

中国科学技术大学

专业硕士学位论文



基于机器学习的激光稳定优化研究

作者姓名：刘哲生

专业领域：超快激光物理、机器学习

导师姓名：田野 研究员 崔金明 教授

完成时间：2024 年 3 月 16 日

University of Science and Technology of China
A dissertation for master's degree



Research on Laser Stability Optimization Based on Machine Learning

Author: Liu Zhesheng

Speciality: Ultrafast laser physics, Machine learning

Supervisors: Rsr. Tian Ye, Prof. Cui Jinming

Finished time: 2024/ 3/ 16

中国科学技术大学学位论文原创性声明

本人声明所呈交的学位论文,是本人在导师指导下进行研究工作所取得的成果。除已特别加以标注和致谢的地方外,论文中不包含任何他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的贡献均已在论文中作了明确的说明。

作者签名: _____

签字日期: _____

中国科学技术大学学位论文授权使用声明

作为申请学位的条件之一,学位论文著作权拥有者授权中国科学技术大学拥有学位论文的部分使用权,即:学校有权按有关规定向国家有关部门或机构送交论文的复印件和电子版,允许论文被查阅和借阅,可以将学位论文编入《中国学位论文全文数据库》等有关数据库进行检索,可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。本人提交的电子文档的内容和纸质论文的内容相一致。

控阅的学位论文在解除后也遵守此规定。

☐ 公开 ☐ 控阅 (____ 年)

作者签名: _____

导师签名: _____

签字日期: _____

签字日期: _____

摘 要

激光，是一种高聚焦度，强相干性、高亮度的光，由于它的这些独特优势，在工业生产和社会生活中扮演者不可替代的地位。随着激光技术的进一步革新，以激光为基础的系统在医疗、通信、工业生产等领域得到了广泛的应用。然而，随着激光精度的不断提高，对激光稳定性的要求也越来越高。例如在全飞秒激光手术过程中，必须精确控制激光切削的位置与深度，否则可能会对患者的视力造成永久性损伤。因此，解决激光在实际应用中由于受外界或内部因素影响而使得光束指向与功率不稳定的问题，有着极为重要的意义。

本文主要研究的是基于机器学习的激光稳定优化系统，这类系统主要研究的是如何使用机器学习这一计算机技术来解决外界或自身干扰造成激光不稳定的问题。本研究设计了一套由光学元件与计算机组成的激光稳定优化系统，当激光受到干扰时，通过机器学习整理总结先前采集的数据而对光束的指向进行预测，从而达到反馈调节的效果。从光学工程的角度上对光路进行了相关原理和设计方面的分析和说明，并给出了系统运行的整体流程图。进行了机器学习算法所需激光指向数据的数据集采集与处理；使用高斯过程回归与随机森林算法分别建立了线性与非线性两种激光稳定优化系统对应的机器学习模型，并在计算机中对这两种系统进行了仿真模拟。经模拟优化后线性激光稳定系统指向抖动振幅约为水平方向上 $2.3\ \mu\text{rad}$ ，竖直方向上 $3.3\ \mu\text{rad}$ 。非线性激光稳定优化系统优化后指向抖动振幅约为水平方向上 $7.6\ \mu\text{rad}$ ，竖直方向上 $6.4\ \mu\text{rad}$ 。相对比优化前线性激光系统指向抖动振幅约为水平方向上 $65\ \mu\text{rad}$ ，竖直方向上 $85\ \mu\text{rad}$ ，指向精度提升了约 30 倍；非线性激光系统指向抖动振幅约为水平方向上 $36\ \mu\text{rad}$ ，竖直方向上 $45\ \mu\text{rad}$ ，指向精度提升约 6 倍。同时相比现有飞秒激光系统中使用的自准直系统约几十个 μrad 的指向稳定精度有较大提升，指向精度提升了约 10 倍。该系统可广泛应用于使用飞秒激光器的光学系统中，预期能较好解决飞秒激光系统中光束指向不稳定的问题。

关键词：机器学习，飞秒激光系统，稳定性，高斯过程回归，随机森林

ABSTRACT

Laser is a type of light with high focus, strong coherence, and high brightness. Due to its unique advantages, it plays an irreplaceable role in industrial production and social life. With the further innovation of laser technology, laser based systems have been widely used in medical, communication, industrial production and other fields. However, with the continuous improvement of laser accuracy, the demand for laser stability is also increasing. For example, in the process of full femtosecond laser surgery, it is necessary to precisely control the position and depth of laser cutting, otherwise it may cause permanent damage to the patient's vision. Therefore, solving the problem of unstable beam direction and power caused by external or internal factors in practical applications of lasers is of great significance.

This article mainly studies laser stabilization optimization systems based on machine learning, which mainly focus on how to use machine learning as a computer technology to solve the problem of laser instability caused by external or self interference. This study designed a laser stabilization optimization system consisting of optical components and a computer. When the laser is disturbed, machine learning is used to organize and summarize previously collected data to predict the direction of the beam, thereby achieving feedback adjustment effect. From the perspective of optical engineering, the relevant principles and design aspects of the optical path were analyzed and explained, and an overall flowchart of the system operation was provided. Collected and processed a dataset of laser pointing data required for machine learning algorithms; We established machine learning models corresponding to linear and nonlinear laser stability optimization systems using Gaussian process regression and random forest algorithm, and simulated these two systems in a computer. After simulation optimization, the linear laser stabilization system pointed to a jitter amplitude of about 2.3 in the horizontal direction μrad , 3.3 in the vertical direction μrad . After optimizing the nonlinear laser stability optimization system, the pointing jitter amplitude is approximately 7.6 in the horizontal direction μrad , 6.4 in the vertical direction μrad . Compared to before optimization, the pointing jitter amplitude of the linear laser system is about 65 in the horizontal direction μrad , 85 vertically μrad , the pointing accuracy has been improved by about 30 times; The pointing jitter amplitude of the nonlinear laser system is approximately 36 in the horizontal direction μrad , 45 vertically μrad

improves pointing accuracy by about 6 times. Compared to the existing femtosecond laser systems that use dozens of self collimation systems the pointing stability accuracy of μrad has been greatly improved, with a pointing accuracy increase of about 10 times. This system can be widely applied in optical systems using femtosecond lasers and can effectively solve the problem of unstable beam pointing in femtosecond laser systems.

Key Words: machine learning, femtosecond laser system, stability, gaussian process regression, random forest

目 录

摘 要.....	I
ABSTRACT.....	II
第 1 章 绪 论.....	1
1.1 课题研究的背景、意义及创新点.....	1
1.1.1 课题背景.....	2
1.1.2 课题研究意义.....	7
1.2 激光束稳定优化国内外发展现状.....	7
1.2.1 激光束稳定优化国外发展现状.....	8
1.2.2 激光束稳定优化国内发展现状.....	8
1.3 本文的主要内容及章节安排.....	9
第 2 章 机器学习背景知识介绍.....	11
2.1 机器学习基本原理.....	11
2.2 贝叶斯优化概述.....	13
2.3 支持向量机概述.....	15
2.4 深度神经网络概述.....	18
2.5 决策树概述.....	22
2.6 本章小结.....	24
第 3 章 基于机器学习的线性激光稳定优化系统构建与仿真	25
3.1 激光稳定优化系统分析设计.....	25
3.1.1 线性光学系统光路分析.....	25
3.1.2 线性光学系统总体设计.....	26
3.1.3 系统主要部件及参数.....	27
3.2 数据采集与处理.....	29
3.2.1 数据采集.....	29
3.2.2 数据处理与特征提取.....	31

3.3 机器学习模型建立.....	31
3.3.1 定义参数空间与评估函数.....	31
3.3.2 高斯过程回归方法.....	32
3.4 系统仿真实验与结果.....	35
3.4.1 实验配置.....	35
3.4.2 实验结果与分析.....	35
3.4.3 模型对比及评估.....	38
3.5 本章小结.....	39
第 4 章 基于机器学习的非线性激光稳定优化系统构建与仿真 ...	41
4.1 激光稳定优化系统分析设计.....	41
4.1.1 非线性光学系统光路分析.....	41
4.1.2 非线性光学系统整体分析.....	42
4.1.3 系统主要部件及参数.....	43
4.2 数据采集与处理.....	44
4.2.1 数据采集.....	44
4.2.2 数据处理与特征提取.....	45
4.3 机器学习模型建立.....	45
4.3.1 定义参数空间与评估函数.....	45
4.3.2 随机森林算法.....	46
4.4 系统仿真实验与结果.....	48
4.4.1 实验配置.....	48
4.4.2 实验结果与分析.....	48
4.4.3 模型对比与评估.....	50
4.5 本章小结.....	51
第 5 章 总结与展望.....	52
5.1 全文总结.....	52
5.1.1 工作总结.....	52
5.1.2 主要贡献及创新点.....	53
5.2 研究展望.....	53
参 考 文 献.....	55

致 谢.....	60
个 人 简 历.....	61
在读期间发表的学术论文与取得的其他研究成果	62

第 1 章 绪 论

激光，是一种特殊类型的光，其名字是由爱因斯坦在 1916 年提出的，本质是原子中的电子受激辐射出光子的过程，激光拥有亮度高、相干性和准直性好的特点，这些特性使得激光在军事、医疗、通信^[1]、精密加工、光和物质相互作用等许多领域得到了广泛应用。

在与激光相关的研究方向中，激光系统的优化设计是一个比较重要的方向，其需要综合考虑光学、电子、机械等多个领域的知识，为了提高激光系统的性能和应用范围，激光系统的优化设计需要解决以下几个难点：1) 激光束质量的优化：保持激光束的高质量是激光系统设计的一个重要目标。这涉及到调节激光束的横截面形状、光斑尺寸、光强分布等参数，以确保激光束的聚焦能力和功率分布均匀性。激光束质量的优化需要综合考虑光学元件的性能和激光器输出的特性^[1]。2) 光学元件的选择和优化：光学元件在激光系统中扮演关键角色，包括透镜、反射镜、光栅等。选择合适的光学元件并优化其设计，以最大程度地减小光学畸变、散射、吸收等效应，是一个复杂而关键的难题。3) 激光系统的稳定性：激光系统在工作过程中可能受到振动、温度变化等外部因素的影响，这可能导致激光的漂移和形状变化^[3-5]。设计一个稳定的激光系统需要考虑如何抵消这些外部干扰，以确保激光系统的性能在不同环境条件下都能保持稳定。4) 功率和能量的稳定性：一些应用要求激光系统输出的功率和能量具有高度的稳定性。实现这一点需要在激光器的输出、光学元件的选择和调整等方面进行细致的优化，以降低功率波动和能量不稳定性。5) 激光系统的集成：在实际应用中，激光系统通常需要与其他部件集成，如控制系统、传感器等，设计一个高效的、稳定的激光系统需要考虑各个部分之间的协调和集成，以确保整个系统的协同工作。6) 成本和复杂性的平衡：激光系统的优化设计需要在提高性能的同时控制成本。平衡复杂性和成本之间的关系是一个挑战，应确保在系统满足性能需求的同时，不能使系统变得过于昂贵或复杂。

1.1 课题研究的背景、意义及创新点

随着科学技术的不断进步，激光系统在医疗、通信、工业技术、科学研究等领域都得到了较为广泛的应用。当然，人们对激光系统的要求也越来越高，例如更高的功率、更优质的激光束质量以及更精准的激光控制等。要满足这些要求，一方面可以从光源本身考虑，选择具有更高输出功率和稳定性的激光器。另一方面，从整个系统结构的角度考虑，可以提高激光系统的光学元件设计、激光束传

输系统的效率，以及整体系统的稳定性和控制精度。为了克服目前激光系统的精度和响应度方面的问题，科技工作者们正致力于从激光器元器件性能、光学元件设计和整体系统结构等方面进行深入研究，以设计出更优质、更高精度的激光系统。这包括提高激光器的输出性能、优化光学元件的选择和布局，以及改进系统的控制算法，以实现更高水平的激光系统性能。这些努力将有助于推动激光技术在各个领域的应用更上一层楼。

1.1.1 课题背景

线性光学是研究光在透明介质中传播和相互作用时遵循线性光学响应的一个光学分支领域。在线性光学中，光的传播和相互作用过程可以用线性的数学关系来描述。线性光学的关键概念是线性响应。线性响应意味着当一个系统受到输入光的激励时，其输出光的性质与输入光的性质成比例，并且不会引入新的频率分量。

在线性光学中，常见的线性光学效应包括折射、反射、干涉、衍射等。通过了解这些效应，可以理解和解释光的传播、成像、形成干涉条纹等现象。线性光学通常适用于光的振幅较小、光强较低的情况。对于高光强或非线性效应显著的情况，需要使用非线性光学理论进行描述。

线性光学广泛应用于各个领域，包括医疗、通信、工业生产等。通过研究和理解线性光学，我们能够揭示光的基本行为和性质，为光学技术的发展和應用提供基础。全飞秒激光手术^[6-7] (Femtosecond Laser Small Incision Lenticule Extraction, 简称“SMILE”) 是一种现代眼科手术技术，主要用于矫正近视(近视眼)，相比传统的半飞秒激光技术 (Laser-Assisted In Situ Keratomileusis, 简称“LAISK”) SMILE 不需要创建传统的角膜瓣，而是通过一个微小的切口来改变角膜形状，其首先使用飞秒激光系统在角膜内部创建一个薄片，称为 lenticule (椭圆形的薄片)。这个椭圆形薄片包含了需要被去除的一部分角膜组织，以改变角膜形状，然后创建一个大约 2mm - 4mm 的微小切口，把椭圆形的薄片取出。“SMILE”技术通常适用于近视患者，尤其是轻度至中度的近视。手术还可以用于治疗一些角膜问题，如角膜斑、角膜脆弱等。全飞秒激光手术示意图如图 1.1 所示，相较于传统的半飞秒激光手术，全飞秒激光手术具有以下优势：切口更小：由于不需要创建大的角膜瓣，手术中产生的切口更小，有助于后续的角膜愈合和康复；创伤更少：角膜上的神经末梢受到激光的影响较小，从而减少了手术后的干眼症风险；康复更快：相较于传统的半飞秒激光手术，全飞秒激光手术治疗后的患者通常能够更快地恢复正常生活和工作。

然而，在全飞秒激光手术治疗过程中，由于所需的激光束直径极为细小，对

于激光的稳定性要求非常高：在角膜的切削过程中，必须精确控制激光束切削的深度，否则可能会对患者的视力造成永久性损伤，因此，如何控制激光束的稳定性是全飞秒激光手术过程中的一个至关重要的问题。




图 1.1 全飞秒激光手术示意图^[7]

Fig 1.1 Schematic diagram of SMILE^[7]

光动力疗法^[8-9] (Photodynamic Therapy, 简称“PDT”)是激光技术在医疗领域应用的一种新兴技术，它于 1976 年由 Kelly JF 和 Snell ME 发明，其使用光敏感剂和特定波长的激光来治疗肿瘤，具有非侵入性、选择性作用、相对少的副作用、可以用于多种疾病的治疗，在医疗上有很高的应用价值。首先，患者接受光敏感剂，这是一种特殊的药物，一般通过静脉注射或皮肤局部给药，然后通过光纤或适当的其他介质，把与光敏感剂相对应波长的激光引导至患者体内的目标区域，光敏感剂受到激发后变成激发态，产生一种叫做单态氧的有毒物质，这种单态氧可以与附近的生物大分子发生氧化反应，破坏目标组织细胞，使目标细胞受损或死亡。光动力疗法治疗原理过程如图 1.2 所示。




