

融合Hermite插值与PINN的空间电磁捕获刚体动力学建模与预测

郑贤彬¹, 杨新海², 余铭初³, 龚培昊¹, 唐 宋^{1*}

¹上海理工大学健康科学与工程学院, 上海

²上海宇航系统工程研究所, 上海

³上海电机学院电气学院, 上海

收稿日期: 2026年6月29日; 录用日期: 2026年7月22日; 发布日期: 2026年7月29日

摘 要

空间电磁捕获过程中刚体运动状态受到电磁场、质量参数及初始条件等多因素耦合作用影响, 其动力学响应具有显著的非线性特征。传统物理信息神经网络通常利用单一网络直接学习完整动力学映射关系, 不仅需要拟合系统中的平滑变化趋势, 还需刻画电磁吸附阶段的局部强非线性行为, 导致模型训练复杂度较高, 并限制了预测精度的进一步提升。针对上述问题, 本文提出一种融合物理约束插值与PINN的协同预测方法。首先, 根据空间电磁捕获动力学响应中普遍存在的趋势项与非线性扰动项特征, 将目标状态分解为线性趋势部分和非线性残差部分; 随后利用Hermite插值构建动力学响应的连续趋势项预测模型, 实现目标轨迹的基线估计; 在此基础上, 引入PINN学习由电磁耦合作用、姿态变化及动力学约束引起的非线性残差项, 并通过牛顿-欧拉方程构建物理约束损失函数, 实现非线性动力学行为的精确刻画; 最终将插值预测结果与PINN残差输出进行融合, 获得目标状态的高精度预测结果。

关键词

空间电磁捕获, 物理信息神经网络, Hermite插值, 残差学习, 刚体动力学预测

Rigid-Body Dynamics Modeling and Prediction for Space Electromagnetic Capture via Hermite Interpolation and Physics-Informed Neural Networks

Xianbin Zheng¹, Xinhai Yang², Mingchu Yu³, Peihao Gong¹, Song Tang^{1*}

¹School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai

*通讯作者。

文章引用: 郑贤彬, 杨新海, 余铭初, 龚培昊, 唐宋. 融合 Hermite 插值与 PINN 的空间电磁捕获刚体动力学建模与预测[J]. 建模与仿真, 2026, 15(7): 131-140. DOI: 10.12677/mos.2026.157114

²Shanghai Aerospace Systems Engineering Research Institute, Shanghai³School of Electrical Engineering, Shanghai Dianji University, Shanghai

Received: June 29, 2026; accepted: July 22, 2026; published: July 29, 2026

Abstract

The dynamic response of rigid bodies during space electromagnetic capture is governed by the coupling effects of electromagnetic fields, mass properties, and initial operating conditions, resulting in highly nonlinear motion characteristics. Conventional Physics-Informed Neural Networks typically employ a single neural network to learn the complete dynamic mapping, requiring the model to simultaneously capture both smooth trend behaviors and strong nonlinear responses occurring during the electromagnetic attraction process. Such a learning paradigm increases training complexity and limits predictive performance. To address this issue, this paper proposes a collaborative prediction framework that integrates physics-constrained interpolation with PINN. The proposed method decomposes the dynamic response into a linear trend component and a nonlinear residual component. First, a Hermite interpolation model is employed to reconstruct the continuous trend term of the motion trajectory and provide a baseline prediction. Subsequently, a PINN is introduced to learn the nonlinear residual dynamics induced by electromagnetic coupling effects, attitude variations, and rigid-body dynamic interactions. Newton-Euler equations are incorporated into the loss function to ensure physical consistency of the residual prediction. The final dynamic state is obtained by fusing the interpolated trend prediction with the nonlinear residual estimated by the PINN.

Keywords

Space Electromagnetic Capture, Physics-Informed Neural Network, Hermite Interpolation, Residual Learning, Rigid-Body Dynamics Prediction

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>

Open Access

1. 引言

随着在轨服务(On-Orbit Servicing, OOS)、失效航天器维护以及空间碎片主动清除等任务需求的快速增长,空间目标捕获技术已成为航天工程领域的重要研究方向。作为一种典型的非接触式捕获方案,电磁捕获技术利用磁场作用实现目标吸附与姿态调控,具有结构简单、可重复使用以及对目标损伤小等优点,在空间机器人自主捕获和在轨操作任务中展现出广阔的应用前景。然而,在实际捕获过程中,目标刚体运动同时受到电磁场分布、质量特性、初始速度及空间相对位置等因素影响,其动力学演化过程呈现明显的非线性、多变量耦合和时变特征。如何准确预测目标在捕获过程中的运动轨迹及状态变化规律,是实现轨迹规划、姿态控制和自主决策的重要基础。

目前,针对空间电磁捕获过程的动力学研究主要依赖多物理场联合仿真方法。通过将电磁场求解器与多体动力学求解器进行耦合,可以较为准确地获得目标在不同工况条件下的位置、速度、姿态及角速度等状态响应。典型方法通常采用 Ansys Maxwell 计算电磁场分布,并结合 Ansys Motion 完成刚体动力学分析。尽管此类方法能够较好地反映电磁场与动力学系统之间的耦合作用机制,但随着工况参数维度

