第18-109页]
- [3] Povazay B, Bizheva K, Unterhuber A, Hermann B, Sattmann H, Fercher A F, Drexler W, Apolonski A, Wadsworth W J, Knight J C, Russell P St J, Vetterlein M, Scherzer E 2002 *Opt. Lett.* **27** 1800
- [4] Paulsen H N, Hilligsøe K M, Thøgersen J, Keiding S R, Larsen J J 2003 *Opt. Lett.* **28** 1123
- [5] Ma C Y, Tian X J, Gao B, Wu G 2018 *Opt. Commun.* **406** 177
- [6] Guo Y Y, Xu Y, Zhang J J, Zhang Z X 2019 *Optik* **181** 13
- [7] Chen Y, Jiang G B, Chen S Q, Guo Z N, Yu X F, Zhao C J, Zhang H, Bao Q L, Wen S C, Tang D Y, Fan D Y 2015 *Opt. Express* **23** 12823
- [8] Haus H 2000 *IEEE J. Sel. Top. Quantum Electron.* **6** 1173
- [9] Zhou J Q, Pan W W, Zhang L, Gu X J, Feng Y 2019 *Chin. J. Las.* **46** 0508013 (in Chinese) [周佳琦, 潘伟巍, 张磊, Gu Xijia, 冯衍 2019 中国激光 **46** 0508013]
- [10] Dudley J M, Genty G, Coen S 2006 *Rev. Mod. Phys.* **78** 1135
- [11] Doran N, Wood D 1988 *Opt. Lett.* **13** 56
- [12] Fermann M E, Haberl F, Hofer M, Hochreite H 1990 *Opt. Lett.* **15** 752
- [13] Li Z H 2025 M.S. Thesis (Nanjing: Nanjing University of Information Science and Technology) (in Chinese) [李正恒 2025 硕士学位论文 (南京: 南京信息工程大学)]
- [14] Liang X 2024 M.S. Thesis (Changchun: Jilin University) (in Chinese) [梁雪 2024 硕士学位论文 (长春: 吉林大学)]