图 1.2 光动力治疗的机理

Fig 1.2 The mechanism of photodynamic therapy

光动力疗法在肿瘤治疗中可以广泛应用、譬如皮肤癌、甲状腺癌、肺癌等，还可用于治疗如黄斑变性、静脉曲张、牛皮癣等非肿瘤类疾病。光动力疗法的诸多优点和较多的应用场景使其受到了社会各界的广泛关注，在光动力疗法中激光束的稳定性尤为重要，在照射过程中良好的光束稳定性确保激光能够集中在治疗的目标区域，最小化对周围正常组织的影响，确保治疗的精准性和有效性；良好的光束稳定性还可以最大限度地减少激光能量在传输过程中的散失，这有助于确保足够的光能量能够到达光敏感剂富集的目标组织，以激活光敏感剂并引发治疗效应。同时良好的光束稳定性还可以避免对周围健康组织的损害：准确的激光定位可以最大限度地减少对周围健康组织的损害。这对于降低治疗的副作用和提高治疗的安全性至关重要。然而，如果照射光不稳定，即使激光源的波长符合光敏感剂的要求，也会影响光动力疗法的治疗效果，甚至有可能对患者造成损害，因此，光动力疗法的核心工作之一就是确保照射激光束的稳定性。

微纳加工^[10-11]是一种制造和加工技术，旨在制造尺寸在微米（微加工）和纳米（纳米加工）尺度的结构和器件。这种技术涉及到对材料进行高度精密的控制和加工，以创建微小尺度的结构，通常用于微电子学、生物医学、光学和其他领域。微加工和纳米加工的示例图片分别如图 1.3 和图 1.4 所示，和传统的毫米级加工相比，微纳加工具有以下优点：

1) 高精度、高分辨率尺寸控制：微纳加工相比传统加工可以实现高精度的精确尺寸控制，可以用来制作微米和纳米尺度的各种工业结构和器件，比如在集成电路加工中使用微纳加工方法制造出尺寸更小、更精密的元件，相比传统加工工艺，使用微纳加工可以制造出微米和纳米级分辨率的结构，可应用于光学元件或传感器等其他对高分辨率需求较高的器件生产工艺中。

2) 高通量自动化控制：微纳加工技术可以实现高度自动化的制造过程以提

高生产效率，这意味着大量的微纳结构可以在较短的时间内制造出来，这对于大规模生产微米级别的器件和结构至关重要。

3) 多功能性和创新性：微纳加工技术允许在同一平台上集成多种功能，通过在微米和纳米级别上精确控制材料的排列和结构，可以实现多功能性的器件，可应用于生物医学、光学和电子学领域，同时微纳加工技术也提供了研究新型结构和器件的平台，可以推动科技进步与创新，为新兴领域发展提供支持。




图 1.3 微加工（左）纳米加工（右）^[12]

Fig 1.3 Micro-processing(left) and Nano-processing(right) ^[12]

然而，在微纳加工过程中，存在着对微小结构的高精度控制和定位的需求，需要保证激光光束的精确对准，类似于激光通信过程中需要确保激光光束的指向稳定性，同时修正或抵消平台振动或外界干扰带来的影响，才可确保加工的精度和质量。因此，微纳加工中的一个关键就是如何确保激光光束的稳定性。

上述几种应用的基础都为激光系统，然而这几种系统中我们主要利用到的是激光的强相干性和高能量密度性，因此上述系统属于线性光学领域；随着激光器功率的不断提高，人们对光与物质相互作用的研究也越来越深入透彻，科学家发现当光的强度足够高且光与特定的非线性材料相互作用时，介质对光的响应不再与光的强度成正比，而会现光频率加倍、光学相位共轭等非线性现象。这意味着人们无法使用线性的偏微分方程来描述光与介质的相互作用，必须使用更复杂的非线性方程进行描述，非线性光学这一研究领域便应运而生。

非线性光学（Nonlinear Optics）是现代光学的一个重要组成部分，它主要研究介质在强相干光下面的非线性效应。非线性光学主要研究强光在介质中的各种现象^[13]：如谐波生产、光学参量放大、振荡效应、受激散射、自聚焦、自相位调制等。

光参量放大器（Optical Parametric Amplifier，简称“OPA”）是一种基于光参量过程的非线性光学器件，可以在光信号中实现非线性放大^[14]。光参量过程是指

在非线性光学材料中,通过非线性作用将一个光束转换为两个不同频率的光束的过程。通常情况下,光参量过程包括光学参量振荡和光学参量放大。在光参量放大器中,一个强泵浦光源被用于注入一个非线性光学晶体。在晶体中,通过非线性相互作用,泵浦光会产生两个较弱的光信号(信号光和辅助光),这两个光信号的频率以及它们与泵浦光之间的相对频率差是由晶体的非线性性质所决定的。其中,信号光是我们希望放大的光信号,而辅助光则起到调制和辅助放大的作用。通过调整非线性晶体的特性和输入光的参数,可以实现对信号光的放大效果,同时在宽带范围内保持相位匹配。光参量放大器具有几个重要的特点和应用:首先,它可以实现宽带放大,可以在光谱范围内进行连续和调谐的放大。其次,光参量放大器具有快速的响应时间,因此可以用于高速光通信和激光脉冲放大等应用。此外,OPA 还可以实现光学非线性过程的相位控制和调制,用于产生新的频率混频和生成超快光脉冲等应用。光参量放大器实物图如图 1.4 示。



图 1.4 光参量放大器

Fig 1.4 Nanoprocessing

然而,在 OPA 的实际应用中,由于激光在光参量放大过程中会产生二次非线性效应、交叉相位调制效应等非线性效应,其光束的指向不可避免地会发生抖动,功率的稳定性也会降低。因此,设计一种用来稳定 OPA 出射光束的优化系统便显得尤为重要。

从以上分析可以看出、激光在新型医疗或工艺技术中有着较为广泛的应用、无论是全飞秒激光手术、光动力疗法或微纳加工等线性过程还是 OPA 等非线性过程中激光都起到至关重要的作用,虽然这几种技术有着诸多优势,但它们都对激光光束的质量及稳定性有着极高的要求。激光光束的质量主要分为指向稳定性^[1]和功率的稳定性,二者存在相关性关系,一般来说激光指向稳定性越好,功率稳定性也越优;本文主要研究的就是激光光束的指向稳定性。

一般来说,影响激光光束稳定性的因素主要来源于两个方面,一是系统误差,二是随机误差,其中系统误差对于激光光束的稳定性影响较大,在自由运行状态

下,激光的指向可能会受到平台振动等因素发生漂移^[16-17],因此设计出一个激光束稳定性良好的光学系统是一个亟待解决的任务。

1.1.2 课题研究意义

光学系统中,导致激光光束不稳定的因素主要分为两类:1)系统平台或光学元件存在的振动、热漂移或者其他机械效应而导致的系统误差;2)空气湍流、温度变化等环境干扰或其他人为因素所导致的随机误差。这两类因素都会对激光光束的稳定性造成极大的干扰,当激光的稳定性降低时,光学系统整体性能可能会有所下降,更有甚者使整个系统发生瘫痪,产生严重的后果。

在光学系统的实际应用过程中,光束的稳定性会由于各种因素引发的振动的存在而影响到整个系统的精度。譬如在全飞秒激光手术过程中、手术使用的激光光源一般为钕玻璃激光器发出的波长 1053nm 的近红外光,在临床治疗时实验平台由于各种原因不可避免地会产生振动,使激光束偏离目标,对患者健康造成损害;在微纳加工过程中,操作平台和激光器本身的固有振荡、加工室内温度、气流等因素都会使激光束产生一定的抖动,影响光束的指向稳定性,使得加工出现偏差,影响所制备的微小结构的质量。

上述分析的几种系统都对激光光束的稳定性要求比较高,主要体现在光束的准直精度上,一般只允许角秒级以下的误差。如何解决振动或其他因素对激光光束的稳定性影响,使出射光稳定,是一个亟待解决的问题,同时对光学系统在各个领域的未来应用和发展也有较大意义。

要抵消或减少系统误差或随机误差带来的振动对激光光束的稳定性造成的影响,需要光学、控制工程、数学、机械等多个领域的理论相互结合才可以解决。一般来说,要解决这个问题,光学工程领域中存在被动减振和主动控制两类方法:被动减振是指使用更加稳定的光学平台来减少阻尼,或在装置连接处使用减振弹簧等方法来被动减少振动^[18];而主动控制方法一般包括光学元件、传感器、反馈控制器等组成部分。光学元件可以修正激光光束的形状和方向,传感器可以实时监测光束的参数,而反馈控制器则根据传感器的反馈信号对光束指向进行精确调整。这种方法把光学工程和控制工程相结合,可以实时检测到激光光束的振动后在相反方向上进行补偿调整^[19],使得激光束在空间内趋向稳定。

1.2 激光束稳定优化国内外发展现状

激光束稳定优化技术是一种结合光学工程、机械工程、自动化控制、嵌入式设计等多个领域学科的技术,这种技术一般使用光学传感器测量到激光光束的质

心在空间上的位置的偏移,传感器把偏移量信号传导给控制系统,反馈控制系统驱动快速反射镜转动,实时补偿偏差,实现对光束的稳定控制。

鉴于以激光为基础的光学系统的日益广泛应用和人们对激光的稳定性不断提高的要求,各大公司和科研机构都致力于开发更加先进的激光束稳定系统。他们深入研究导致激光稳定性降低的因素、解决方案和未来可能存在的问题。一些机构已经取得了显著的进展,这些进展有助于推动光学系统的发展。

1.2.1 激光束稳定优化国外发展现状

国外在上个世纪末便开始了关于激光束指向稳定控制系统的研究:1999 年日本的 NEC 公司设计的电磁驱动光束校正装置^[20](widerange fine pointing mechanism,简称“WFPM”),其控制精度可达 $30\ \mu\text{rad}$,偏转范围为 $140\ \text{mrad}$,相应带宽达 $380\ \text{Hz}$ 。2010 年,WUY 等人首次提出了全被动光束稳定指向技术^[21],他们提出了一种基于图像旋转与和频生成的无源光束指向稳定方法,该方法不仅特别适用于单次低重频激光系统,而且还适用于产生连续波的激光系统。其主要技术方法是基于波束复制、反向指向变化和和频率生成。该方法在原理验证实验中将指向稳定性提高了 2 个数量级,达到 $10\ \text{mrad}$ 水平。德国 MRC 公司的商用激光束指向稳定控制模块^[22]通常用于抵消或纠正由振动、冲击震动、热量漂移,或其他对激光方位有不良影响的因素引起的变化,该系统技术成熟,应用广泛,可用于大部分对激光指向稳定性要求较高的系统中,其最大矫正量达到 $2\ \text{mrad}$ 水平,稳定精度与光斑大小相关。2015 年,Barna 等人针对 KrF 高功率激光系统的光束偏移研发的主动光束指向稳定系统^[23]使用位置敏感探测器监测光束输出的焦点位置,并使用离轴抛面镜对光束紧密聚焦,稳定后指向稳定性约为 $14\ \mu\text{rad}$ 。2022 年,Meng Q X 等人设计的 3D 打印激光自准直仪^[24]能够在两个正交方向上测量角度,并能够在长时间的实验中以精确的计时连续监测并准直角,设计紧凑、轻便且易于构建,其指向稳定性优于 $14.5\ \mu\text{rad}$ 。

1.2.2 激光束稳定优化国内发展现状

国内很多科研机构 and 高校也纷纷开展了对激光束稳定优化的研究,并取得了一定的研究成果:

2016 年,西安理工大学的宋跃辉等人设计了一种用于同轴米散射激光雷达的自准直系统^[25],该系统通过将几何重叠因子作为判定依据,通过传感器采集到信号后输入计算机进行反馈调节,指向稳定性达到 $0.05\ \text{mrad}$ 水平,大幅优于基于回波信号成像位置的激光自准直系统。2019 年,中国科学院西安光机所的谢

美琳等人针对机载瞄准吊舱系统设计的高精度激光束指向系统^[26]分析了大气湍流这一影响室外激光系统中光束指向波动的因素,设计了一种抗外界环境干扰的光束指向波动算法,经 Simulink 软件仿真后,指向精度达到 0.003 mrad 水平,具有较好的可移植性。2021 年,上海交通大学的杨红伟等人设计的基于差分成像的激光光束指向控制装置^[27]通过使用两个对称的聚焦镜组和两个 CCD 抑制光束的抖动误差,该装置抑制了光束的指向抖动干扰,稳定调节后指向精度优于 $\pm 10 \mu\text{rad}$ 。2022 年,赵晖宁等人使用自动准直的光学方法^[28],同时测量径向、轴向和倾斜误差运动,并通过光线追踪建立数学模型,使用 Optic Studio 模拟相应的光路,设计了一种基于材料弹性变形的 X-Y 微位移调节机构,用于调节高精度钢球的安装偏心误差。该结构具有光路简单、响应速度快、成本低、精度高等优点,其装置指向稳定性达到 25.1 μrad 水平。

上述的指向稳定性控制系统大多采用位置测量-反馈控制的方案,即首先通过传感器采集到光束的指向抖动偏移量,而后将偏移量信号输入控制系统,控制系统通过反馈调节实时对偏移量作出补偿,使激光束指向趋于稳定。在飞秒激光系统中,经自准直仪校正稳定后,目前在空间内的激光指向性振幅波动约为几十个 μrad ^[29-31];已经不能满足日益提高的实验精度要求,较大地影响了飞秒激光系统的应用。因此,设计出一种新型的激光束指向稳定技术已经迫在眉睫。本文所研究的基于机器学习的激光稳定优化便是针对这一问题而提出的新型方案。

1.3 本文的主要内容及章节安排

本文主要研究对象为基于机器学习的激光稳定性优化系统,主要探讨激光束的指向稳定性和功率稳定性由于内部或外界因素发生偏移的情况下,使用计算机通过机器学习算法通过总结引发激光不稳定的因素并预测光束的指向位置,使得激光光束趋于稳定。

第一章绪论起到引言的作用,主要介绍的是课题研究的背景、意义及创新点,通过举出课题相关的应用实例引出课题背景和意义,并介绍了目前激光束稳定优化系统的国内外发展现状和本文总体的章节安排。

第二章为机器学习的背景知识介绍,介绍了机器学习基本原理及其在物理模型中的优势;又分别介绍了贝叶斯优化模型、支持向量机模型、深度神经网络、决策树算法这几种在机器学习中常用的优化算法的原理和应用场景。

第三章是本课题的关键章节:首先对线性激光稳定优化系统进行了详尽的分析,从光学工程的角度对线性系统的光路进行了相关原理和设计方面的分析和说明;接下来介绍了线性激光稳定优化系统中的主要部件与它们的基本参数。并使