增加, 仿真计算成本显著提高。当需要进行大量参数分析、在线轨迹预测或实时控制时, 传统数值仿真方法往往难以满足效率要求。近年来, 数据驱动建模方法为复杂动力学系统预测提供了新的解决思路。多层感知机(MLP)、长短期记忆网络(LSTM)等深度学习模型能够通过学习历史样本中的统计规律建立输入与输出之间的映射关系, 在轨迹预测、系统辨识以及状态估计等领域取得了广泛应用。然而, 这类方法主要依赖数据分布特征进行学习, 缺乏对系统物理规律的显式约束。当训练样本覆盖范围有限或测试工况偏离训练分布时, 模型预测结果容易出现物理不一致和泛化能力下降等问题。

为了增强预测模型的物理可信度, 物理信息神经网络(Physics-Informed Neural Network, PINN)通过将控制方程嵌入神经网络训练过程, 实现了数据驱动学习与机理建模的统一。借助自动微分技术, PINN 能够直接计算状态变量导数, 并利用动力学方程残差约束模型输出, 从而提高预测结果的物理一致性。在流体力学、热传导、结构振动以及轨迹优化等领域, PINN 均表现出良好的应用效果。对于空间电磁捕获[1]问题, PINN 同样能够通过引入牛顿-欧拉动力学方程和电磁作用约束[2], 提高复杂动力学响应预测精度。

然而, 现有 PINN 方法大多采用单一网络直接学习完整动力学映射关系[3], 即同时拟合系统中的平滑变化趋势和局部强非线性响应。对于空间电磁捕获过程而言, 目标运动状态通常包含两类不同性质的信息。一类是由质量、电流、初始速度等参数决定的整体变化趋势, 其演化过程相对平滑且连续; 另一类则来源于电磁力快速增长、姿态耦合以及接触前后动力学突变等因素所产生的局部非线性响应。由于两类信息具有不同的尺度特征和变化规律, 当统一交由同一网络学习时, 模型需要同时兼顾全局趋势拟合与局部非线性表征, 不仅增加了训练难度, 也容易导致预测误差在强非线性区域累积。

从系统辨识和信号分解角度来看, 复杂动力学响应往往可以表示为趋势项与残差项的叠加。其中趋势项反映系统的整体演化规律, 而残差项则刻画偏离趋势的局部非线性特征。如果能够利用插值方法先建立动力学响应中的连续趋势模型, 再通过 PINN 针对非线性残差部分进行学习, 则有望降低模型学习难度, 并充分发挥插值方法在平滑趋势重构方面以及 PINN 在非线性动力学建模方面的优势。

基于上述分析, 本文提出一种融合物理约束插值与 PINN 的空间电磁捕获刚体动力学协同预测方法。该方法首先利用 Hermite 插值构建目标运动状态的连续趋势预测模型, 获得动力学响应中的基线估计; 随后将真实动力学响应与趋势预测之间的差异定义为非线性残差, 并利用 PINN 结合牛顿-欧拉动力学约束对残差部分进行学习; 最终通过趋势项与残差项融合重构获得目标状态的高精度预测结果。与传统 PINN 直接学习完整动力学映射不同, 所提出方法通过将趋势建模与非线性建模任务进行分离, 实现了动力学响应的分层学习, 从而提高模型在复杂工况下的预测精度与物理一致性。

本文的主要贡献如下:

- (1) 针对空间电磁捕获动力学响应中同时存在平滑趋势和强非线性特征的问题, 提出一种基于趋势项与残差项分解的协同预测建模思想。
- (2) 构建 Hermite 插值与 PINN 融合预测框架, 利用插值模型学习动力学响应中的连续趋势信息, 利用 PINN 学习非线性残差及物理约束特征, 实现优势互补。
- (3) 基于 Ansys Motion 与 Maxwell 联合仿真数据开展实验验证, 并与 MLP、LSTM 以及传统 PINN 模型进行对比, 结果表明所提出方法在预测精度、非线性特征表征能力和物理一致性方面均具有明显优势。

2. 背景与理论基础

2.1. 空间电磁捕获动力学特性

空间电磁捕获是一种利用电磁场作用实现目标吸附与控制的非接触式捕获方式。与传统机械接触捕

获相比,电磁捕获过程中不存在刚性碰撞,其动力学行为主要由电磁场与目标刚体之间的相互作用决定。因此,目标运动状态不仅受到自身质量、惯性特性以及初始运动条件影响,同时还与线圈电流强度、磁场分布以及相对位置变化密切相关,表现出显著的多变量耦合特征。空间电磁捕获过程涉及复杂的多场耦合动力学行为[4]。为精确描述目标的运动演化,本研究在惯性坐标系 $\mathcal{F}_I$ 下建立目标的刚体动力学模型[5]。设目标质心位置矢量为 $\mathbf{r} \in \mathbb{R}^3$, 在体坐标系 $\mathcal{F}_B$ 下的角速度矢量为 $\boldsymbol{\omega} \in \mathbb{R}^3$, 则目标的平动与转动动力学方程可统一表述为:

$$m\ddot{\mathbf{r}} = \mathbf{F}_{em}(\mathbf{I}, d) + \mathbf{F}_{ext} \quad (1)$$

