

# 基于深度学习的航空制造机械系统自适应控制策略研究

张经瑞

中国商飞上海飞机制造有限公司, 上海 200436

**摘要:** 针对航空制造机械系统在复杂环境下存在的非线性、强耦合和扰动难以建模等问题, 本文提出一种基于深度学习的自适应控制策略。通过构建深度神经网络预测模型与增量学习机制, 实现系统状态的动态识别与控制参数的实时优化。仿真实验结果表明, 该方法在精度、鲁棒性与响应速度方面优于传统PID和LQR控制策略, 能够有效应对不确定工况。进一步结合工业现场应用, 分析了该控制器在PLC/嵌入式平台上的部署方案及其在典型制造流程中的适应性。研究表明, 该策略具备良好的工程实用性与推广前景。

**关键词:** 深度学习; 自适应控制; 航空制造; 智能系统; 扰动抑制

DOI:10.63887/jeti.2025.1.3.32

## 引言

随着航空工业的飞速发展和制造任务复杂度的不断提升, 航空制造机械系统作为高端装备制造的核心支撑, 其运行精度、响应速度与自适应能力成为衡量系统智能化水平的关键指标。传统控制方法如PID、模糊控制或经典自适应控制在某些特定环境下虽具有良好效果, 但在面对非线性强、系统动态复杂、环境扰动大及多变量耦合严重等航空制造工况时, 存在响应迟滞、控制精度不足和调参效率低等明显局限。这一现实推动了面向智能化、高可靠性控制策略的深入研究, 尤其是在航空制造过程中的焊接、钻孔、复合材料铺设、自动装配等典型子系统控制任务中, 提升其对动态变化和不确定性的感知与响应能力, 成为实现智能制造的重要突破口。

## 1 航空制造机械系统的建模与控制需求分析

### 1.1 航空制造机械系统组成及运行特性

航空制造机械系统包括多自由度数控机床臂、高精度加工平台、自动化传输装置、传感器网络和实时控制单元等多个子系统, 这些子系统在航空零部件的加工、装配、检测和搬运任务中协同工作, 形成一个高度复杂且自动化的制造体系<sup>[1]</sup>。与传统制造机械系统相比, 航空制造机械系统对系统响应时间、路径精度和设备稳定性提出更高要求, 系统运行特性表现为动态多变、结构多样、工况切换频繁。例如, 在自动钻铆系统中, 必须实时调整钻削速度与进给路径以应对不同材料厚度; 在复合材料铺放机器人中, 路径轨迹与材料张力的精准控制直接影响产品性能。控制设计必须兼顾高维性、多约束和多目标任务, 确保从底层驱动到高级规划的全流程协调<sup>[2]</sup>。

### 1.2 常见动态模型及控制变量特征

航空制造机械系统的动力学模型通常包括多刚体系统、非线性驱动机构、摩擦建模和外部扰动<sup>[3]</sup>。模型多采用非线性状

态空间或拉格朗日/牛顿-欧拉建模方法进行推导。常见控制变量包括位置、速度、加速度、电机转矩、电流输入以及压力、温度、振动等传感器反馈信息。这些变量高度相关且存在耦合性，需要精细建模与分层解耦控制。建模过程中还需考虑制造误差、装配偏差、传感器噪声等因素，导致模型的不确定性，传统线性模型无法全面描述系统运行规律。因此，建立能够捕捉非线性关系、具有泛化能力和实时更新的建模机制成为研究关键目标之一，这也为深度学习的引入提供了契机。

### 1.3 控制系统中的非线性、耦合性与扰动特性

航空制造机械系统广泛存在非线性因素，如电机驱动中的饱和与死区、机械臂运动中的柔顺性、气动系统中的压缩滞后等，导致传统控制策略在高精度任务中频繁失效<sup>[4]</sup>。机械结构复杂，各控制轴间存在动态耦合，单一控制通道无法独立运行，需设计全系统级联反馈控制器以消除内部干扰。外部扰动，如工件夹紧误差、材料硬度变化和电源波动等，可能引起控制精度下降或系统不稳定。传统控制策略虽能通过加设观测器或鲁棒项来缓解，但面对快速变化的扰动时，响应迟缓与泛化能力弱的缺陷更加突出。因此，提高控制系统对非线性、耦合与扰动的适应能力，是智能化航空制造系统的基础。

### 1.4 控制目标：高精度、抗干扰与自适应性需求

航空制造控制系统的最终目标包括高精度定位、高动态响应、强鲁棒性和良好的自适应性。高精度要求系统在动态轨迹跟踪或静态定位中，误差控制在微米级别，这对建模精度和控制器反馈调节能力提出极高要求<sup>[5]</sup>。抗干扰性要求系统能在环境

变化、外部扰动或设备参数波动下保持稳定，并维持控制精度。自适应性要求控制策略能根据系统变化动态调整参数，维持系统性能的最优状态。以上控制目标是相互关联的，因此，必须突破传统固定参数控制方法，构建基于深度学习的智能控制体系。