用机器学习方法对线性激光系统进行了系统建模与仿真,首先介绍了数据的采集与特征抽取,并根据数据标签特征建立数据集,并介绍了机器学习模型的建立方法,包括评估函数定义与高斯过程回归这一具体模型的选择;最后进行模型的系统仿真和模拟,经过该方法优化后,指向抖动达到水平方向 $2.3\ \mu\text{rad}$, 竖直方向 $3.3\ \mu\text{rad}$, 相比偏最小二乘算法优化后的稳定性,提高了 1 个数量级以上。经对比后高斯过程回归优化后的指向性抖动为线性回归系统的 20 %, 并对时域和频域结果中的误差进行了分析,相比偏最小二乘算法优化后的高频噪声幅度降低了 1 个数量级,低频噪声幅度降低到了约 45 %^[32]。

第四章介绍了基于机器学习的非线性激光稳定优化系统,本章节是对上一章节的拓展延伸,在线性激光系统的光路中增加了一组空芯光纤,激光在经过空芯光纤时由于受到自相位调制这一非线性过程的干扰而发生了指向抖动和功率波动。从光学工程的角度对线性系统和光路进行了相关原理和设计方面的分析和说明;接下来介绍了非线性激光稳定优化系统中的主要部件与它们的基本参数。并使用机器学习方法对线性激光系统进行了系统建模与仿真,首先介绍了数据的采集与特征抽取,并根据数据标签特征建立数据集;介绍了机器学习模型的建立方法,包括评估函数定义与随机森林算法这一具体模型的选择;最后进行模型的系统仿真和模拟,经过该方法优化后,指向抖动达到水平方向 $7.6\ \mu\text{rad}$, 竖直方向 $6.4\ \mu\text{rad}$, 并与贝叶斯优化后的结果进行对比,印证了随机森林算法的优越性。

第五章是对本文中工作的总结和展望,简要总结了本课题的主要工作,指出了课题的不足,介绍了未来努力的方向。

第 2 章 机器学习背景知识介绍

机器学习（Machine Learning，简称“ML”）是一种人工智能（Artificial Intelligence AI）的分支领域，致力于使计算机系统通过学习数据和经验，而不是通过明确编程，来改善其性能。简而言之，机器学习使计算机能够利用数据来“学习”并做出决策或预测，而无需显式地进行编程^[33-34]，机器学习的常见算法分类如图 2.1 所示：




图 2.1 机器学习常见算法分类

Fig 2.1 Classification of Common Machine Learning Algorithms

2.1 机器学习基本原理

机器学习的基本原理可以概括为从数据中学习模式和规律，以便对新数据进行预测或决策。机器学习按方式划分可以分为有监督学习、无监督学习与强化学习三种。

有监督学习是指机器通过已知输入和输出的训练数据来学习模型，从而能够预测新的输入数据对应的输出^[35]。有监督学习是最常见的机器学习方法，也被称为有导师学习。在有监督学习中，模型通过学习输入和输出之间的关系来进行预测和分类：首先收集包含输入和输出对应关系的训练数据，其中每个训练样本都包含输入特征和对应的目标输出。有监督学习适用于许多任务，包括分类、回归、

序列标注等。它是机器学习领域中最常用的方法之一，被广泛应用于各种领域，如自然语言处理、计算机视觉、医疗诊断、天气预测等^[36-39]。常见的有监督学习方法有朴素贝叶斯、支持向量机、决策树、随机森林等。

在实际生活中，大部分情况下许多问题缺乏先验知识，无法进行对数据集人工标注类别或成本较高。无监督学习这种机器学习方法便应运而生。与有监督学习相对应，无监督学习中，模型在训练过程中不存在对每个输入样本提供对应的标签或输出，从而试图从数据中发现隐藏的结构、模式或规律^[40]。无监督学习使用方法主要为聚类分析，即首先将数据集中的样本分成若干个组（簇），使得同一组内的样本彼此相似，而不同组之间的样本差异较大。常见的无监督算法有主成分分析^[41]、高斯混合模型^[42]、生成对抗网络^[43]等。

强化学习又名增强学习，其主要方法是让智能体（agent）通过与环境的交互学习来获得最大化累积的奖励信号^[44]。与传统机器学习方法不同，强化学习不使用数据集进行训练，而是强调智能体与环境的交互，通过不断的交互与学习，最终找到问题的最优解；强化学习算法可以在不完全理解所有环境模型的情况下建立解决问题的最佳模型，在处理复杂的物理模型时具有独特的优势。常见的强化学习算法有策略梯度算法^[45]、蒙特卡洛算法^[46]、动态规划^[47]等。

以下是机器学习模型的几个基本原理和关键概念：

（1）数据： 机器学习的核心是数据。算法需要访问和学习的数据包括输入特征和对应的目标（标签）。这些数据可以是结构化的，比如表格数据，也可以是非结构化的，比如图像、文本或声音。

（2）特征： 数据中的特征是描述输入的属性或变量。特征可以是数值型、类别型或其他类型的数据。在机器学习中，特征的选择和提取对于模型的性能至关重要。

（3）标签： 标签是在监督学习中与输入特征相关联的输出值，也称为目标。机器学习的目标通常是通过学习从输入到输出的映射关系，使模型能够对新的输入进行预测。

（4）模型： 模型是机器学习算法的数学表示，用于学习数据的模式。模型的选择取决于任务的性质，可以是线性模型、决策树、支持向量机、神经网络等。

（5）训练： 训练是指机器学习使用历史采集到的数据来动态调整模型的参数，机器学习通过算法模拟数据中的规律，响应数据的模式。通过逐步降低预测数据与训练集数据之间的误差，模型能够学到数据中的规律。

（6）损失函数： 损失函数衡量的是模型在训练数据上的预测误差。机器学习中训练的的目的是使损失函数值最小，来提高模型的泛化能力，泛化能力越高，对新数据的预测准确率一般也就越高。

(7) 测试和评估：训练完成后，模型需要新的独立测试集上运行评估，使用训练好的模型对测试集中的样本进行预测，比较其与训练集上的表现是否一致。常用的评估指标包括准确率、精确度、召回率、F1 分数等。

(8) 优化和调优：模型测试后，必须进行进一步的优化和调优，这是一个迭代的过程，优中选优，有利于提高模型性能，常用的调优方法有调整参数、更换模型、交叉验证等。

(9) 预测和决策：完成模型训练和评估后，可以将模型应用于新的、未见过的数据，进行预测或做出决策。

总体而言，机器学习的基本原理是通过数据驱动的方式，让计算机系统能够从经验中学习并改进其性能，从而实现对未知数据的预测和决策。这种学习过程强调模型对数据中潜在模式的发现和理解。

2.2 贝叶斯优化概述

贝叶斯优化是一种样本有效且无梯度的方法，用于具有噪声输出的黑箱函数的全局优化^[48]。贝叶斯优化是一种先验方法，它通过结合先前的计算数据和步骤来提高新测量值的价值，贝叶斯优化的基本原理是贝叶斯定理。

贝叶斯定理主要原理是根据得到的数据计算先验概率，然后通过朴素贝叶斯算法^[49]计算出每个事件的后验概率，并将最大后验概率对应的事件的类别视为分类的结果。贝叶斯公式如下所示：

$$P(B|A) = \frac{P(A, B)}{P(A)} = \frac{P(A|B)P(B)}{P(A)}$$

其中 $P(B|A)$ 为在事件 A 发生的条件下事件 B 发生的概率（条件概率）， $P(A|B)$ 为在事件 B 发生的条件下事件 A 发生的概率（条件概率）， $P(A, B)$ 是事件 A 和事件 B 都发生的概率（联合概率）， $P(B)$ 和 $P(A)$ 分别是事件 B 和事件 A 发生的概率（边缘概率）。从贝叶斯公式可以计算通过事件 A 的概率，事件 B 的概率和在 B 的情况下事件 A 的概率，通过计算求得在 A 的情况下事件 B 发生的概率。

朴素贝叶斯公式如下列所示：

$$\begin{aligned} P(Y = c_k), k = 1, 2, \dots, K \\ P(X = x) = P(X^{(1)} = x^{(1)}, \dots, X^{(n)} = x^{(n)}) \\ P(X = x|Y = c_k) = P(X^{(1)} = x^{(1)}, \dots, X^{(n)} = x^{(n)}|Y = c_k), k = 1, 2, \dots, K \end{aligned}$$

在模型的实际训练过程中，朴素贝叶斯公式一般求解的是在一个特定的特征组合下该样本被分为各个类别 c_k 的概率，其中 K 为类别的总数；然而在实际应

用中一个特征可能有着非常多的取值，如果 $P(X = x)$ 采用联合概率分布，那么就需要对每种特征的每种取值的每一个组合计算先验概率，这种情况下条件概率分布会产生指数级数量的参数。在条件独立的情况下，原先的条件概率可转换为多个独立事件的条件概率的连乘：

$$\begin{aligned} P(X = x|Y = c_k) &= P(X^{(1)} = x^{(1)}, \dots, X^{(n)} = x^{(n)}|Y = c_k) \\ &= \prod_{j=1}^n P(X^{(j)} = x^{(j)}|Y = c_k) \end{aligned}$$

此假设下，使用贝叶斯定理计算后验概率：

$$\begin{aligned} P(Y = c_k|X = x) &= \frac{P(X = x, Y = c_k)}{P(X = x)} = \frac{P(X = x|Y = c_k) P(Y = c_k)}{\prod_j P(X^{(j)} = x^{(j)})} \\ &= \frac{P(Y = c_k) \prod_j P(X^{(j)} = x^{(j)}|Y = c_k)}{\prod_j P(X^{(j)} = x^{(j)})} \end{aligned}$$

进一步可简化为：

$$y = \arg \max_{c_k} P(Y = c_k) \prod_j P(X^{(j)} = x^{(j)}|Y = c_k)$$

贝叶斯优化算法主要由两部分组成：概率代理模型和采集函数。贝叶斯优化的第一步是建立一个对目标函数的代理模型，通常采用高斯过程回归方法。高斯过程回归是一种能够对未知函数进行概率建模的工具，该方法可以得到目标函数在每个点上的后验概率分布，包括均值和方差信息等^[50-51]。概率代理模型提供了一种目标函数不确定性的量化方式，它将提供一个后验概率分布，在该分布上可以定义不同的采集函数。采集函数是贝叶斯优化中的关键组成部分，它在概率代理模型的基础上定义了在哪里采样新的点以进行评估。运用“开发与探索”的概念，“开发”指通过最大化当前模型的预测值，即在已知高概率区域中寻找下一个采样点；而“探索”意为通过最大化当前模型的不确定性，即在不确定性较高的区域中寻找下一个采样点。贝叶斯优化通过设计采集函数来有效平衡开发和探索，旨在搜索全局最优解。在开发阶段，算法倾向于选择那些在当前最有希望的区域内最大化目标函数的点，而在探索阶段，算法倾向于选择那些在不确定性较高的区域内的点。常见的采集函数包括威尔逊置信函数（Upper condence bound，简称“UCB”）：

$$UCB(x) = u(x) + \beta_t^{\frac{1}{2}} \sigma(x)$$

第一项 $u(x)$ 为均值，注重于开发，第二项 $\beta_t^{\frac{1}{2}} \sigma(x)$ 注重探索， β 越大，说明越注重探索。在获得每个位置的 UCB 后，选择对应于最大 UCB 的 x 作为下一个要测试的参数组合，其中， β_t 表示 β 随着测试次数的增加，数值发生变化，通常会变大。因此，方差对 UCB 的贡献也增加了，表明对探索的重视程度越来越高，

有一定的可能性，在局部最优区域的开发完成后，可以找到全局最优。

概率提升函数（Probability of Improvement，简称“PI”）：

$$PI(x) = P(f(x) \geq f(x^+) + \xi) = \Phi\left(\frac{u(x) - f(x^+) - \xi}{\sigma(x)}\right)$$

其中 $\Phi(\cdot)$ 代表的是累积分布函数， $f(x^+)$ 为当前参数组合中测得的最优值， x^+ 代表这个最优参数，而 ξ 为一个参数，代表最优值的阈值。概率提升函数衡量了在当前最优结果（通常是在观察过的样本中的最佳结果）的基础上，目标函数是否有可能提升。它通过计算在当前最优结果下，目标函数超过某个阈值（通常是当前最优结果加上一定量的提升值）的概率来实现。

期望提升函数（Expected Improvement，简称“EI”）：

$$EI(x) = \begin{cases} (u(x) - f(x^+) - \xi)\Phi(Z) + \sigma(x)\phi(Z) & \sigma(x) > 0 \\ 0 & \sigma(x) = 0 \end{cases}$$

$$Z = \begin{cases} \frac{u(x) - f(x^+) - \xi}{\sigma(x)} & \sigma(x) > 0 \\ 0 & \sigma(x) = 0 \end{cases}$$

其中 $\Phi(\cdot)$ 代表的是累积分布函数， $\phi(\cdot)$ 代表的是概率密度函数，上述公式中的第一项影响开发，第二项影响探索，而参数 ξ 越大代表函数值越趋近于探索，越小代表函数值越趋近于开发。与概率提升函数相比，期望提升函数考虑了对大于最优点的点的期望。从期望提升函数公式的第一项可以看出，它实际上是点的值乘以该点大于最优点的概率，即乘以概率提升函数。

采集函数的数值优化，结合了模型的期望和不确定性，指导每个新的采样点的选择。这使贝叶斯优化具有平衡探索和开发的能力，这使其成为优化有噪声或不确定目标的理想选择。历史数据、模拟或理论等先验知识可以提高优化效率，并将搜索限制在低信噪比状态下。贝叶斯优化已经应用于数量迅速增长的领域；例如，资源勘探、强化学习的主动策略搜索、神经网络参数调整、实验控制等。大型科学实验运行成本高昂，输入和输出嘈杂且不确定，并且有详细的物理理论、模拟和广泛的数据集支持；所有这些品质使得复杂的物理实验非常适合通过贝叶斯优化进行控制。

2.3 支持向量机概述

支持向量机（Support Vector Machine，简称“SVM”）是一种常用的监督学习机器学习算法，在 1995 年由俄罗斯统计学家 Vapnik 提出^[52]，其主要用于分类

和回归分析，在样本小、高维及非线性领域表现出色，同时尽量减小了过拟合和欠拟合的概率；它的目标是找到一个超平面，能够将不同类别的数据点尽可能地分开，并且保持分类边界的间隔最大化。其最初用于解决聚类分析问题，但后来也用于预测分析，在文本分类、图像识别、生物信息学、金融领域等多个领域有着较为广泛的应用^[53-55]。

支持向量机的核心思想之一是通过核函数将原始数据映射到高维空间。这个高维空间的维度通常比原始特征空间高得多，甚至是无穷维。这种映射可以使得在高维空间中的数据更容易被线性分隔。在高维空间中，支持向量机通过找到一个超平面来实现数据的划分。这个超平面的选择是通过最大化不同类别数据点之间的间隔来完成的。这个过程被称为最大分离间隔。在构建超平面的过程中，只有离超平面最近的一些数据点才是关键的，它们被称为支持向量。这些支持向量决定了超平面的位置和方向。支持向量机的目标是找到一个超平面，使得支持向量到超平面的距离（函数间隔）最大化。这种最大间隔的选择有助于提高模型的泛化能力，使其在新数据上的表现更好。函数间隔是指数据点到决策超平面的带符号的距离。通过最大化函数间隔，支持向量机能够更鲁棒地处理噪声和泛化到未见过的数据。