其中, m 为目标质量, $\mathbf{F}_{em}$ 为电磁吸附力, 其大小与线圈励磁电流 I 及目标与捕获端之间的相对距离 d 呈强非线性耦合关系; $\mathbf{F}_{ext}$ 为空间环境摄动力(如残余大气阻力与光压)。

$$\mathbf{I}\dot{\boldsymbol{\omega}} + \boldsymbol{\omega} \times (\mathbf{I}\boldsymbol{\omega}) = \mathbf{M}_{em}(\mathbf{I}, d) \quad (2)$$

其中, $\mathbf{I} \in \mathbb{R}^{3 \times 3}$ 为刚体转动惯量张量, $\mathbf{M}_{em}$ 为由电磁吸附作用产生的附加力矩。上述动力学方程组确立了目标状态轨迹 $\mathbf{y}(t) = [\mathbf{r}(t), \dot{\mathbf{r}}(t), \mathbf{q}(t), \boldsymbol{\omega}(t)]^T$ 的演化准则。在本文所构建的协同预测框架中, 这些方程不仅是描述捕获过程的物理基础, 更构成了后续物理信息神经网络(PINN)训练中的核心监督算子。定义动力学残差算子 $\mathcal{R}$ 为:

$$\mathcal{R}(\mathbf{y}; \theta) = m\ddot{\mathbf{r}} - \mathbf{F}_{em} - \mathbf{F}_{ext} \quad (3)$$

在后续章节中, 该残差项将被嵌入至神经网络的损失函数中, 通过强制神经网络输出满足动力学平衡关系, 从而确保在参数外推工况下, 模型的预测结果始终处于物理合理的流形空间内, 避免出现传统深度学习方法中常见的“轨迹发散”或“物理违背”现象。

这种非线性关系导致目标运动状态在吸附末端阶段容易出现速度突增、加速度峰值以及姿态快速调整等现象, 使得动力学响应呈现明显的局部非线性特征。另一方面, 从整体运动轨迹来看, 在给定工况条件下, 目标位置、速度以及姿态变化仍然保持连续演化规律, 其主导运动趋势受到质量、初始速度和电流参数的共同影响。因此, 空间电磁捕获动力学响应同时包含两类不同尺度的信息: 一类是反映系统整体运动规律的平滑趋势特征; 另一类是由电磁耦合效应引起的局部非线性响应特征。前者决定了轨迹演化的总体形态, 后者则决定了动力学细节变化和局部突变行为。因此, 从动力学建模角度出发, 若能够对系统响应中的整体趋势和非线性扰动进行分离建模, 则有望降低模型学习复杂度, 并提高对复杂动力学行为的预测能力。基于这一认识, 下一节将从响应分解角度分析空间电磁捕获动力学中的趋势项与非线性残差项特征, 为后续协同预测模型的构建提供理论基础。

2.2. 现有动力学预测方法及其局限性

近年来, 数据驱动建模方法为复杂动力学系统的快速预测提供了新的技术途径。多层感知机(Multilayer Perceptron, MLP)和长短期记忆网络(Long Short-Term Memory, LSTM)等深度学习模型能够通过训练样本学习工况参数、时间变量与动力学状态之间的非线性映射, 在轨迹预测、状态估计和系统辨识等任务中得到了广泛应用。然而, 此类方法主要依据样本中的统计关联进行训练, 缺乏对系统控制方程和物理边界条件的显式约束。当训练样本数量有限, 或测试工况偏离训练数据分布时, 模型预测结果可能出现动力学不一致或泛化性能下降等问题。为提高数据驱动模型的物理可信度, 物理信息神经网络(Physics-Informed Neural Network, PINN)将系统控制方程引入神经网络训练过程。PINN 利用自动微分计算网络输出关于时间或空间变量的导数, 并根据控制方程构造物理残差损失, 从而实现数据监督与物理机理约束的联合建模。对于空间电磁捕获问题, 可以将牛顿-欧拉动力学方程、姿态运动学关系以及相

关电磁作用约束嵌入网络训练过程,以提高预测状态的物理一致性。

尽管如此,传统 PINN 在空间电磁捕获动力学预测中仍面临一定局限。空间电磁捕获过程受到目标质量、惯量、线圈励磁电流、初始相对速度及位置偏移等多种因素共同影响。目标状态在大部分运动阶段表现为连续、平滑的演化过程,而在目标逐渐进入强电磁作用区域后,电磁力和电磁力矩的非线性增强可能引起速度快速变化、加速度峰值及姿态快速调整等局部复杂响应。因此,完整动力学状态同时包含变化尺度和演化特征不同的信息。