- [15] Paschotta R, Keller U 2001 *Appl. Phys. B* **73** 653
- [16] Bao Y Q, Li H 2019 *China Civil Engineering Journal* **52** 1 (in Chinese) [鲍跃全, 李惠 2019 土木工程学报 **52** 1]
- [17] Wu K H, Guo Z X, Fan Y F, Xie J, Tao M L 2025 *J. Electron. Inf. Technol.* **47** 4862 (in Chinese) [吴康徽, 郭子薰, 范一飞, 谢坚, 陶明亮 2025 电子与信息学报 **47** 4862]
- [18] Yang Y, Sun Y, Li F, Guan B X, Liu J X, Shang J L 2024 *IEEE Trans. Neural Netw. Learn. Syst.* **35** 15701
- [19] Yuan T, Song J S, Xu X J, Tian Q, Huang H 2025 *Mod. Manag.* **45** 69 (in Chinese) [袁涛, 宋加山, 胥兴军, 田祺, 黄寰 2025 管理现代化 **45** 69]
- [20] Li B T, Xu Y C, Yu Z W, Xiong Z Y, Sun Y L, Yang P, Yuan W H, Liu K 2024 *J. Hubei Inst. Technol.* **40** 10 (in Chinese) [李博通, 徐彦呈, 于志伟, 熊正阳, 孙云龙, 杨鹏, 袁文豪, 柳奎 2024 湖北理工学院学报 **40** 10]
- [21] Jiang Y H, Qiao Z L, Li D, Ren S J, Si F Q 2025 *Therm. Power Gener.* **54** 126 (in Chinese) [姜宇恒, 乔宗良, 李逗, 任少君, 司凤琪 2025 热力发电 **54** 126]
- [22] Wang L, Wang R L, Qu H F, Xuan Y 2016 *Softw. Guide* **15** 38 (in Chinese) [王磊, 王汝凉, 曲洪峰, 玄扬 2016 软件导刊 **15** 38]
- [23] Bi X Y, Li S D, Hao M Y 2025 *Clean Coal Technol.* **31** 74 (in Chinese) [毕小云, 李尚达, 郝梦媛 2025 洁净煤技术 **31** 74]
- [24] Gu J X, Wang Z H, Kuen J, Ma L Y, Shahroudy A, Shuai B, Liu T, Wang X X, Wang G, Cai J F, Chen T 2018 *Pattern Recognit.* **77** 354
- [25] Xu P Y 2025 M.S. Thesis (Beijing: Beijing University of Posts and Telecommunications) (in Chinese) [许盼英 2025 硕士学位论文 (北京: 北京邮电大学)]
- [26] Schafer J D 1985 *Proceedings of the 1st International Conference on Genetic Algorithms* (Lawrence: Erlbaum) p93
- [27] Holland J H 1975 *Adaptation in Nature and Artificial Systems* (Cambridge, MA: MIT Press)
- [28] Meng X F, Hao X L, Ma C H, Yang C, Aishan Maolinianzi, Wu C, Wei J Y 2023 *Chin. J. Comput.* **46** 877 (in Chinese) [孟小峰, 郝新丽, 马超红, 杨晨, 艾山·毛力尼亚孜, 吴潮, 魏建彦 2023 计算机学报 **46** 877]
- [29] Barredo Arrieta A, Díaz-Rodríguez N, Del Ser J, Bennetot A, Tabik S, Barbado A, Garcia S, Gil-Lopez S, Molina D, Benjamins R, Chatila R, Herrera F 2020 *Inf. Fusion* **58** 115
- [30] Lundberg S, Lee S 2017 *31st Conference on Neural Information Processing Systems* (NIPS 2017) Long Beach, CA, USA, 2017 p1
- [31] Lundberg S M, Erion G, Chen H, DeGrave A, Prutkin J M, Nair B, Katz R, Himmelfarb J, Bansal N, Lee S I 2020 *Nat. Mach. Intell.* **2** 56
- [32] Wei J G, Wu X Z, Zheng Y, Yang Y 2025 *Journal of Southeast University (Natural Science Edition)* **55** 1328 (in Chinese) [韦建刚, 吴洵楨, 郑裔, 杨艳 2025 东南大学学报(自然科学版) **55** 1328]
- [33] Dong Z K, Song Y R 2021 *Chinese Journal of Lasers* **48** 98 (in Chinese) [董自凯, 宋晏蓉 2021 中国激光 **48** 98]
- [34] Yang J H, Dai S X, Hu L L, Jiang Z H 2003 *Laser Optoelectron. Prog.* **40** 33 (in Chinese) [杨建虎, 戴世勋, 胡丽丽, 姜中宏 2003 激光与光电子学进展 **40** 33]
- [35] Vorontsov M, Shishakov K 1992 *J. Opt. Soc. Am. B* **9** 7177
- [36] Gan Y P 2020 M.S. Thesis (Harbin: Harbin Institute of Technology) (in Chinese) [淦亚苹 2020 硕士学位论文 (哈尔滨: 哈尔滨工业大学)]

- [37] Li P, Shi L, Mao Q H 2013 *Acta Phys. Sin.* **62** 15203 (in Chinese) [李磐, 时雷, 毛庆和 2013 物理学报 **62** 15203]
- [38] **Chen L, Li P, Liu H S, Yu J, Ke C J, Luo Z R 2023 *Chin. Phys. B* **32** 024213**
- [39] Guo M J, Fang S R, Wei Y J 2025 *China Journal of Econometrics* **5** 463 (in Chinese) [郭明君, 方思然, 魏云捷 2025 计量经济学报 **5** 463]

Research on NOLM Mode-Locked Fiber Lasers Based on SHAP

LIU Zhe¹⁾ FENG Zheng¹⁾ WANG Feiran¹⁾²⁾³⁾ ZHANG Haiyang¹⁾²⁾³⁾ ZHANG Yunjie¹⁾²⁾³⁾

YAN Xiang'an¹⁾²⁾³⁾ FENG Song¹⁾²⁾³⁾ FANG Qing⁴⁾ HAN Xiaoxiang¹⁾²⁾³⁾[†]