假设给定一个线性可分的数据集 $D(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ ，如图 2.2 所示：




图 2.2 SVM 最优平面示意图

Fig 2.2 Schematic diagram of SVM optimal plane

其中红色和蓝色圆点分别代表不同的数据集样本点类别， $x \cdot \omega + b = 0$ 为支持向量机的分类方程，黑色线段为超平面，由于该超平面离数据集各样本点的平均距离最远，超平面收到样本点波动的影响较小，故该超平面的泛化能力最好，分类结果鲁棒性最高，即该超平面为最优超平面^[56]。直线 T_1 和 T_2 穿过 D_1 和 D_2 样本中距分类点最近的点且平行于超平面，这两条直线之间的距离即为分类间隔。通过归一化简化支持向量机的分类方程中常数项 b 和系数 ω 的计算：

$$y_i \cdot ((\omega \cdot x_i) + b) - 1 \geq 0, \quad i = 1, 2, \dots, n$$

若分离间隔 $\frac{2}{\|\omega\|}$ 到达最大值，最优超平面被确定且数据集样本点被分为支持向量和非支持向量。根据统计学习理论，支持向量机的学习过程可以看作是在最大化间隔的同时，通过优化一个结构风险最小化准则来选择最优超平面。这种方法使支持向量机能够在保持良好泛化能力的同时，对训练数据进行有效的分类。

支持向量机的学习可以形式化为一个凸二次规划问题。这个问题的目标是最大化函数间隔，即最小化权重向量的范数，并且在正确分类的前提下，最大化间隔。这是一个凸优化问题，可以通过常用的优化算法（如 SMO 算法、梯度下降等）来求解，在优化过程中，支持向量机需要满足一些约束条件，以确保对训练数据的完全正确分类。这些约束条件通常包括使每个样本点到超平面的距离大于等于 1（对于硬间隔支持向量机），或者允许一些样本点出现在间隔带内部（对于软间隔支持向量机）。为了解决带约束的凸二次规划问题，可以使用拉格朗日乘子法来转化为无约束问题。通过构建拉格朗日函数，并对其求偏导数，然后令偏导数为零，可以得到一组等式和不等式约束条件的解，从而得到最优的超平面参数。

$$J = \frac{\|\omega\|^2}{2} + C \sum_{i=1}^n L(y_i, \hat{f}(x_i, \omega))$$

上式中的 C 代表惩罚因子，表示对误分类的惩罚程度， C 值大小与惩罚程度和模型训练时的严格程度正相关， C 值越大，模型越容易过拟合；反之， C 值越小，模型可能会出现欠拟合现象，影响训练效果。损失函数 $L(\cdot)$ 用于评估模型预测结果与真实值之间的差距，损失函数 $L(\cdot)$ 的选择取决于具体的问题和数据集，在支持向量机中常用的损失函数有 0-1 损失和合页损失，SVM 是一种基于最小化损失函数的学习算法，它通过优化求解来找到最优的超平面，从而实现对数据的分类。

SVM 是一种现成的分类器，这意味着可以直接将其应用于数据分类而不需要进行太多修改^[57]。它的基本形式已经被广泛研究和实践，因此具有较低的入门

门槛。并且其在许多情况下能够获得较低的分类错误率主要因为它寻求找到能够最大化分类间隔的超平面,从而使分类边界更加鲁棒,减少了分类错误的可能性。支持向量机在处理复杂数据集时通常具有较高的泛化能力,即对新数据的预测能力很强。主要由于它的决策边界是由支持向量确定的,这些支持向量是最接近决策边界的数据点,因此更能够代表数据的特征,支持向量机不仅对训练集上的数据表现良好,而且对于训练集之外的新数据点也能够进行有效的分类决策,这是因为其决策边界是通过最大化间隔而不是直接拟合数据来确定的,因此更具有一般性。由于支持向量机产生的是一个二值决策结果,因此被称为“机”。这意味着它可以用于进行决策,而不仅仅是进行概率估计。总体来说,支持向量机是一种强大而灵活的机器学习算法,具有许多优点,包括对复杂数据的准确分类能力、较强的泛化能力以及在处理高维数据和小样本数据时的效果显著。

2.4 深度神经网络概述

深度学习(Deep Learning, 简称“DL”)是机器学习的一个子集,其主要通过数学函数模拟人类大脑的神经网络结构来进行学习和理解数据,与传统的机器学习算法相比,深度学习算法通常占用更多的数据和计算资源^[58]。深度学习的核心是人工神经网络(Artificial Neural Networks, 简称“ANNs”),这是一种由大量神经元组成的网络结构,每个神经元都与其他神经元连接,并且具有可调节的权重,用于学习输入数据的特征表示^[59]。

深度神经网络(Deep Neural Network, 简称“DNN”)是一种前馈人工神经网络,其由单层神经网络演化而来,且具有多个隐藏层。与单层神经网络模型相比,深度神经网络通常可以更好地提取特征并进行更有效的学习^[60]。如图 2.3 所示,深度神经网络主要由输入层、隐藏层和输出层组成。输入层用于向网络输入数据,隐藏层用来计算数据,而输出层则输出隐藏层计算出的结果,其特征是相邻层通过元节点完全连接,每个连接都有一个权重。




图 2.3 一种具有三个隐藏层的全连接深度神经网络

Fig 2.3 A fully connected deep neural network with three hidden layers

神经元是深度学习神经网络的基本组成部分，深度神经网络中每层都有多个神经元，神经网络的本质从数学角度上讲是一种运用带大量参数的非线性函数去逼近真值的函数。理论上讲神经网络的逼近能力与参数数量和网络层数正相关，但事实上考虑到可能存在的各种条件的限制，网络层数并不能无限制增加，如果数据量不足，可能会出现过拟合现象，更复杂的网络也可能需要更高的计算机配置和更长的训练时间。

神经元是深度学习神经网络的基本单位，每一层中都有大量的神经元，单个神经元的结构如图 2.4 所示：




图 2.4 单个神经元结构图

Fig 2.4 Single neuron structure diagram

通常来说，单个神经元的结构由输入、权重与偏置、激活函数、输出四部分构成：

输入：单个神经元的输入可以表示为 $x = (x_1, x_2, \dots, x_n)^T$ ，其中 $(\cdot)^T$ 代表矩阵或向量的转置；

权重与偏置：神经元权重为 $w = (w_1, w_2, \dots, w_n)^T$ ，偏置为 b ，对输入 x 加权求和，有

$$z = \sum_{i=1}^n w_i x_i + b$$

激活函数：非线性函数 σ 是神经元的激活函数，其作用是求出加权求和后的 z 值，这些函数引入非线性性，使得神经网络可以学习复杂的映射关系。常用的几种激活函数及其图像如图 2.5 所示：

Sigmoid 函数：

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

常用于返回 0 到 1 之间的值，在输出层中可以用于二分类问题。

双曲正切（tanh）激活函数：

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

类似于 Sigmoid，但将输入映射到范围 $(-1, 1)$ 。与 Sigmoid 相比，tanh 输出的范围更广，使其在某些情况下更有优势。

整流线性单元（Relu）激活函数：

$$\text{Relu}(x) = \max(0, x)$$

Relu 是一种简单而广泛使用的激活函数，它将负数部分截断为零并保留正数部分。在输入小于 0 时输出为 0，大于 0 时输出为输入值，其导数在输入大于 0 时为 1，小于 0 时为 0，避免了梯度消失问题。且有助于模型学习非线性特征，使得计算相对较为高效。然而，存在称为“Relu 死亡”的问题，即某些神经元可能在训练过程中永远不会激活。

Leaky-Relu 激活函数：

$$\text{Leaky-Relu}(x) = \begin{cases} \alpha x, & x < 0 \\ x, & x \geq 0 \end{cases}$$

其中 α 一般约为 0.01，引入这个参数的目的是使得 $x > 0$ 和 $x < 0$ 之间的差异更加明显。Leaky-Relu 激活函数相比传统 Relu 函数允许小于零的部分有一个

小的梯度。这有助于在训练过程中保持梯度流动，从而更好地学习，解决了“Relu 死亡”问题。




图 2.5 几种常见激活函数

Fig 2.5 Several common activation functions

输出：经激活函数作用后，神经元输出为：

$$Y = \sigma(z) = (w^T x + b)$$

在深度神经网络中，网络通常可以写为：

$$(f(x))_j = \sum_{i=1}^n w_{ij} x_i + b_j \quad i = 1, 2, \dots, k$$

$$\phi = (f_D \circ \sigma \circ f_{D-1} \circ \dots \circ \sigma \circ f_1)(x)$$

其中输入 x 作为训练集，输出 $\phi = \{\phi_i\}_{i=1}^k$ ，其中 D 表示层数。

在实际问题中，神经网络的训练将转化为求解目标函数的优化，即通过优化算法求解最优参数，使目标函数的值最小化，这是一个无约束优化问题。在解释深度神经网络前，首先使用函数将其输入输出关系抽象化：

$$f: \mathbb{R}^d \rightarrow \mathbb{R}$$

该函数接收通常对应于各种传感器测量的实值特征 $x = (x_1, x_2, \dots, x_d)^T$ 作为输入，产生一个实值分数作为输出，决策基于此输出。在机器学习中，函数输出可以被解释为支持/反对决定支持某个类的证据量。然后，通过测试输出分数是否高于某个阈值，或者对于多类问题，是否大于表示剩余类的其他函数的输出

分数，从输出分数中获得分类决策。

事实上，目前在很多场景中，线性模型或浅层神经网络已经没有足够的表达能力来最优地进行预测任务，深度神经网络已成为当下主流的预测模型，它可以抽象为一系列层的集合：

$$f(x) = f_L \circ \dots \circ f_1(x)$$

其中在每一层应用线性变换，然后逐个元素进行非线性变换。深度神经网络将大量的层组合在一起使得该模型具有较高的预测能力。

虽然深度神经网络这一模型在图像处理、人机交互、语音识别和推荐系统等领域的应用正在不断拓展和深化，但目前对深度神经网络的基础理论研究仍处于初级阶段，在深度学习领域，存在着几个迫切需要解决的问题：1）深度神经网络模型的解释困难问题：深度神经网络通常被视为黑盒模型，这使得人们难以解释其内部的具体推导实现过程和决策机制，给人们带来了理解和信任上的障碍，尤其是在涉及重要决策的应用场景中；2）深度神经网络的训练优化缓慢问题：训练一个深度神经网络需要大量的计算资源和时间，特别是当网络结构较复杂或数据集过大。在训练过程中，常常会发生梯度消失或梯度爆炸等问题，导致训练过程收敛缓慢甚至失败。3）深度神经网络的泛化能力问题：尽管深度神经网络在训练集上表现出色，但在未见过的数据上的泛化能力往往较差。这意味着模型过度拟合了训练数据，无法很好地适应新的输入，从而限制了其在实际场景中的应用。

2.5 决策树概述

与上述几种机器学习算法类似，随机森林（Random Forest，简称“RF”）同样在现有数据的基础上进行分析和建模，从而探索出数学规律进行分类预测^[61]。随机森林基于决策树构建而成，它通过训练多个决策树，并将它们的结果进行组合来进行分类或回归，由于分类结果由多颗决策树共同投票决定，因此实际分类效果要明显优于其他分类器，尤其在处理非线性的时间序列数据时表现突出。为了解随机森林的原理，必须首先引入决策树的概念：

决策树（Decision Tree）是一种基于树形结构进行决策的模型，它将协变量空间递归地划分为子空间，每个子空间都是不同预测函数的基础。决策树最常用于解决分类问题^[62]。分类的目标是根据对象或样本的属性值（特征）将它们分配到预定义的类别集合中。决策树由多个节点组成，从整个数据集开始，根节点对应于第一次数据分割，这表示数据在该节点被分成不同的子集。随后的子节点继续对数据进行进一步的分割，将数据划分为更小的块。这个过程一直持续下去，

直到某些条件满足，不再需要继续分割，或者达到了预定义的停止条件。这样的停止条件可以是节点中的样本数量达到某一阈值，或者树的深度达到一定限制等。叶子节点代表最终的数据分区或类别。当决策树的分割过程结束时，最后的子集被分配到某个叶子节点，这个叶子节点所对应的类别就是该子集中样本的分类结果。每个叶子节点表示一个类别或者一个离散的输出值。根节点没有传入边。内部节点（也称为测试节点）正好有一条入边和两条或多条出边。每个内部节点都表示要对实例进行检查的测试。每个分支（出边）表示测试的结果。叶子节点（也称为决策节点）没有输出边，并存放预测值或预测模型。决策树结构流程图如图 2.6 所示：




图 2.6 决策树结构图

Fig 2.6 Decision tree structure diagram

N_0 为根节点,入度为 0, 出度为 0 或 2, 两条出边指向两个内部节点 N_1 、 N_2 ；内部节点的入度为 1, 出度为 2, 出边指向决策节点 C_r 。

决策树的构建采用贪心策略，在每一层选择当前最优的特征进行节点划分，直到满足停止条件为止^[63-64]。决策树从根节点开始，通过对数据集的分割来构建树形结构，然后逐步扩展和细化每个分支，直到达到停止条件。在每次迭代中，算法都会寻找最佳分割属性，以便将数据集划分为效果最优的子集，由于大多数数据集为单变量，即数据集中的每个样本仅包含一个特征（变量），而不是多个特征，因此决策树需要在每个节点上选择一个特征作为分割属性，以将数据集划分为不同的子集。常用的分割标准包括信息增益和基尼指数。一旦确定了使用哪种分割标准，决策树会根据该标准下属性的取值将数据集划分为多个子集。对于数字型数据集，决策树会尝试找到一个分割点，将属性的取值分为两个区间，例如小于等于某个值和大于某个值，这样就得到了两个子集，可以进行进一步的节点划分。由于存在许多可能的分割点，因此决策树会选择使得这些分割准则值最大化（或最小化，根据不同的指标而定）的分割点作为最佳的分割点，以确保得

到最好的数据划分。

在决策树中，双亲节点和子节点不纯度的差被称为增益，决策树中最常用的算法为分类回归树（Classification and Regression Trees，简称“CART”）法，它通过对自变量的所有值进行遍历来选择使增益 $\Delta i(t)$ 的极大值点作为最优分割点，设双亲节点、左子节点、右子节点为 t_p 、 t_l 、 t_r ；CART 算法中最广泛的分割方法为基尼指数法，其不纯度 $i(t)$ 为：

$$i(t) = 1 - \sum_{j=1}^J \{p(j|t)\}^2$$

上式中 J 表示分类数量， $p(j|t)$ 表示节点 t 中 j 类的条件概率，在样本中表示为第 j 类样本所占的比例，可得不纯度增益 $\Delta i(t)$ ：

$$\Delta i(t) = - \sum_{j=1}^J p^2(j|t_p) + P_L \sum_{j=1}^J p^2(j|t_p) + P_R \sum_{j=1}^J p^2(j|t_p)$$