传统 PINN 通常采用单一网络直接建立工况参数、时间变量与完整动力学状态之间的映射关系。在该建模方式下,网络需要同时学习相对平滑的整体演化规律和捕获末端阶段的局部强非线性响应。由于两类特征在变化幅度、频率范围和学习难度方面存在差异,统一建模可能增加网络的优化难度,并使模型更倾向于拟合占主导比例的平滑状态变化,从而影响对局部复杂动力学行为的刻画能力。尤其在电磁吸附末端阶段,局部预测误差可能随非线性作用增强而增大。

因此,如何在保持动力学方程约束的基础上,降低模型同时学习不同尺度动力学特征的难度,并提高其对局部强非线性响应的表征能力,是空间电磁捕获动力学预测需要进一步解决的问题。针对上述问题,下一章将提出一种融合 Hermite 插值与物理信息神经网络的协同预测方法。

2.3. Hermite 插值理论基础

在动力学系统的替代建模与轨迹预测中,插值方法是将离散仿真或观测数据转化为连续时间域函数的重要数学工具。传统的线性插值虽然计算简便,但仅能保证函数值在节点处的连续性(C^0 连续),其一阶导数在节点处往往发生跳变,无法准确反映刚体动力学系统中的连续速度变化信息;高阶多项式插值(如多项式 Lagrange 插值)虽然能提高整体拟合精度,但在节点数量较多或步长不均匀时,极易在边界处触发龙格现象,导致轨迹出现剧烈震荡,严重破坏局部稳定性。相比之下,分段三次 Hermite [6]插值(Cubic Hermite Interpolation)在构造插值多项式时,不仅利用了节点处的状态变量值,还显式引入了节点处的一阶导数(即状态变化率)信息。这种特性使其能够在保证轨迹曲线连续的前提下,确保一阶导数(如速度、角速度)在时间节点处的平滑过渡,因而更加契合刚体动力学响应中平滑演化趋势的物理特性。从刚体动力学的角度审视,空间电磁捕获目标的运动轨迹(包含位置、速度、姿态四元数及角速度等)在宏观尺度上是由系统惯性、初始运动工况以及平均电磁效应主导的,具有较好的低频连续性和光滑性。利用 Hermite 插值理论能够高效地重构出目标运动状态的宏观变化基线。然而,由于 Hermite 插值本质上基于多项式逼近和局部平滑性假设,它难以对空间电磁捕获末端阶段由强非线性电磁力、姿态快速耦合所产生的高频动态突变(如速度骤增、加速度峰值和局部姿态剧烈调整)进行精准刻画。这种数学插值模型与真实物理响应之间的不可避免的理论偏差,构成了动力学演化中的非线性残差,为后文开展针对性的机理约束与残差补偿提供了明确的学习对象。

3. 协同预测框架设计

针对传统 PINN 需要同时学习动力学响应中的整体趋势特征与局部非线性特征[7],导致模型训练复杂度较高以及非线性区域预测精度受限的问题,本文提出一种融合 Hermite 插值与物理信息神经网络(PINN)的协同预测框架。该框架采用“趋势预测-残差学习-结果融合”的分层建模思想,将复杂动力学响应分解为趋势项和非线性残差项分别进行建模。空间电磁捕获刚体动力学响应可表示为系统整体运动趋势,以及动力学非线性因素引起的残差项。如图 1 所示,本文提出的协同预测框架主要由 Hermite 趋势预测模块、PINN 残差学习组成。首先利用 Ansys Motion 与 Maxwell 联合仿真平台获取目标在不同工况条件下的位置、速度、姿态和角速度数据,并完成数据归一化处理。随后利用 Hermite 插值算法对离散

轨迹节点进行连续重构,获得目标动力学响应的趋势预测结果。然后将时间变量及工况参数作为 PINN 输入,通过自动微分计算动力学导数信息,并结合牛顿-欧拉动力学方程构建物理约束,实现非线性残差项学习。最终,将 Hermite 插值预测结果与 PINN 预测残差进行融合,得到未知质量工况下的运动特性。与传统 PINN 直接学习完整动力学响应相比,所提出框架将易学习的趋势部分与复杂非线性部分进行解耦。Hermite 插值负责描述轨迹整体变化趋势, PINN 负责补偿复杂动力学残差,从而充分发挥两类方法的优势,提高模型预测精度与物理一致性。




Figure 1. Framework of the proposed hybrid interpolation-PINN collaborative prediction method