(1. School of Science, Xi'an Polytechnic University, Xi'an 710048, China;

2. Shaanxi Engineering Research Center of Flexible Radiation Protection, Xi'an Polytechnic University, Xi'an 710048, China;

3. Xi'an Key Laboratory of Nuclear Protection Textile Equipment Technology, Xi'an Polytechnic University, Xi'an 710048, China;

4. School of Science, Kunming University of Science and Technology, Kunming 650500, China)

Abstract

This paper presents an interpretable machine-learning framework integrating RK4IP simulation, surrogate modeling, SHAP analysis, and genetic algorithm (GA) optimization to address the challenge of optimizing nonlinear optical loop mirror (NOLM) based passively mode-locked fiber lasers in their high-dimensional coupled parameter space. The Ginzburg-Landau equation is solved via the fourth-order Runge-Kutta in the interaction picture (RK4IP) method to simulate pulse evolution in the laser cavity. A comprehensive dataset of 500 samples is generated by uniformly varying six key parameters: second-order dispersion (β_2 , 11.2-29.2 ps²/km), nonlinear refractive index (n_2 , 2.3-2.9 $\times 10^{-16}$ cm²/W), small-signal gain (g_{ss} , 36-39 dB), gain saturation power (P_{sat} , 22-25 dBm), gain fiber length (L_{AF} , 0.7-1.3 m), and gain bandwidth ($\Delta\lambda$, 50~110 nm). Four surrogate models—Random Forest (RF), XGBoost (XGB), backpropagation neural network (BPNN), and one-dimensional convolutional neural network (1D CNN)—are systematically compared. BPNN and 1D CNN demonstrate superior generalization, achieving test-set R^2 values of 0.951 for peak power, 0.981 for pulse energy, and 0.996 for pulse duration, with ratio of performance to deviation (RPD) reaching 4.56, 7.31, and 15.94, respectively. RF and XGB exhibit certain overfitting tendencies in specific tasks. SHAP analysis quantifies feature contributions and uncovers the physical mechanisms governing output characteristics. For peak power, n_2 and g_{ss} are the most influential parameters, with SHAP dependence plots revealing that n_2 exerts a negative effect while g_{ss} shows a strong positive correlation. For pulse energy and pulse duration, g_{ss} , P_{sat} , and L_{AF} collectively dominate model predictions, while β_2 , n_2 , and $\Delta\lambda$ play marginal roles. Based on these interpretability results, a two-stage GA optimization is implemented. Baseline optima are first established through full six-dimensional search for peak power, pulse energy, and pulse duration. Subsequently, parameters with consistently low SHAP importance across models are fixed at nominal values, and GA is re-executed in the reduced subspace. The optimized outputs from the reduced search closely match full-space results: RF and BPNN retain over 99% of baseline peak power performance; BPNN and 1D CNN preserve 86.5% of pulse energy; pulse

duration retention exceeds 94% for RF, BPNN, and 1D CNN. Meanwhile, computational time is reduced by 60%–70% and convergence accelerates by 30%–60%, demonstrating substantial efficiency gains without sacrificing solution quality. This work establishes an efficient, interpretable framework for NOLM laser optimization, combining simulation, surrogate modeling, SHAP interpretation, and GA search to enable accurate prediction, global optimization, and physical insight.

Key words: nonlinear optical loop mirror; passively mode-locked fiber laser; RK4IP algorithm; SHAP algorithm

* Project supported by the National Natural Science Foundation of China (Grant Nos. U2330109, 62405239, 61805212), the Science and Technology Program of Jiangsu Province, China (Grant No. FZ20240945), the Innovation Capability Support Program of Shaanxi Province, China (Grant No. 2025QCY-KXJ-041), and the Basic Research Program of Yunnan Province, China (Grant No. 202501AS070048).

† Corresponding author. E-mail: hanxiaoxiang@xpu.edu.cn