基尼指数法的最优分割：

$$\arg \max_{X_j < X_j^R, j=1,2,\dots,M} \left(- \sum_{j=1}^J p^2(j|t_p) + P_L \sum_{j=1}^J p^2(j|t_p) + P_R \sum_{j=1}^J p^2(j|t_p) \right)$$

决策树是一种自上而下的非参数分类方法，其通过逐层遍历数据集的特征属性，在每一层选择最佳的分类性能属性进行分割，最终构建出具有最优泛化能力的决策树模型。决策树原理虽简单易懂，但存在着两点主要缺陷：（1）决策树使用“分而治之”策略来训练模型。如果样本各属性间相关度较低，决策树分类效果便比较理想；反之，各属性间相关度较高，则决策树效果较差。（2）对训练集、不相关属性和噪声^[65]的过度敏感使决策树特别不稳定：靠近根的一个分支的微小变化将改变下面的整个子树。训练集中的小变化可能导致不同的分割，从而导致不同的决策树，影响最终分类结果。

2.6 本章小结

本章首先介绍了机器学习的基本原理与关键概念，并简要介绍了贝叶斯优化、支持向量机、深度神经网络、决策树算法这几种较为常见的机器学习方法。对于每种模型，本章不仅详细阐述了其原理和工作机制，还深入探讨了它们在各自领域中的应用场景和优势，旨在帮助读者更好地理解这些模型的特点和适用范围，从而为实际问题的解决提供有效的指导和思路。通过本章的说明，读者将能够更深入地了解机器学习的基本概念和原理，以及常见优化模型的工作机制和应用情况，为下一步探索和在物理过程中应用机器学习算法奠定了坚实的基础。

第 3 章 基于机器学习的线性激光稳定优化系统构建与仿真

为解决线性激光应用中的光束指向抖动问题,本章构建了一种基于机器学习的线性激光稳定优化系统,并进行了仿真实验。仿真实验是指使用计算机程序对实际系统复现模拟的过程,通过分析系统具体工作原理和组成结构建立模型,并观察和研究系统的动态特性。

3.1 激光稳定优化系统分析设计

本论文主要研究的基于机器学习的激光束稳定优化系统主要应用场景为室内,为验证方案可行性需要在理论上对实验进行设计和方案分析,在入射光受到扰动的情况下,通过机器学习算法控制,使光束保持稳定。本节从光学角度上进行分析方案可行性,为研究方法奠定理论基础。

3.1.1 线性光学系统光路分析

传统的激光束稳定控制系统从本质上来说是针对激光束的自适应调节系统,它使用位置测量-反馈控制的方案,即首先通过光学位置传感器测量到光束指向的变化,然后将接收到的位置信号传入伺服回路中,经过回路传达至控制系统,控制系统发送电信号驱动快速转向镜(Fast Steering Mirror,简称“FSM”)转动,反馈补偿光束的抖动偏差,使得激光指向保持稳定。

本系统采用的控制方案为双 FSM 光束稳定系统^[66],该系统由一个相对稳定的激光光源、2 组反射镜、2 组快速转向镜、2 个位置敏感探测器(Position Sensitive Detector,简称“PSD”)、2 个分束片、2 个聚焦镜、衰减片、计算机、控制器组成。系统原理图如图 3.1 所示。光束从光源输出后经过反射镜反射后到达快速转向镜 1 的中心,经快速转向镜 1 反射后到达快速转向镜 2 中心,接下来经过分束片 1 分束后大部分光反射出去作为主光束,另一部分光透射出去经过衰减片衰减后再由聚焦镜聚焦到达分束片 2,经分束片 2 分束后一部分光反射到达位置敏感探测器 PSD1,透射光经反射镜 2 反射后到达位置敏感探测器 PSD2。PSD1 用于探测近场光斑,与快速转向镜 1 对应;而 PSD2 用于探测远场光斑,与快速转向镜 2 对应。系统运行时,首先通过位置敏感探测器采集到光束指向的位置,将位置信号作为原始样本数据集输入到计算机中,计算机使用机器学习算法训练样本

数据，预测出激光的位置指向，发送信号到控制器，驱动快速转向镜调节激光角度及位置，使得主光束稳定。本系统中分束片 1 到 PSD1 与 PSD2 的距离应该相等，且略小于焦距 f ，这是由于在实际运行中焦点位置并不发生较大偏移，故位置敏感探测器应放置于焦前。两个快速转向镜默认应与水平面呈 45° 夹角，快速转向镜用于调节激光束位置及角度上的偏差，其中快速转向镜 1 调节光束的位置偏差，快速转向镜 2 调节光束的角度偏差。




图 3.1 线性激光稳定系统原理图

Fig 3.1 Schematic diagram of linear laser stabilization system

3.1.2 线性光学系统总体设计

线性激光稳定优化系统本质上来说属于一种自动化光学控制系统，它主要由光源、传感器、控制模块、快速转向镜四部分组成。其中传感器主要为 2 个位置敏感探测器，它主要用于实时捕捉探测系统中激光在水平和竖直的偏移量，并将采集到的信息传递给控制系统；本系统中控制模块为计算机和基于现场可编程门阵列（field programmable gate array，简称“FPGA”）的控制器。传感器采集到的信息到达计算机后，计算机通过机器学习算法训练计算相应数据，预测出下一步的偏移量后将电信号传递给控制器，控制器将控制信号传递给快速转向镜完成实时调节。控制模块是本系统的核心，它接收来自传感器的信息，并向快速转向镜输出信息。这四个部分协调共同工作，组成了线性激光稳定优化系统控制回路，流程框图如图 3.2 所示：




图 3.2 线性激光稳定优化系统流程图

Fig 3.2 Flowchart of Linear Laser Stability Optimization System

3.1.3 系统主要部件及参数

(1) 光源

本实验所采用的激光器为美国 Coherent 公司生产的 Legend Elite Duo HE+泵浦钛宝石激光放大器，中心波长 800 nm，输出功率 $\geq 16\text{W}$ ，占地面积较小，可靠性较高，实物图如图 3.3 所示：



图 3.3 钛宝石激光器

Fig 3.3 Titanium Sapphire Laser

(2) 位置敏感探测器

位置敏感探测器采用美国 Thorlab 公司的 PDQ80A 四象限位置探测器，有效探测波长为 400 nm ~ 1050 nm，有效探测区间为 3.9×3.9 mm，光敏部分由四个互相独立而又完全相同的象限形光电二极管组成，这四个光电二极管将光信号转化为光电流，通过光电流大小计算出光的位置信息，实物图如图 3.4 所示：



图 3.4 位置敏感探测器

Fig 3.4 Position Sensitive Detector

(3) 快速转向镜

快速转向镜的型号为 POLARIS-K1S3P，由美国 Thorlab 公司生产，镜片直径为 25.4 mm，带有三个压电调节器，设计用来为闭环系统提供长期的校准稳定性。它通过压电调节器提供每 0.1V 步进 0.5 微弧度的角度分辨率，实物图如图 3.5 所示：



图 3.5 快速转向镜（带镜架）

Fig 3.5 Quick Steering Mirror (with frame)

(4) 控制器

本实验采用的用于调节快速转向镜角度的控制器同样由美国 Thorlab 公司制造，型号为 K-Cube KPZ101，它拥有两个双向触发端口，用于读取或控制外部设备，可以通过附带的 USB 电缆连接电脑，具有功耗低，相应速度快的特点。实

物图如图 3.6 所示：



图 3.6 压电控制器

Fig 3.6 Piezoelectric Controller

3.2 数据采集与处理

使用机器学习算法优化前必须进行数据的采集与处理，通过采集激光在自由空间内的指向抖动情况，将测得的激光焦点质心位置在水平与竖直两个正交方向上的时空变化情况设为数据集 D ，取得数据集后为使其能更好地契合模型，需要对测量到的初始数据进行进一步的处理，接下来将详细描述数据采集与处理的过程：

3.2.1 数据采集

为更好地捕捉到激光在自由空间内的指向抖动规律，本系统首先评估了激光系统自由运行（无指向性反馈控制）时经 $f = 2\text{m}$ 的透镜聚焦的焦点位置的水平方向抖动情况和竖直方向抖动情况。测量中使用了 Ophir SP932U high resolution CCD 相机（30 万像素， 2048×1536 ），以 24 帧/秒的采样频率记录了 5 min 内在激光焦平面上的远场光斑质心的分布变化，如图 3.7 所示，其中插图为焦斑图样。自由状态下，焦斑在 $100\text{ }\mu\text{m}$ 范围内抖动，对应的指向性抖动范围为水平方向 $65\text{ }\mu\text{rad}$ ，竖直方向 $85\text{ }\mu\text{rad}$ 。这一抖动主要来自于系统噪声和随机噪声，对于指向性敏感的激光物理应用，需要通过指向稳定性系统加以反馈控制。




图 3.7 光斑分布散点图与光斑图（插图）

Fig 3.7 Scatter diagram of light spot distribution and light spot image (illustration)

接下来我们使用位置敏感传感器 PDQ80A 以每秒 150 次的采样频率对原始样本数据集进行采集，共采集 2 小时后，得到激光的指向抖动数据约 108 万条；具体为近场和远场光斑的质心的时间序列数据。

图 3.8 分别记录了自由状态下线性激光系统中光束指向抖动水平和竖直方向的时间序列细节，其中蓝色实线表示水平方向偏差，其零点为在 5 000 ms 内记录期间的平均点中心；红色实线则表示参考同一参考位置的竖直方向的偏差。其中光斑的中心位置由位置敏感传感器采集得出，而角度和像素偏差之间的关系在测试前进行校准。




图 3.8 自由运行状态下，水平（左）与竖直（右）方向指向性抖动时域曲线

Fig 3.8 Time domain curve of horizontal(left) and vertical(right) directional jitter in free running state

3.2.2 数据处理与特征提取

对于使用机器学习模型进行训练的数据集,使用特征工程对数据集进行特征提取是十分有必要的,它有助于提高模型的性能和泛化能力。特征工程是指通过选择、构建和转换特征来改善机器学习模型的输入数据,以便更好地揭示数据的模式和结构。样本数量较大的数据集如果不进行特征提取便直接进行训练,会大大增加模型的训练时间成本,降低训练效率。

对于时间序列的数据来说,最易提取的便是各种各样的统计特征,本系统中激光焦点质心在时间上的水平与竖直方向的抖动情况便为一种典型的时间序列数据:设水平方向的时序数据集为 $X = (x_1, x_2, \dots, x_n)$, 其中时间戳 t_i 对应的值为 x_i ; 对于时序数据而言,均值(mean)、方差(variance)、偏度(skewness)、峰度(kurtosis)等统计学的经典指标^[67]都可以作为统计特征,公式表示为:

$$\begin{aligned}\text{mean}(X) &= \frac{1}{n} \sum_{i=1}^n x_i \\ \text{varirance}(X) &= \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 \\ \text{skewness}(X) &= E\left(\left(\frac{X - \mu}{\sigma}\right)^3\right) = \frac{1}{n} \sum_{i=1}^n \frac{(x_i - \mu)^3}{\sigma^3} \\ \text{kurtosis}(X) &= E\left(\left(\frac{X - \mu}{\sigma}\right)^4\right) = \frac{1}{n} \sum_{i=1}^n \frac{(x_i - \mu)^4}{\sigma^4}\end{aligned}$$

使用以下方法对序列 $X = (x_1, x_2, \dots, x_n)$ 进行归一化:

$$\begin{aligned}\hat{x}_i &= \frac{x_i - \mu}{\sigma}, 1 \leq i \leq n \\ \hat{y}_i &= \frac{2x_i - \max(X) - \min(X)}{\max(X) - \min(X)}, 1 \leq i \leq n \\ \hat{z}_i &= \frac{x_i - \min(X)}{\max(X) - \min(X)}, 1 \leq i \leq n\end{aligned}$$

其中 μ 为时间序列的均值, σ 为时间序列的标准差,均值与标准差的计算公式在上文中已给出。

3.3 机器学习模型建立

3.3.1 定义参数空间与评估函数

首先确定需要优化的参数范围和步长，对于激光束指向稳定性的问题，可能涉及到调整激光束的位置、角度等参数。本文中的参数主要为位置传感器采集到的光束指向的数据集 D 中的数据，包括水平方向和竖直方向上激光束的指向性抖动的时间序列。根据具体情况，可以确定每个参数的范围和步长：数据集中的水平和竖直方向的偏差取值范围为 $(-100 \mu\text{rad} \sim +100 \mu\text{rad})$ ，超出此范围的数据为异常值，应舍去；由于位置敏感探测器的采样频率为 150 Hz ，故步长为 $1/150$ 秒。

为了便于对比不同模型的优化效果，本研究选取四个评估指标作为评估不同模型预测优劣的标准：

(1) 均方误差 MSE：函数关系式如下所示：

$$\text{MSE}(x, z) = \frac{1}{n} \sum_{i=1}^n (x_i - z_i)^2$$

(2) 均方根误差 RMSE：函数关系式如下所示：

$$\text{RMSE}(x, z) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - z_i)^2}$$

(3) 平均绝对值误差 MAE：函数关系式如下所示：

$$\text{MAE}(x, z) = \frac{1}{n} \sum_{i=1}^n |x_i - z_i|$$

(4) 平均绝对值百分比误差 MAPE：函数关系式如下所示：

$$\text{MAPE}(x, z) = \frac{1}{n} \sum_{i=1}^n \frac{|x_i - z_i|}{x_i} \times 100\%$$

上述公式中 x_i 代表真实值，而 z_i 代表经模型预测后的预测值， n 表示参与计算评估函数的样本数目， i 表示第 i 个样本。上述四个评估指标的值均为非负数，且数值大小与预测精度呈负相关；一般来说数值越小，模型的预测精度越高。在机器学习中，均方误差常作为模型的损失函数，该值越低模型越精确；而均方根误差在数值上为均方误差的开平方，量级上与原样本较为接近；平均绝对值误差相比于均方误差对异常误差敏感度较低；上述三项评估指标主要用于评价绝对误差，而平均绝对值百分比误差则通常用于评估相对误差，本研究使用几种误差评估方式相结合，使模型对比的评估预测更为科学。

3.3.2 高斯过程回归方法

高斯过程回归（Gaussian Process Regression，简称“GPR”）是统计学和机器学习领域中的一种数学工具，用于建模随机过程，无需对模型做出任何假设，其分析过程只需估计输入数据与输出之间的关系。给定一组观测数据，可以使用高斯过程预测新的未知输入对应的输出值，并提供相应的不确定性估计。高斯过程回归具有较高的计算效率，特别是在处理大规模数据时效率更加明显。由于高斯过程的求解可以通过矩阵计算来进行，因此可以利用矩阵运算的高效性，从而很好地处理大量数据。同时，高斯过程建模可以方便地进行增量学习，即在已有数据基础上随时添加新的数据进行建模，这使得高斯过程回归在实时应用和动态环境中具有适应性和实时性。