图 1. 协同预测流程图

3.1. 电磁捕获动力学的趋势项与非线性项分解

空间电磁捕获过程中,目标刚体的运动状态受到惯性效应、电磁作用以及姿态耦合等多种因素共同影响,其动力学响应通常表现为连续演化趋势与局部非线性扰动并存的特征。从系统辨识角度来看,这种复杂响应并非完全随机变化,而是由整体运动趋势和非线性偏差共同构成。因此,对动力学响应进行合理分解有助于降低模型学习复杂度,并提高预测模型对不同特征尺度信息的表达能力。设目标在捕获过程中的状态响应表示为:

$$y(t) = [r(t), v(t), q(t), \omega(t)] \quad (4)$$

其中, $r(t)$ 、 $v(t)$ 、 $q(t)$ 和 $\omega(t)$ 分别表示位置、速度、姿态四元数以及角速度随时间的变化过程。对于大多数空间电磁捕获轨迹而言,状态变量总体上呈现连续变化趋势。例如,在自由接近阶段,位置和速度变化主要由初始运动条件决定;在电磁作用逐渐增强阶段,轨迹整体仍保持平滑演化特征。

因此,动力学响应中存在一个能够描述系统总体变化规律的趋势项,可记为: $y_L(t)$ 趋势项主要反映系统的低频变化特征和整体运动规律,其变化过程连续且具有较好的可预测性。然而,当目标进入强电磁场作用区域后,电磁力的快速增长以及姿态耦合作用会导致系统产生明显的局部非线性响应。例如速度峰值、加速度突变以及姿态快速调整等现象均表现为偏离整体趋势的动态行为。对于这部分复杂动力学特征,可定义非线性残差项: $y_{NL}(t)$ 用于描述实际动力学响应相对于趋势项的偏离程度。因此,目标状态响应可以表示为: $y(t) = y_L(t) + y_{NL}(t)$ 该表达式表明,空间电磁捕获动力学响应本质上是趋势信息与非线性信息共同作用的结果。其中趋势项决定系统运动轨迹的整体形态,而非线性残差项则刻画电磁耦合效应引起的局部动态变化。为了进一步说明两类特征的差异,可将动力学响应视为不同频率成分的叠加。趋势项主要包含低频连续变化信息,其变化速率相对平缓;而非线性残差项则集中反映高频动态特征,其幅值虽然通常小于趋势项,但对预测精度具有决定性影响。尤其是在电磁吸

附末端阶段,残差项往往呈现快速增长趋势,并成为影响模型预测误差的主要来源。从建模角度分析,如果采用单一模型直接学习完整动力学响应,则模型需要同时拟合低频趋势信息与高频非线性信息。这不仅增加了学习难度,还可能导致模型容量被大量用于拟合易学习的趋势部分,从而削弱对关键非线性特征的表达能力。相反,若能够首先建立趋势项预测模型获得动力学响应的基线估计,再针对残差部分进行专门建模,则能够有效降低学习复杂度,并提高模型对复杂动力学行为的刻画能力。基于上述分析,本文采用分层建模思想对动力学响应进行预测。首先利用 Hermite 插值对趋势项 $y_L(t)$ 进行连续重构,获得目标运动状态的基线预测结果;随后利用物理信息神经网络对非线性残差项 $y_{NL}(t)$ 进行学习,并通过牛顿-欧拉动力学方程引入物理约束;最终将两部分预测结果进行融合,得到完整动力学响应: $y(t) = y_L(t) + y_{NL}(t)$ 该分解策略不仅能够充分发挥插值方法在平滑趋势重构方面的优势,还能够利用 PINN 对复杂非线性动力学行为进行高精度建模,为后续协同预测框架的构建提供理论依据。

3.2. 插值约束趋势预测

在空间电磁捕获过程中,目标的状态轨迹由多维度工况参数决定,并表现出明显的阶段性演化特征。针对传统神经网络直接学习完整映射时面临的训练难度高与非线性区域误差积聚问题,本文构建了物理约束插值趋势预测模块,旨在从动力学响应中剥离并重构系统的宏观演化趋势。

空间电磁捕获动力学响应可以表示为趋势项与非线性残差项的叠加。其中,趋势项反映目标运动状态的整体演化规律,主要由系统惯性特性、初始运动条件以及电磁作用的平均效应共同决定。相较于非线性残差项,趋势项通常具有较好的连续性和光滑性,其状态变量及变化率在时间域内呈现缓慢变化特征。因此,对于趋势项的建模,更关注轨迹整体形态的连续重构,而非局部非线性细节的精确刻画。在轨迹预测问题中,插值方法能够利用已知状态点之间的关联关系构建连续函数,从而获得未知时刻的状态估计结果。常见的线性插值虽然计算简单,但仅保证函数值连续,难以准确描述动力学轨迹中的速度变化信息;高阶多项式插值虽然能够提高拟合精度,但容易出现振荡现象,并降低局部稳定性。相比之下,Hermite 插值不仅利用状态变量本身,还引入节点处的一阶导数信息,能够同时保证轨迹和速度的连续性,因此更适合描述刚体动力学响应中的平滑趋势特征。设在时间区间 $[t_i, t_{i+1}]$ 内已知目标状态 $y_i = y(t_i)$ 和 $y_{i+1} = y(t_{i+1})$, 以及对应的一阶导数 y'_i 和 y'_{i+1} , 则 Hermite 插值函数可表示为:

$$H(t) = h_{00}(s)y^*(t_j) + h_{10}(s)\Delta t \dot{y}^*(t_j) + h_{01}(s)y^*(t_{j+1}) + h_{11}(s)\Delta t \dot{y}^*(t_{j+1}) \quad (5)$$

其中 $\Delta t = t_{i+1} - t_i$, $s = (t - t_i)/\Delta t$ 。为归一化时间变量对应的 Hermite 基函数分别为: $h_{00}(s) = 2s^3 - 3s^2 + 1$, $h_{10}(s) = s^3 - 2s^2 + s$, $h_{01}(s) = -2s^3 + 3s^2$, $h_{11}(s) = s^3 - s^2$ 。通过上述基函数构造的插值曲线不仅满足 $H(t_i) = y_i$, $H(t_{i+1}) = y_{i+1}$ 。同时满足 $\dot{H}(t_i) = \dot{y}_i$, $\dot{H}(t_{i+1}) = \dot{y}_{i+1}$

从而保证轨迹状态及其变化率在节点处保持连续,同时保证一阶导数连续,从而能够较好地恢复轨迹整体演化规律。对于空间电磁捕获问题而言,位置、速度以及姿态等状态变量在大部分运动阶段均呈现连续变化趋势,因此 Hermite 插值能够较好地恢复轨迹整体演化规律。设通过 Hermite 插值获得的趋势预测结果为 $\hat{y}_L(t)$, 则其可以看作目标动力学响应的基线估计,用于描述系统的低频变化特征和整体运动趋势。然而,由于 Hermite 插值本质上依赖于邻域状态点之间的连续性假设,其预测结果难以准确刻画电磁吸附阶段产生的速度突变、加速度峰值以及姿态快速调整等强非线性动力学行为。因此,趋势项预测结果与真实响应之间仍然存在一定偏差,该误差项本质上反映了动力学响应中的非线性残差特征,也是后续 PINN 需要重点学习的对象。因此,将 Hermite 插值作为趋势预测模块,负责提取动力学响应中的连续变化规律;同时利用 PINN 对趋势预测误差进行进一步建模,从而实现复杂动力学响应的高精度重构。

3.3. PINN 非线性残差学习

Hermite 插值能够有效重构空间电磁捕获动力学响应中的整体变化趋势, 并获得趋势预测结果 $\hat{y}_L(t)$ 。然而, 由于电磁力的非线性增长、姿态耦合效应以及复杂动力学约束的共同作用, 实际动力学响应与趋势预测结果之间仍然存在明显偏差。因此, 需要进一步建立非线性残差模型, 对 Hermite 插值无法表征的复杂动力学行为进行补偿。设真实动力学响应为 $y(t)$, Hermite 插值预测结果为 $\hat{y}_L(t)$, 则非线性残差定义为:

$$r(t) = y(t) - \hat{y}_L(t) \quad (6)$$

其中, $r(t)$ 反映了目标动力学响应偏离整体趋势的部分, 主要包含电磁吸附末端阶段的速度突变、加速度峰值、姿态快速调整以及刚体动力学耦合效应等复杂非线性特征。传统神经网络虽然能够通过数据拟合学习残差项, 但其训练过程完全依赖样本数据, 缺乏对动力学规律的显式约束。当测试工况超出训练样本分布范围时, 模型容易产生不符合物理规律的预测结果。为提高残差预测的物理可信度, 本文引入物理信息神经网络(Physics-Informed Neural Network, PINN)对非线性残差进行建模。PINN 通过将动力学控制方程嵌入神经网络训练过程, 实现数据驱动学习与物理约束建模的统一。设 PINN 网络表示为:

$$\hat{r}(t) = N_\theta(t, \mu) \quad (7)$$

其中, t 表示时间变量, μ 表示工况参数向量, θ 表示网络参数, $\hat{r}(t)$ 表示网络预测的非线性残差。在训练过程中, PINN 利用自动微分技术计算残差预测结果的一阶和二阶导数, 并构建动力学残差约束。与直接拟合动力学响应不同, PINN 的训练目标被显式约束在牛顿-欧拉方程定义的流形空间内有平动动力学残差:

$$\mathcal{R}_i(\theta) = m\ddot{\mathbf{r}} - (\mathbf{F}_{em} + \mathbf{F}_{ext}) \quad (8)$$

转动动力学残差: $\mathcal{R}_r(\theta) = \mathbf{I}\dot{\hat{\omega}} + \hat{\omega} \times (\mathbf{I}\hat{\omega}) - (\mathbf{M}_{em} + \mathbf{M}_{ext})$ 其中 $\hat{\mathbf{r}} = \hat{\mathbf{r}}_L + \hat{\mathbf{r}}_{NN}$, 所有微分项均通过深度学习框架的自动微分高效计算。通过在损失函数中引入上述残差算子, PINN 不仅能够最小化数据拟合误差, 还能确保模型学习到的非线性修正量 $\hat{\mathbf{r}}_{NN}$ 在物理层面上满足刚体运动规律[8]。最终, 通过 $\hat{\mathbf{y}}(t) = \hat{\mathbf{y}}_L(t) + N_\theta(t, \mu)$ 实现动力学响应的高精度重构。该解耦建模策略降低了网络的全局学习压力, 使得模型能够聚焦于电磁耦合产生的局部高频复杂特征。