本研究为提高线性激光系统的指向稳定性，使用机器学习方法，通过采集大量激光束的光束指向位置坐标，采用高斯过程回归算法对这些数据进行分析和学习，提取激光束抖动模式和规律，最后通过控制策略给出对应调控参数对激光稳定性进行控制。相比传统方法，机器学习方法响应时间更短、控制效果更加精确和稳定，本研究使用高斯过程回归算法，对噪声数据进行综合分析，实现更高精度的指向稳定性快速反馈。

在高斯过程回归模型中，被拟合函数 $f(x)$ 可以表示为

$$f(x) = g(m(x), K(x, x'))$$

式中 x 是输入向量，在这里的值为位置敏感探测器采集到的光束指向抖动数据集中的数据； $m(x)$ 则为给定的均值函数； $K(x, x')$ 为定义域内任取 x, x' 两点的协方差函数。

在高斯过程回归中，我们通常用核函数 $K(r)$ 表示任意两点的协方差的值。常用的核函数有指数二次协方差核函数：

$$K(r) = (1 + \frac{r^2}{2\alpha l^2})^{-\alpha}$$

RBF 核函数：

$$K(r) = \sigma^2 \exp(-\frac{\|r\|^2}{2l^2})$$

Periodic 核函数：

$$K(r) = \sigma^2 \exp(-\frac{2}{l^2} \sin(\frac{\pi}{p})r)$$

式中： r 表示欧氏空间中 x, x' 两点的距离测度； σ, l, α, p 都是核函数中的超参数。

径向基函数是最为常用的协方差函数之一：

$$K(x, x') = \sigma^2 \exp(-\frac{|x - x'|}{2l^2})$$

高斯过程的推导与使用何种均值函数无关，故我们先假设 $m(x) = 0$ ，则 N 个目标点上的高斯先验分布可写为：

$$p(f|x) = (2\pi)^{(-N/2)} |K|^{-1/2} \exp\left(-\frac{1}{2} f^T K^{-1} f\right), K = K(x, x')$$

假设 x 点观测值 y 受到方差 σ^2 影响且相互独立，则似然函数为：

$$p(y|f, x) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_i - u_i(x_i))^2}{2\sigma^2}\right)$$

接下来，我们可以使用贝叶斯定理计算其后验分布：

$$p(y|f, x) = \frac{p(y|f, x)p(f, x)}{p(y|x)}$$

对数似然估计为：

$$\begin{aligned} \log p(y|x) &= \int p(y|f, x)p(f, x)du \\ &= -\frac{1}{2} y^T (K(x, x') + \sigma^2 I_N)^{-1} y - \frac{1}{2} \log |K + \sigma^2 I_N| - \frac{N}{2} \log 2\pi \end{aligned}$$

式中： I_N 表示大小为 $N \times N$ 的矩阵，其物理意义为时间序列数据中的观测值，其中 N 表示样本的数量。

则点 x^* 处对高斯过程回归 $f^* = f(x^*)$ 的预测可表示为：

$$E(f^*) = K(x^*, x)(K + \sigma^2 I_N)^{-1} y$$

$$\text{Var}(f^*) = K(x^*, x^*) - K(x^*, x)(K + \sigma^2 I_N)^{-1} K(x, x^*)$$

式中： E 为函数 $f(x)$ 的近似期望值； Var 为函数 $f(x)$ 的近似方差。

使用高斯过程回归模型，可以得到较高的拟合精度与预测值对应的方差和可信度。通过计算相关样本点，可以拟合得到高维模型。高斯过程回归模型搭建流程如图 3.9 所示：




图 3.9 GPR 模型搭建及预测模型

Fig 3.9 GPR model construction and prediction model

3.4 系统仿真实验与结果

本节将介绍使用高斯过程回归优化后的线性激光系统的指向稳定性系统仿真实验与结果，并将优化后的时域结果通过傅里叶变换转化为频域数据进行分析；同时为彰显机器学习算法的优越性，使用传统线性回归方法优化后与高斯过程回归算法进行对比和评估，以便直观展现机器学习方法迁移到光学系统中的鲁棒性和适用性。

3.4.1 实验配置

计算机环境

处理器：13th Gen Intel(R) Core(TM) i5-13600K 3.50 GHz

内存：16.00 GB

操作系统：Linux 操作系统（虚拟机）

编程语言：Matlab、Python3.8

编程环境：VS Code + tensorflow + scikit-learn + Jupyter Notebook

3.4.2 实验结果与分析

经过高斯过程回归优化后，随机连续抽取 5 毫秒采样，激光在水平和竖直方向的指向抖动时域曲线如图 3.10 所示：




图 3.10 GPR 优化后水平（左）与竖直（右）方向指向抖动

Fig 3.10 Horizontal(left) and vertical(right) directional jitter after GPR optimization

为了便于对比高斯过程回归模型在线性激光系统的指向稳定性优化方面的优越性，我们使用偏最小二乘法回归(Partial least squares regression, 简称“PLS”)这种线性回归方法作为对比。偏最小二乘法回归这种统计方法通过投影预测变量和观测变量到一个新空间来寻找一个线性回归模型，在建模过程中集中了主成分分析，典型相关分析和线性回归分析方法的特点。

使用线性回归优化后，随机连续抽取 5 毫秒采样，激光在水平和竖直方向的指向抖动时域曲线如图 3.11 所示：




图 3.11 线性回归优化后水平（左）与竖直（右）方向指向抖动

Fig 3.11 Horizontal(left) and vertical(right) directional jitter after linear regression

由图 3.8 可知，准直前的光束指向抖动范围为水平方向上 $65 \mu\text{rad}$ ，竖直方

向上 $85\ \mu\text{rad}$ ；使用线性优化方法的光束指向波动范围为水平方向上 $30.8\ \mu\text{rad}$ ，竖直方向上 $45.4\ \mu\text{rad}$ ；而使用高斯过程回归优化后的光束指向波动范围为水平方向上 $2.3\ \mu\text{rad}$ ，竖直方向上 $3.3\ \mu\text{rad}$ 。可以看出，高斯过程回归优化相较线性优化，指向稳定性提高了 1 个数量级以上，其原因主要是高斯过程回归是一种非参数方法，它对数据没有严格的假设或限制，能够自适应地适应光束指向波动优化问题中的各种数据分布和非线性关系。相比之下，线性优化方法在处理复杂的光束指向波动模型时可能受到线性假设的限制而失去准确性和鲁棒性。

为了进一步分析影响光束稳定性的主要来源，根据测得的时域指向波动，通过快速傅里叶变换（fast Fourier transform，简称“FFT”）分析光束指向波动的频谱分布，得到光束指向波动的频域图，如图 3.12 ~ 图 3.14 所示：




图 3.12 自由运行状态下水平（左）与竖直（右）方向指向波动频域图

Fig 3.12 Frequency domain diagram of horizontal(left) and vertical(right) directional fluctuations in free running state




图 3.13 GPR 优化后水平（左）与竖直（右）方向指向波动频域图

Fig 3.13 Frequency domain diagram of horizontal(left) and vertical(right) directional fluctuations after GPR optimization




图 3.14 线性回归优化后水平（左）与竖直方向（右）指向波动频域图

Fig 3.14 Frequency domain diagram of horizontal(left) and vertical(right) directional fluctuations after linear regression optimization

由图 3.12 可以看出在系统无准直时,水平方向上存在着明显的高低频振荡;由图可以看出在系统无准直时,竖直方向 36 Hz 的振荡占主导,因此推断该成分主要来源为实验光学平台的固有振荡频率,与前期测试的机械振动频率范围相吻合。而高频相位可能来自于激光放大器中的系统噪声,由图 3.10,图 3.11,图 3.13 和图 3.14 分析发现,使用高斯过程回归优化要显著优于传统线性优化方案,其不仅在低频部分(100 Hz 以内)能够有效消除噪声影响,在高频系统中的噪声优化效果也极佳。整体来说,高斯过程回归优化将高频噪声幅度降低了 1 个数量级,将低频噪声幅度降低到了约 45 %,体现了基于高斯过程回归的机器学习方案在处理多因素耦合问题上的优越性。

3.4.3 模型对比及评估

为了便于对比高斯过程回归模型在线性激光系统的指向稳定性优化方面的优越性,绘制出使用高斯过程回归方法与线性回归优化的损失函数曲线,如图 3.15 所示:




图 3.15 GPR 优化（左）与线性回归优化（右）后损失函数曲线

Fig 3.15 Loss function curve after GPR optimization (left) and linear regression optimization (right)

由图 3.15 左图分析可以看出, 经过约 12 轮训练轮数后, 使用高斯过程回归优化后的训练误差曲线便不足 0.001, 训练效果较佳; 而从 3.16 右图可以得出, 经过约 80 轮训练轮数后使用偏最小二乘法线性回归优化的损失函数误差约为 0.024 左右, 相比高斯过程回归方法效果较差。具体计算出的模型指标如表 3.1 所示:

表 3.1 GPR 优化与线性回归优化后评估指标

Tab 3.1 Evaluation indicators after GPR optimization and linear regression optimization

	GPR 优化	线性回归优化
MSE	65.35	928.33
RMSE	8.084	30.468
MAE	4.2699	26.3156
MAPE	0.0492%	0.9793%

由表 3.1 可知, 相比线性回归优化, 高斯过程回归优化后的绝对误差与相对误差值均降低了约一个数量级, 优化效果更佳。

3.5 本章小结

本章主要介绍了一种基于高斯过程回归的机器学习优化方法, 针对线性激光系统中存在的光束指向抖动问题进行系统评估并通过预测方法降低其指向抖动; 首先从从光学角度上进行了方案分析, 分析优化方法的可行性, 为研究方法奠定了理论基础, 接下来简要介绍了实验的主要部件及其参数; 然后简述了数据采集及处理过程, 接下来较为详细地介绍了机器学习模型的建立方法, 包括高斯过程

回归的概念以及模型的评估方法；最后进行了实验模拟与仿真，经优化后大大降低了线性光学系统中激光束指向的系统噪声，测试后振幅约为水平方向上 $2.3\ \mu\text{rad}$ ，竖直方向上 $3.3\ \mu\text{rad}$ ，并将高频噪声幅度降低了 1 个数量级，将低频噪声幅度降低到了约 45 %。同时使用线性回归方法作为对比，对比后印证了机器学习方法在拟合物理模型上的优越性。

第4章 基于机器学习的非线性激光稳定优化系统构建与仿真

为解决非线性激光系统中激光存在的指向脉漂、功率不稳定等问题，本章介绍了一种基于机器学习中的随机森林算法的非线性激光稳定优化系统，该系统在前文所述线性激光稳定优化系统的基础上增加了一段空芯光纤部分，并对总体光路进行了一定的调整，在计算机中进行了仿真实验模拟。

4.1 激光稳定优化系统设计

4.1.1 非线性光学系统光路分析

在本系统中，激光束在经过空芯光纤时，发生了三阶非线性光克尔效应(Kerr effect)与自相位调制(Self phase modulation, 简称“SPM”)过程，克尔效应是指物质因响应外界电场的感应而发生了折射率上的变化；而自相位调制是指是光波在介质中传播过程中，由于介质的非线性光学性质而导致光波的相位发生调制的现象。这种调制是由光波本身在介质中的强度分布不均匀引起的，当强度较高的光波通过介质时，由于克尔效应介质中的折射率发生了变化，而折射率的变化又会影响光波的相位。由于空芯光纤的纤芯较细，光路较长，对激光的指向稳定性要求也较高。实际应用时光路会存在扰动，实验平台也可能会产生振动，为了减少或抵消各种扰动对激光质量的干扰，引入激光稳定控制系统成为一个必要且紧迫的目标。

与线性激光稳定系统类似，本系统控制方案同样采用双FSM光束稳定系统，系统主要由一个相对稳定的激光光源、一组耦合透镜($f = 2m$)、3组反射镜、2组快速转向镜、2个位置敏感探测器(Position Sensitive Detector, 简称“PSD”)、2个分束片、3个聚焦镜、2个衰减片、计算机、控制器组成。系统原理图如图4.1所示。




图 4.1 非线性激光稳定系统原理图

Fig 4.1 Principle diagram of nonlinear laser stabilization system

光束从光源输出后经过反射镜反射后到达快速转向镜 1 的中心，经快速转向镜 1 反射后到达快速转向镜 2 中心，接下来经过焦距为 2m 的耦合透镜以便耦合入光纤中心；经分束片 1 分束后大部分光反射入空芯光纤中作为主光束，另一部分光透射出去经过衰减片 1 衰减后再由聚焦镜 1 聚焦到达反射镜 2，经反射镜 2 反射后经聚焦镜 1 聚焦到达位置敏感探测器 PSD1，主光束经空芯光纤后到达分束片 2，由衰减片 2 衰减后经反射镜 3 反射，再由聚焦镜 2 聚焦到达位置敏感探测器 PSD2。PSD1 用于入射光斑，与快速转向镜 1 对应；而 PSD2 用于探测出射光斑，与快速转向镜 2 对应。系统运行时，首先通过位置敏感探测器采集到光束指向的位置，将位置信号作为原始样本数据集输入到计算机中，计算机使用机器学习算法训练样本数据，预测出激光的位置指向，发送信号到控制器，驱动快速转向镜调节激光角度及位置，使得主光束稳定。两个快速转向镜默认应与水平面呈 45° 夹角，快速转向镜用于调节激光束位置及角度上的偏差。

4.1.2 非线性光学系统整体分析

非线性激光稳定优化系统本质上来说属于一种自动化光学控制系统，它主要由光源、传感器、控制模块、快速转向镜四部分组成。其中传感器主要为 2 个位置敏感探测器，它主要用于实时捕捉探测系统中激光在水平和竖直的偏移量，并将采集到的信息传递给控制系统；本系统中控制模块为计算机和基于现场可编程门阵列（Field Programmable Gate Array，简称“FPGA”）的控制器。传感器采集

到的信息到达计算机后，计算机通过机器学习算法训练计算相应数据，预测出下一步的偏移量后将电信号传递给控制器，控制器将控制信号传递给快速转向镜完成实时调节。控制模块是本系统的核心，它接收来自传感器的信息，并向快速转向镜输出信息。这四个部分协调共同工作，组成了非线性激光稳定优化系统控制回路，流程框图如图 4.2 所示：




图 4.2 非线性激光稳定优化系统流程图

Fig 4.2 Flowchart of Nonlinear Laser Stability Optimization System

4.1.3 系统主要部件及参数

(1) 光源、位置敏感探测器、快速转向镜、控制器

由于本章节是在上一章基础上所作的延申与扩展，所采用实验部件与上一章基本相同。所采用的激光光源、位置敏感探测器、快速转向镜、控制器不再详述。

(2) 空芯光纤

本研究使用的空芯光纤为上海光学精密机械研究所制造，外径 2 mm，芯径为 405 μm ，长度为 2.6 m，使用时在光纤内充入 Ne 气，气体压力为 700~1000 Pa，恒压模式。空芯光纤截面图如图 4.3 所示：

图 4.3 空芯光纤截面图^[68]Fig 4.3 Cross section diagram of hollow core optical fiber^[68]