3.3.1. 网络架构设计

PINN 采用全连接深度神经网络结构 $N_\theta(t, \mu)$, 旨在建立工况参数 $\mu = [m, v_0, I, \delta]^T$ 与时间变量 t 到残差项 $\hat{r}(t)$ 的非线性映射。网络输入层维度为 5, 隐藏层设置为 4 层, 每层包含 64 个神经元, 并采用双曲正切函数(tanh)作为激活函数以满足导数连续性要求。网络最终输出为残差项的修正向量 $\hat{\mathbf{r}}(t) \in \mathbb{R}^{13}$, 涵盖位置、速度、姿态四元数及角速度的残差分量。

3.3.2. 物理约束损失函数

为了保证残差预测的物理一致性, PINN 的损失函数设计综合考虑了数据监督项与动力学物理残差项。总损失函数 $\mathcal{L}_{total}$ 定义如下: $\mathcal{L}_{total} = \lambda_D \mathcal{L}_{data} + \lambda_p \mathcal{L}_{phys} + \lambda_{IC} \mathcal{L}_{IC} + \lambda_{reg} \mathcal{L}_{reg}$, 其中, 数据一致性损失 $\mathcal{L}_{data}$ 度量神经网络输出与仿真残差数据的均方误差:

$$\mathcal{L}_{data} = \frac{1}{N_{data}} \sum_{i=1}^{N_{data}} \left\| \hat{\mathbf{r}}(t_i, \mu_i; \theta) - (\mathbf{y}_{true}(t_i, \mu_i) - \hat{\mathbf{y}}_L(t_i, \mu_i)) \right\|^2 \quad (9)$$

物理残差约束 $\mathcal{L}_{phys}$ 通过自动微分计算网络输出的一阶导数, 并代入牛顿-欧拉动力学方程。令 $\hat{\mathbf{y}}(t) = \hat{\mathbf{y}}_L(t) + \hat{\mathbf{r}}(t)$, 则物理残差项为:

$$\mathcal{L}_{phys} = \frac{1}{N_{phys}} \sum_{j=1}^{N_{phys}} \left(\left\| m\ddot{\mathbf{r}}_r - (\mathbf{F}_{em} - m\ddot{\mathbf{y}}_L) \right\|^2 + \left\| \mathbf{I}\dot{\boldsymbol{\omega}}_r + \boldsymbol{\omega} \times (\mathbf{I}\boldsymbol{\omega}) - (\mathbf{M}_{em} - \mathbf{M}_{ext}) \right\|^2 \right) \quad (10)$$

3.3.3. 残差补偿与状态重构

训练完成后，对于任意输入工况 $\boldsymbol{\mu}^*$ 及时间 t ，刚体的最终动力学预测结果 $\hat{\mathbf{y}}(t)$ 通过残差融合公式进行实时重构： $\hat{\mathbf{y}}(t, \boldsymbol{\mu}^*) = \hat{\mathbf{y}}_L(t, \boldsymbol{\mu}^*) + N_\theta(t, \boldsymbol{\mu}^*)$ 。由于插值模块已承担了工况参数域的全局泛化任务，PINN 模块只需聚焦于捕获电磁耦合引起的局部高频非线性变化。这种分层预测机制显著降低了网络的学习方差，在强非线性动力学演化阶段展现出更优的拟合能力与更快的收敛速度。

4. 实验与结果分析

为了验证本文提出的“插值趋势估计与 PINN 残差学习”协同预测框架在空间电磁捕获动力学中的有效性，实验基于 Ansys Motion 与 Maxwell 联合仿真平台构建了包含 1200 组工况的数据集。该数据集涵盖了目标质量 ($m \in [m_{\min}, m_{\max}]$)、线圈励磁电流 ($I \in [I_{\min}, I_{\max}]$)、初始相对速度 ($v_0 \in [v_{\min}, v_{\max}]$) 及空间位置偏移 ($\delta \in [\delta_{\min}, \delta_{\max}]$) 等关键变量的组合，能够充分覆盖电磁吸附过程中的平稳接近、电磁力增强及末端捕获三个阶段。

4.1. 计算环境与训练策略

所有实验均在配置有 NVIDIA RTX 4080 GPU 的工作站上完成，基于 PyTorch 深度学习框架实现。网络优化器采用 Adam 算法，初始学习率设定为 1×10^{-3} ，并配合指数衰减策略(衰减率为 0.9，每 1000 个 Epoch 执行一次)，以确保训练后期参数的稳定性。针对协同预测框架，物理约束项权重 λ_p 与数据损失项权重 λ_d 分别设定为 0.1 和 1，以平衡物理一致性与数据拟合精度。所有模型均训练 10,000 个 Epoch，直至损失函数达到稳定收敛状态。