4.2 数据采集与处理

4.2.1 数据采集

为更好地捕捉到激光在自由空间内的指向抖动规律,本系统首先评估了激光系统自由运行(无指向性反馈控制)时经空芯光纤后的水平方向抖动情况和竖直方向抖动情况。测量中使用了 Ophir SP932U high resolution CCD 相机(30 万像素, 2048×1536),以 24 帧/秒的采样频率记录了 5 min 内在激光焦平面上的远场光斑质心的分布变化,如图 4.4 所示,其中插图 of 焦斑图样。自由状态下,焦斑在 $100\ \mu\text{m}$ 范围内抖动,对应的指向性抖动范围为水平方向 $26\ \mu\text{rad}$, 竖直方向 $23\ \mu\text{rad}$ 。这一抖动主要来自于空芯光纤内光束发生的自相位调制等非线性过程。




图 4.4 光斑分布散点图与光斑图(插图)

Fig 4.4 Cross section diagram of hollow core optical fiber

接下来我们使用位置敏感传感器 PDQ80A 以每秒 150 次的采样频率对原始样本数据集进行采集，共采集 1 小时后，得到激光的指向抖动数据约 64 万条；具体为近场和远场光斑的质心的时间序列数据。

图 4.5 分别记录了自由状态下线性激光系统中光束指向抖动水平和竖直方向的时间序列细节，其中蓝色实线表示水平方向偏差，其零点为在 5 000 ms 内记录期间的平均点中心；红色实线则表示参考同一参考位置的竖直方向的偏差。其中光斑的中心位置由位置敏感传感器采集得出，而角度和像素偏差之间的关系在测试前进行校准。




图 4.5 空芯光纤出射光水平（左）与竖直（右）方向指向性抖动时域曲线

Fig 4.5 Time domain curves of directional jitter in the horizontal (left) and vertical (right) directions of the emitted light from hollow core optical fibers

4.2.2 数据处理与特征提取

对于非线性激光稳定优化系统而言，数据的处理与特征的提取过程与线性激光稳定优化系统大致相同：设非线性系统中水平方向的时间序列数据集为 $X_1 = (x_1, x_2, \dots, x_n)$ ，其中时间戳 t_i 对应的值为 x_i ，我们同样使用均值、方差、偏度与峰度作为非线性激光稳定优化系统的统计特征。

4.3 机器学习模型建立

4.3.1 定义参数空间与评估函数

本章节中所定义的参数主要为位置传感器采集到的非线性系统中光束指

向的数据集 D_1 中的数据，包括水平方向和竖直方向上激光束的指向性抖动的时间序列。根据具体情况，可以确定每个参数的范围和步长：数据集中的水平和竖直方向的偏差取值范围为 $(-100 \mu\text{rad} \sim +100 \mu\text{rad})$ ，超出此范围的数据为异常值，应舍去；由于位置敏感探测器的采样频率为 150 Hz，故步长为 1/150 秒。

为了便于对比不同模型的优化效果，本章中使用 MSE、RMSE、MAE、MAPE 这四个评估指标作为评估不同模型预测优劣的标准。

4.3.2 随机森林算法

为解决决策树存在的诸多缺陷，Leo Breiman 等人在 2001 年提出了随机森林方法^[50]，“随机”意味着随机森林随机选取特征和随机抽取样本，而“森林”意味随机森林通过生成多颗决策树参与决策，通过多数投票的方式确定最终样本分类。使用随机森林算法可以较好地解决决策树泛化能力差的问题，同时分类的精度也得到了一定提高。

随机森林使用 Bagging 套袋法这种抽样方法进行抽取，Bagging 方法通过随机采样的方式生成众多并行式的分类器，通过少数服从多数的原则来确定最终结果。首先从原始样本集中不一定有放回地随机选择 n 个样本，总共进行 k 轮，以获得 k 个可能具有重复元素的独立训练集。接下来在每个训练集上训练一个模型，并获得 k 个结果。对于分类问题，使用结果中的多数值作为最终结果，而对于回归问题，使用平均值作为最后结果。Bagging 套袋法结构图如图 4.6 所示：




图 4.6 Bagging 算法结构图

Fig 4.6 Bagging Algorithm diagram

随机森林算法结构图如图 4.7 所示：




图 4.7 随机森林算法结构图

Fig 4.7 Structure diagram of Random Forest Algorithm

随机森林的具体构建过程如下：假设原始样本数据集 $D(x_1, x_2, \dots, x_n)$ ，建立 k 颗决策树：

- （1）数据集抽取：从原始数据集中使用自助采样法随机有放回地随机抽取 n 个样本，对于分类方法，若样本总数为 N ，则采样集大小也为 n 。回归问题同样进行自助采样。抽取过程重复进行 n 次组成训练集；剩余样本则为袋外数据集，即测试集 OOB。
- （2）特征抽取与选择：在每次构建决策树的过程中，随机选择一部分特征，通常是从所有特征中随机选择一部分作为候选特征，并计算其相对应的基尼指数，选择基尼指数值最小的特征及其对应分割点为最优分割点，同时生成 2 个叶子节点，将剩余训练数据放入叶子节点中。这样做的目的是为了增加每棵树之间的差异性，使得随机森林中的每棵树都有不同的特点。
- （3）决策树构建：对每个训练集重复进行（2），递归分割节点直至所有叶子节点生成。
- （4）随机森林：重复步骤（2）、（3），直至生成 k 颗决策树。
- （5）数据测试：训练集生成后的每颗决策树对测试集结果进行分类，投票统计 k 个结果，得票最高者即为样本类别。

随机森林是性能最好的学习机器学习算法之一。它在预测任务方面比线性回归做得更好，主要原因是线性回归首先假设模型为线性。这种假设使模型易于解

释,但通常不够灵活,无法进行预测。随机森林很容易适应数据中的非线性关系,因此往往比线性回归更好地预测。更具体地说,像随机森林这样的集成学习算法非常适合大中型数据集。当自变量数大于观测值数时,由于估计的参数可能呈指数增长,参数估计会十分困难,故线性回归和逻辑回归算法效果将会变得很差。随机森林由于具有较高的灵活性、鲁棒性和能够处理复杂数据关系的能力,使其成为许多机器学习问题的首选算法之一。考虑到随机森林算法的上述优势,本研究采用随机森林算法作为非线性激光稳定优化系统的主要方法。

4.4 系统仿真实验与结果

本节将介绍使用随机森林算法优化后的非线性激光系统的指向稳定性系统仿真实验与结果,为表现随机森林算法的优越性,使用贝叶斯优化算法优化后与随机森林算法进行对比和评估,以便直观展现随机森林算法在处理非线性时序数据中的优势。

4.4.1 实验配置

计算机环境

处理器: 13th Gen Intel(R) Core(TM) i5-13600K 3.50 GHz

内存: 16.00 GB

操作系统: Linux 操作系统(虚拟机)

编程语言: Matlab、Python3.8

编程环境: VS Code + tensorFlow + scikit-learn + Jupyter Notebook

4.4.2 实验结果与分析

经过随机森林算法优化后,在空芯光纤出射光焦平面上随机连续抽取 5 毫秒采样,激光在水平和竖直方向的指向抖动时域曲线如图 4.8 所示:




图 4.8 RF 优化后水平（左）与竖直（右）方向指向性抖动时域曲线

Fig 4.8 Time domain curves of horizontal (left) and vertical (right) directional jitter after Random Forest optimization

为了便于对比随机森林算法在非线性激光系统的指向稳定性优化方面的优越性，我们使用贝叶斯优化算法作为对比。贝叶斯优化依赖于贝叶斯统计和先验知识来预测函数的性能，并通过构建概率模型来不断更新和改进目标函数的搜索，而随机森林更侧重于通过多个决策树的平均或多数投票来提高预测的准确性和稳定性，在时序数据上的预测有着突出的优势

使用贝叶斯算法优化后，随机连续抽取 5 毫秒采样，激光在水平和竖直方向的指向抖动时域曲线如图 4.9 所示：




图 4.9 BO 优化后水平（左）与竖直（右）方向指向性抖动时域曲线

Fig 4.9 Time domain curves of horizontal (left) and vertical (right) directional jitter after Bayesian Optimization

由图 4.7 ~ 图 4.9 可知，准直前的光束指向抖动范围为水平方向上 $36 \mu\text{rad}$ ，竖直方向上 $45 \mu\text{rad}$ ；使用随机森林算法优化后的的光束指向波动范围为水平方

向上 $7.6 \mu\text{rad}$ ，竖直方向上 $6.4 \mu\text{rad}$ ；而使用高斯过程回归优化后的光束指向波动范围为水平方向上 $18.9 \mu\text{rad}$ ，竖直方向上 $22.4 \mu\text{rad}$ 。可以看出，随机森林优化相较贝叶斯优化，光束的指向稳定性提高了约 3 倍，其原因主要是随机森林算法训练过程中使用了多个决策树，并且每个决策树只使用数据的一个子集进行训练，因此对异常值和噪声具有一定的鲁棒性在处理时序数据中的异常情况时更加稳健。能够自适应地适应光束指向波动优化问题中的各种数据分布和非线性关系。相比之下，贝叶斯优化方法可能对输入数据的分布和范围过于敏感，需要对数据进行归一化或标准化，而随机森林通常不需要对输入数据进行这样的预处理，因此预测准确度更高。

4.4.3 模型对比与评估

为了对比出随机森林算法与贝叶斯优化在非线性激光系统的指向稳定性优化上的优劣，绘制出使用随机森林算法与贝叶斯优化的损失函数曲线，如图 4.10 所示：




图 4.10 RF 优化（左）与 BO 优化（右）后损失函数曲线

Fig 4.10 Loss function curves after Random Forest optimization (left) and Bayesian Optimization (right)

由图 4.10 左图分析可以看出，经过约 30 轮训练轮数后，使用随机森林算法优化后的训练误差曲线稳定在 0.0065 左右，训练效果较佳；而从图 4.10 右图可以得出，经过约 50 轮训练轮数后使用贝叶斯算法优化的损失函数误差约为 0.028 左右，相比随机森林效果较差。具体计算出的模型指标如表 4.1 所示：

表 4.1 RF 优化与 BO 优化后评估指标

Tab 4.1 Evaluation indicators after Random Forest optimization and Bayesian Optimization

	RF 优化	BO 优化
MSE	224.85	1248.33
RMSE	14.99	35.33
MAE	9.2537	34.7581
MAPE	0.2324%	1.3262%

由表 4.1 可知，相比贝叶斯优化，随机森林算法优化后的绝对误差与相对误差值均降低到了约五分之一，优化效果更佳。

4.5 本章小结

本章主要介绍了一种基于随机森林的机器学习优化方法，针对非线性激光系统中存在的光束指向抖动问题进行系统评估并通过回归的预测方法降低其指向抖动；首先从光学角度上进行了方案分析，分析优化方法的可行性，为研究方法奠定了理论基础，接下来简要介绍了实验的主要部件及其参数；然后简述了数据采集及处理过程，接下来介绍了机器学习模型的建立方法，；最后进行了实验模拟与仿真，经优化后大大降低了由于自相位调制及系统误差引起的非线性光学系统中激光束指向的系统噪声，测试后振幅约为水平方向上 $7.6 \mu\text{rad}$ ，竖直方向上 $6.4 \mu\text{rad}$ ，训练误差曲线稳定在 0.0065 左右；同时使用贝叶斯方法作为对比，对比后印证了随机森林算法在拟合预测时序数据模型上的优越性。

第 5 章 总结与展望

5.1 全文总结

随着科技的发展与社会的进步,激光在人们的生产生活中逐渐扮演着更为重要的角色,在通信、医疗、化学、工业技术等方面得到了进一步的应用。例如在激光微纳加工这一新型工业技术中,为保证加工质量,对控制系统与定位的精度要求极高,需要保证激光束的指向稳定而不发生较大漂移。激光在实际应用时存在着一个较为严重的问题便是极容易受到外界或自身干扰而导致光束不稳定。假如激光的指向稳定性或功率稳定性波动较大,容易给带来财产损失,甚至危害到人们的生命安全。因此,如何更好地优化光学系统,提高激光的稳定性,是一个亟待解决的问题。本研究使用机器学习这种基于数据驱动的计算机算法,提高了线性激光系统与非线性激光系统中激光束的指向稳定性。通过构建高斯过程回归与随机森林这两种机器学习算法,大大降低了激光系统中的指向抖动。此外,机器学习算法成功应用于物理模型中,有效解决了多因素耦合的复杂光学问题,从而为人工智能算法与物理相互结合的实际应用和相关研究工作提供了坚实的基础。

5.1.1 工作总结

本文所研究主要内容为基于机器学习的激光稳定优化系统,主要解决的是如何通过机器学习这一计算机技术来解决外界或自身干扰造成激光不稳定的问题,设计了一套由光学元件与计算机组成的激光稳定优化系统,当激光受到干扰时,通过机器学习整理总结先前数据而对光束的指向进行预测,从而达到反馈调节的效果。主要工作如下:

- (1) 分析并创新性地设计了一种以高斯过程回归算法为基础的线性激光稳定优化系统,针对线性激光系统中存在的光束指向抖动问题进行系统评估,并通过预测的方法降低其指向抖动。大大降低了线性光学系统中激光束指向的系统噪声,测试后振幅约为水平方向上 $2.3\ \mu\text{rad}$, 竖直方向上 $3.3\ \mu\text{rad}$ 。相比优化前水平与竖直方向上分别为 $65\ \mu\text{rad}$ 与 $85\ \mu\text{rad}$ 的振幅提升了约 20 倍,相比偏最小二乘法这种线性优化方法将高频噪声幅度降低了 1 个数量级,将低频噪声幅度降低到了约 45%,体现了基于高斯过程回归的机器学习方案在处理多因素耦合问题上的优越性。

- (2) 针对非线性光学系统中激光由于受到自相位调制这一非线性过程干扰而发生指向与功率不稳定的问题,创新性地设计出了一种基于随机森林算法的非线性激光稳定优化系统,针对线性激光系统中存在的光束指向抖动问题进行系统评估,并通过预测的方法降低其指向抖动。测试后振幅约为水平方向上 $7.6\ \mu\text{rad}$, 竖直方向上 $6.4\ \mu\text{rad}$ 。相比现有飞秒激光系统中使用的自准直系统约几十个 μrad 的指向稳定精度有较大提升,指向精度提升了约 10 倍。该系统可广泛应用于使用飞秒激光器的光学系统中,预期能够较好解决飞秒激光系统中光束指向不稳定的问题。

5.1.2 主要贡献及创新点

本文在激光光束的稳定性优化研究中,有以下两个关键创新点:

首先,在激光光束的稳定优化系统的设计上,通过文献调研和分析,使用了主动控制方法,可以提高实验精度、优化实验参数,还可以降低要求条件、延长设备使用寿命,并且有助于避免潜在的安全隐患。

其次,针对影响激光稳定性的因素对于复杂使用环境和不同的激光系统之间差异巨大,且难以建立准确的物理模型来精准描述指向抖动的问题,创新型地使用了机器学习这种在解决多变量因素耦合的复杂问题上具有独特优势的方法,从输入的大量数据中学习提取规律,总结数据的变化特征,并利用这些模式和规律来做出预测或做出决策,提高了激光光束的整体稳定性,对于激光光束稳定性敏感的精密实验和精密加工具有重要意义。