4.2. 不同模型对比

本文所提协同框架采用两阶段策略：第一阶段在参数空间中通过三次 Hermite 物理约束插值建立工况参数与动力学响应之间的连续映射关系，并结合动力学残差与电磁单调性约束筛选高可信插值样本，从而为未见工况提供合理的状态先验；第二阶段将插值先验信息连同时间变量及工况参数共同输入 PINN，利用自动微分构建牛顿-欧拉方程与电磁力学残差，对时间维度上的状态演化过程进行物理一致性修正。对比模型包括：MLP 与 LSTM 作为纯数据驱动基准，传统 PINN (未引入插值先验，由单一网络同时学习参数空间与时间动力学) 作为物理约束基准，以验证插值先验对协同框架预测性能的贡献。表 1 列出了各模型在位置、线速度、姿态(四元数)及角速度上的均方根误差(RMSE)与平均绝对误差(MAE)。

Table 1. Comparison data of different model experiments

表 1. 不同模型实验对比数据

模型	位置 RMSE (mm)	速度 RMSE (mm/s)	姿态 MAE	角速度 RMSE (rad/s)
MLP	0.098	0.104	0.028	0.072
LSTM	0.076	0.086	0.012	0.045
PINN	0.032	0.025	0.004	0.018
Interp + PINN	0.019	0.014	0.002	0.011

5. 结论

针对空间电磁捕获过程中刚体动力学预测面临的强非线性、参数耦合及多阶段演化难题，本文提出

了一种基于插值趋势估计与 PINN 残差学习的协同预测方法。该方法将复杂的动力学映射解耦为宏观趋势预测与微观非线性残差修正两个层面，主要结论如下：

1) 实现了动力学映射的精准解耦：通过 Hermite 插值构建了空间电磁捕获过程的基线演化趋势，有效地吸收了动力学系统中的低频演化特征；在此基础上，利用 PINN 专门攻克电磁吸附末端由剧烈力矩和非线性电磁力引起的高频残差项，显著降低了神经网络直接拟合全轨迹的流形学习难度。

2) 强化了跨工况泛化能力：该协同架构在跨质量、电流强度及初始偏移量等未见工况的外推实验中，表现出极佳的鲁棒性。插值模块为未知工况提供了可靠的物理先验，使模型在边界条件下仍能保持平稳的预测性能，为空间在轨服务任务中的轨迹规划与实时控制提供了高效的替代建模新思路。

基金项目

上海航天科技创新基金，项目编号 SAST2023-084。

参考文献

- [1] Zhang, Y.W., Yang, L., Zhu, Y., Huang, H. and Ao, H. (2014) Spacecraft Electromagnetic Docking: A Review on Dynamics and Control. *AIAA/AAS Astrodynamics Specialist Conference*, San Diego, 4-7 August 2014, AIAA 2014-4162. <https://doi.org/10.2514/6.2014-4162>
- [2] Varey, J., Ruprecht, J.D., Tierney, M. and Sullenberger, R. (2024) Physics-Informed Neural Networks for Satellite State Estimation. *2024 IEEE Aerospace Conference*, Big Sky, 2-9 March 2024, 1-8. <https://doi.org/10.1109/aero58975.2024.10521414>
- [3] 郑贤彬, 余铭初, 龚培昊, 唐宋. 基于 PINN 的空间电磁捕获刚体动力学建模与预测[J]. 建模与仿真, 2026, 15(1): 33-40.
- [4] Shi, K., Sun, Z., Liu, C. and Ye, D. (2017) Dynamics Modeling and Simulation of Space Electromagnetic Docking for CubeSat. *2017 8th International Conference on Mechanical and Aerospace Engineering (ICMAE)*, Prague, 22-25 July 2017, 603-608. <https://doi.org/10.1109/icmae.2017.8038716>
- [5] Forbes, J.R. (2015) Fundamentals of Spacecraft Attitude Determination and Control [Bookshelf]. *IEEE Control Systems Magazine*, **35**, 56-58.
- [6] Cooley, M., Kirby, M., Zhe, S. and Shankar, V. (2025) HyResPINNs: A Hybrid Residual Physics-Informed Neural Network Architecture Designed to Balance Expressiveness and Trainability. *Transactions on Machine Learning Research*, **12**, 1-44. <https://openreview.net/pdf?id=et9WkjKqAw>
- [7] Wang, S., Teng, Y. and Perdikaris, P. (2021) Understanding and Mitigating Gradient Flow Pathologies in Physics-Informed Neural Networks. *SIAM Journal on Scientific Computing*, **43**, A3055-A3081. <https://doi.org/10.1137/20m1318043>
- [8] Kondo, K., Wu, Y., Kumar, V. and How, J.P. (2026) MIGHTY: Hermite Spline-Based Efficient Trajectory Planning. *IEEE Robotics and Automation Letters*, **11**, 6664-6671. <https://doi.org/10.1109/lra.2026.3681187>