5.2 研究展望

然而,由于时间有限,本课题仍存在着一些不足,未来的研究应着眼于以下方向:

- (1) 在优化过程中只考虑到了指向稳定性对激光光束质量的影响,然而光斑形状、光谱等因素同样对激光光束质量有一定的影响。未来可以考虑引入更多变量,使用机器学习方法探究多个变量之间相互耦合的复杂关系,以期达到更好的优化效果。
- (2) 由于时间因素,本文只采用了少数几种常见的机器学习算法对激光的稳定性进行优化,随着人工智能技术的不断发展,机器学习算法也在不断迭代更新,未来可以考虑使用新的机器学习或深度学习算法,并与前面的算法进行比较,或许能使得优化模型更加优异。

激光的稳定优化研究是一门设计到多个学科的综合性的技术，其技术的革新离不开相关科研人员的努力，期待着激光能够得到更为广泛的应用，普惠于民的那天。

参 考 文 献

- [1] 高铎瑞, 谢壮, 马榕, 等. 卫星激光通信发展现状与趋势分析[J]. 光子学报, 2021, 50(4): 9-29.
- [2] 冯国英, 周寿桓. 激光光束质量综合评价的探讨[J]. 中国激光, 2009, 36(07): 1643-1653.
- [3] THOMAS H L, ALISON M, , PAUL R, et al. Spectrally Beam-Combined Fiber Lasers for High-Average-Power Applications[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2007, 13(3): 487-497.
- [4] 陈虹, 吴世凯, 张正伟, 等. 高功率激光光束特性对激光加工的影响[J]. 光学技术, 2006, 32(6): 834-837.
- [5] FENG C, DONG Y, JIN G. Dynamic effects of temperature-dependent aberration factors on beam quality of LD end-pumped lasers[J]. Japanese Journal of Applied Physics, 2022, 61(10): 100904.
- [6] KENDALL E D, ROSA B, FLORENCE C, et al. Femtosecond laser-assisted cataract surgery[J], Journal of Cataract & Refractive Surgery, 2013, 39(13): 1753-1763.
- [7] TRIKHA S, TURNBULL A, MORRIS R. et al. The journey to femtosecond laser-assisted cataract surgery: new beginnings or a false dawn?[J], Eye, 2013, 27: 461-473.
- [8] DOLMANS D, FUKUMURA D, JAIN R. Photodynamic therapy for cancer[J], Nature Review Cancer, 2003, 3(5):380-387.
- [9] THOMAS S MANG, Lasers and light sources for PDT: past, present and future[J], Photodiagnosis and Photodynamic Therapy, 2004, 1(1): 43-48,
- [10] SUGIOKA K, CHENG Y. Femtosecond laser three-dimensional micro-and nanofabrication[J]. Journal of Applied Physics, 2014, 1(4): 041303.
- [11] 王洪庆, 温积森, 杨臻垚, 等. 高速并行双光子激光直写光刻系统[J]. 中国激光, 2022, 49(22): 121-128.
- [12] AccSci Corp. Nanofabrication[EB/OL]. (2024-3-2) [2024-3-2]<https://www.accscicn.com/nanofabrication/fabrication-lithography>.
- [13] ELSA G. Nonlinear optics in daily life[J]. Optical Express, 2013, 21: 30532-30544.
- [14] SMIRNOVA D, LEYKAM D, CHONG Y. Nonlinear topological photonics[J]. Applied Physics Reviews, 2020, 7(2): 021306.
- [15] 姚林海, 陆培国, 杨永安, 等. 光束指向稳定性高精度检测方法研究[J]. 应用光学, 2022, 43(2): 339-344.
- [16] LI S S, PENG Y W, FAN D, et al. Study of evaluating nearfield beam quality of the high power laser beams[J]. Optik, 2018, 157: 148-155.

- [17] GRAY J, THOMAS P, ZHU X D. Laser pointing stability measured by an oblique-incidence optical transmittance difference technique[J]. Mrs Online Proceedings Library Archive, 2001, 72(9): 3714-3717.
- [18] TOYOFUKU K, et al, Study on dynamic characteristic analysis of air spring with auxiliary chamber[J]. JSAE review, 1999, 20(3): 349-355.
- [19] SARAI S, M IKEDA, T MIURA. Decentralized position and attitude control of a vibration isolation system[C]. Control Applications, 2001.(CCA'01). Proceedings of the 2001 IEEE International Conference on. 2001. IEEE.
- [20] INAGAKI K, T MIYAZAKI, M FUJISE. High-speed tracking target simulator for fine tracking mechanisms[J]. Proceedings of SPIE - The International Society for Optical Engineering, 1994, 63(8): 652-654.
- [21] YOU W, DOUG F, IGOR J, Passive beam pointing stabilization[J]. Optics letters, 2010, 35(2): 250-252.
- [22] MRC Systems GmbH. Active Laser Beam Stabilization[EB/OL].(2023-9-15) [2023-9-15].<https://www.mrc-systems.de/en/products/laser-beam-stabilization>.
- [23] BARNA A, FÖLDES I B, BOHUS J, et al. Active stabilization of the beam pointing of a high- power KrF laser system[J]. Metrology and Measurement Systems, 2015, 22(1): 165-172.
- [24] MENG Q, STIRLING J, WADSWORTH W J, et al. ACute3D: A Compact, Cost-Effective, 3-D Printed Laser Autocollimator[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-11.
- [25] 宋跃辉, 鲁雷雷, 华灯鑫, 等. 同轴米散射激光雷达自准直系统设计[J].中国激光, 2016, 43(07): 245-253.
- [26] XIE M L, LIU P, MA C W, et al. Application research of high-precision laser beam pointing technology in airborne aiming pod[J]. Optik, 2019, 183: 775-782.
- [27] 杨红伟, 杜益冕, 吕立冬, 等. 基于差分成像的激光光束指向性控制[J]. 中国激光, 2021, 48(17): 78-85.
- [28] ZHAO H, DING W, FAN M, et al. An optical method based auto-collimation for measuring five degrees of freedom error motions of rotary axis[J]. Review of Scientific Instruments, 2022, 93(12): 110-125.
- [29] JIANG L, WANG A D, LI B, et al. Electrons dynamics control by shaping femtosecond laser pulses in micro/nanofabrication: modeling, method, measurement and application[J]. Light Science and Application, 2018, 7: 17134.
- [30] ZHANG D, ZENG Y, BAI Y. et al. Coherent surface plasmon polariton amplification via

- free-electron pumping[J]. *Nature*, 2022, 611: 55-60.
- [31] AHMMED K M T, GRAMBOW C, KIETZIG A M. Fabrication of Micro/Nano Structures on Metals by Femtosecond Laser Micromachining[J]. *Micromachines*, 2014, 5: 1219-1253.
- [32] 刘哲生, 张冬冬, 李洪阳, 等. 基于高斯过程回归的线性激光束指向稳定优化[J]. *应用光学*, 2023, 44(06): 1265-1272.
- [33] JANIESCH C, ZSCHECH P, HEINRICH K. Machine learning and deep learning[J]. *Electronic Markets*, 2021, 3(13): 685-695.
- [34] BIAMONTE J, WITTEK P, PANCOTTI N, et al. Quantum machine learning[J]. *Nature*, 2017, 549(7671): 195-202.
- [35] JIANG T, GRADUS J, ROSELLINI A. Supervised Machine Learning: A Brief Primer[J]. *Behav Ther.* 2020, 51(5):675-687.
- [36] CAMBRIA E, WHITE B. Jumping NLP Curves: A Review of Natural Language Processing Research [J]. *IEEE Computational Intelligence Magazine*, 2014, 9(2): 48-57.
- [37] ATHANASIOS V, NIKOLAOS D, ANASTASIOS D, et al. Deep Learning for Computer Vision: A Brief Review[J]. *Computational Intelligence and Neuroscience*, 2018: 7068349.
- [38] ZHANG Y, WENG Y, LUND J. Applications of Explainable Artificial Intelligence in Diagnosis and Surgery[J]. *Diagnostics*, 2022, 12(2):237.
- [39] MCGOVERN A, ELMORE K L, GAGNE D J, et al. Using Artificial Intelligence to Improve Real-Time Decision-Making for High-Impact Weather[J]. *Bulletin of the American Meteorological Society*, 2017, 98(10): 2073-2090.
- [40] HUANG G, SONG S, GUPTA J, et al. Semi-Supervised and Unsupervised Extreme Learning Machines[J]. *IEEE Transactions on Cybernetics* 2014, 44(12): 2405-2417.
- [41] BRO R, SMILDE A K. Principal component analysis[J]. *Analytical Methods*, 2014, 6, 9: 2812-2831.
- [42] SCRUCCLA L, FOP M, MURPHY T B. mclust 5: Clustering, Classification and Density Estimation Using Gaussian Finite Mixture Models[J]. *The R Journal*, 2016, 8(1): 205-233.
- [43] PAN Z, YU W, YI X, et al. Recent Progress on Generative Adversarial Networks (GANs): A Survey[J]. *IEEE Access*, 2019, 7: 36322-36333.
- [44] YUTAKA M, YANN L, MANEESH S, et al. Deep learning, reinforcement learning, and world models[J]. *Neural Networks*, 2022, 152: 267-275.
- [45] LIANG D, RUOBIN G, David Z W, et al. Bayesian optimization based dynamic ensemble for time series forecasting[J]. *Information Sciences*, 2022, 591: 155-175.
- [46] DING F, PAN J, ALSAEDI A, et al. Gradient-Based Iterative Parameter Estimation Algorithms for Dynamical Systems from Observation Data[J]. *Mathematics*, 2019, 7(5): 428.

- [47] GILES M B. Multilevel Monte Carlo methods[J]. *Acta Numerica*, 2015, 24: 259-328.
- [48] GAO W, JIANG Z P. Adaptive Dynamic Programming and Adaptive Optimal Output Regulation of Linear Systems[J]. *IEEE Transactions on Automatic Control*, 2016, 61(12): 4164-4169.
- [49] PENG M F, HUI D, WEI C, et al. Naive Bayes Classifier with Feature Selection to Identify Phage Virion Proteins[J]. *Computational and Mathematical Methods in Medicine*, 2013: 530696.
- [50] ERIC S, MAARTEN S, ANDREAS K. A tutorial on Gaussian process regression: Modelling, exploring, and exploiting functions[J]. *Journal of Mathematical Psychology*, 2018, 85: 1-16.
- [51] LIU H, ONG Y S, SHEN X, et al. When Gaussian Process Meets Big Data: A Review of Scalable GPs[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(11): 4405-4423.
- [52] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine learning*, 1995, 20(3): 273-297.
- [53] YANG M G, Ubeynarayana C U. Construction accident narrative classification: An evaluation of text mining techniques[J]. *Accident Analysis & Prevention*, 2017, 108: 122-130.
- [54] ABDULHAMIT S. Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders[J]. *Computers in Biology and Medicine*, 2013, 43(5):576-586.
- [55] WANG H F, ZHENG B S, SANG W Y, et al. A support vector machine-based ensemble algorithm for breast cancer diagnosis[J]. *European Journal of Operational Research*, 2018, 267(2): 687-699.
- [56] 蒋觉义, 何玉珠, 李建宏. 基于误差最小的 SVM 最优分类面修正[J]. *北京航空航天大学学报*, 2012, 38(11): 1483-1486.
- [57] CHAUHAN V, DAHIYA K, SHARMA A. Problem formulations and solvers in linear SVM: a review[J]. *Artificial Intelligence Review*, 2019, 52: 803-855.
- [58] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521: 436-444.
- [59] FENG J, YAGUO L, JING L, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. *Mechanical Systems and Signal Processing*, 2016, 72(73): 303-315.
- [60] TAVANAEI A, GHODRATI M, KHERADPISHEH S, et al. Deep learning in spiking neural networks[J]. *Neural Networks*, 2019, 111: 47-63.
- [61] JAIME L, MICHAEL E, MILLER J, et al. A comparison of random forest variable selection methods for classification prediction modeling[J]. *Expert Systems with Applications*, 2019,

- 134: 93-101.
- [62] CHRISTOPHER K, XUAN A, NICOLAS H. Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500[J]. European Journal of Operational Research, 2017, 259(2): 689-702.
- [63] ROKACH L. Decision forest: Twenty years of research[J]. Information Fusion, 2016, 27:111-125.
- [64] KAMINSKI B, JAKUBCZYK M, SZUFEL P. A framework for sensitivity analysis of decision trees[J]. Centtal European Journal Operations Research, 2018, 26: 135-159.
- [65] BREIMAN L. Random Forests[J]. Machine Learning, 2001, 45(1): 5-32.
- [66] 邓耀初. 振动环境下的快速反射镜精跟踪系统[J]. 激光与红外, 2008, 1(01): 11-13.
- [67] MARIA J, JAUME A, DOLORES L. Skewness and Kurtosis in Real Data Samples[J]. Methodology-European Journal Of Research Methods For The Behavioral And Social Sciences, 2013, 9, 2: 78-84.
- [68] ZHU X, YU F, WU D, et al. Laser-induced damage of an anti-resonant hollow-core fiber for high-power laser delivery at 1 μm [J]. Optics Letters, 2022, 47(14): 3548-3551.

致 谢

此课题是由田野老师建议我研究的，在研究过程中遇到了很多困难，田野老师一次次不厌其烦地对我进行耐心的指导和点拨，给我提出了很多中肯的建议，感激不尽。在考求职最艰苦的一段时间里，田野老师并没有一直催促我的工作进度，而是准允我先忙完求职后再去作研究，我也终于不负众望，成功找到了一份较为不错的工作。同样，这也离不开田野老师的帮助。在论文撰写期间，田老师也在百忙之中一次次地给我提出建议，指导我如何采集数据集，完善模型，润色论文。古人云：“仰之弥高，钻之弥坚”，越是钻研越觉得自己所掌握的知识方恨少，在强场激光技术与机器学习方面的研究仍需进一步地积累与沉淀，方可提升自己的能力水平。古人云“学贵得师”，希望在此对田老师表示我本人最由衷的感谢！同时感谢实验室各位师兄师姐与同门的帮助，没有他们的帮助，本课题很难顺利完成。感谢父母在我学习遇到困难时的安慰和关爱。最后，感谢母校中国科学技术大学与上海光机所对我三年来的培养，也感谢读研期间教授过我课程的所有老师，令我学习到了很多知识，丰富了我。

2024 年 3 月

个 人 简 历

2017.9.1-2021.7.30 华南理工大学 计算机科学与工程学院 计算机科学与技术

2021.9.1-2022.6.30 中国科学技术大学 物理学院 电子信息

2022.9.1- 中国科学院上海光学与精密机械研究所 强场激光国家重点实验室
(联合培养)

在读期间发表的学术论文与取得的其他研究成果

已发表论文:

- [1] 刘哲生, 张冬冬, 李洪阳, 等. 基于高斯过程回归的线性激光束指向稳定优化[J]. 应用光学, 2023, 44(06): 1265-1272.

(建议按照发表时间由近及远顺序)