## 2 深度学习辅助自适应控制算法设计

### 2.1 控制器总体架构与系统耦合关系

由于航空制造机械系统具有多输入多输出、非线性和高耦合性，传统控制器难以保证系统在动态环境下的控制性能。因此，本研究构建了一个基于深度学习的自适应控制器架构，核心为任务导向的控制，通过对系统状态和环境输入的深度感知，实时调节控制律以适应不同工况。该架构包括数据采集与预处理层、状态估计与建模层、决策控制层及执行反馈层，模块间通过高频率信息交互实现动态耦合和反馈闭环。控制通道的相互影响通过深度特征融合机制处理，将多轴数据与扰动信息输入神经网络，从而生成最优控制策略。

### 2.2 控制策略核心模块划分

控制器设计可分为多个功能模块。深度神经网络建模预测子系统负责学习系统输入输出的非线性映射关系，利用端到端训练构建状态转移模型，预测未来系统响应。网络结构可选择多层感知机（MLP）、卷积神经网络（CNN）或循环神经网络（RNN），并结合时间序列处理捕捉动态演化规律。状态反馈与误差补偿机制实时采集执行误差，通过与目标轨迹的对比调整控制输入，优化系统稳定性与跟踪精度。

### 2.3 自适应调节机制设计

为提高系统在复杂环境中的自适应性，本文设计了一种基于增量学习的调节

机制，该机制通过在线采集运行数据动态调整神经网络参数，避免模型老化或迁移失效。与传统批量训练不同，增量学习兼顾实时性与泛化性，适用于多批次、小样本的数据场景。此机制通过误差驱动的学习率调整策略，抑制系统突变带来的冲击，提升系统响应能力和长期稳定性。

## 2.4 控制器参数优化算法

本文进一步引入强化学习和进化算法进行控制策略的最优参数配置。强化学习通过构建马尔可夫决策过程，利用策略梯度或 Q-learning 等方法不断优化控制策略，特别适用于环境变化频繁的制造场景。进化算法如遗传算法、粒子群优化则通过种群进化机制对控制参数进行全局搜索，避免局部最优。两者结合应用，强化学习用于策略学习，进化算法用于结构优化和初值设定，提升控制器的稳定性和收敛效率。

## 2.5 系统鲁棒性与收敛性理论分析

为了应对航空制造中的不确定性因素，本文引入了鲁棒损失函数与正则化项，增强了模型对异常样本的容忍能力。通过 Lyapunov 稳定性准则，证明在满足一定条件下，控制器能在有限时间内收敛至稳定轨道。复合增益调节函数保证系统在扰动条件下的精度和鲁棒性，确保控制精度不因工况波动而下降，实现高响应和高鲁棒性，满足航空制造的应用需求。

# 3 算法实现与系统仿真实验

## 3.1 仿真系统平台构建

为验证所提出基于深度学习的航空制造机械系统自适应控制策略的有效性，本文选用 MATLAB/Simulink 与 Python 混合构建的仿真平台进行实验模拟。平台中，MATLAB/Simulink 用于建立系统动力学模型与控制框架，Python 负责神经网络训练与调用，二者通过 TCP 通信协议进行数据交互。仿真模型复现了典型航空制造机械臂结构，包括多自由度运动单元、驱动执行模块与实时传感反馈系统，同时嵌入了执行器非线性、耦合扰动与传感器延迟等复杂工况因素，确保系统建模的真实性与工程相关性。

## 3.2 实验设计与控制工况设定

实验场景设定参考复合材料铺放作业流程，包含路径跟踪、轨迹切换与扰动恢复等三个阶段。控制目标为使机械臂末端在 0.1mm 误差范围内精准完成曲面轨迹跟踪，同时在外界施加随机扰动情况下保持系统稳定性。控制输入包括轴向转角、力矩、速度等变量，输出为位姿误差。实验共设置三种典型工况：理想模型无扰动、建模误差扰动场景与强外部干扰环境，覆盖从实验室仿真到工程场景的完整范围。

## 3.3 深度学习控制器与传统 PID/LQR 控制器性能对比

为了比较本文控制器的有效性，实验分别在三种控制策略下进行测试，分别为：传统 PID 控制、线性二次调节器（LQR）控制与基于深度神经网络的自适应控制策略。

表 1 不同控制器在三类工况下的误差表现（单位：mm）

控制策略	理想工况均值误差	建模误差下最大误差	强扰动下最大误差
PID	0.34	1.21	2.03
LQR	0.26	0.98	1.76
深度学习控制器	0.15	0.46	0.69

从表 1 结果可以看出，深度学习控制器在所有工况下的控制精度均明显优于传统 PID 与 LQR 方法，特别是在强扰动场景下仍能保持小于 1mm 的误差水平，展现出极强的自适应性与鲁棒性。

### 3.4 在典型扰动与模型不确定性条件下的适应性评估

表 2 控制系统在不确定性扰动条件下的适应性评估

扰动类型	平均恢复时间 (s)	稳态误差 (mm)
参数漂移	0.84	0.17
刚度突变	1.12	0.24

如表 2 所示，尽管扰动对系统状态造成明显偏移，但深度学习控制器能在较短时间内实现误差恢复，并将系统重新稳定于设定轨迹，表现出优异的扰动识别能力和快速调整机制，验证了增量学习结构的有效性。

### 下的适应性评估

进一步评估控制系统在不确定性条件下的自适应能力，实验引入两类扰动源：一为系统参数的随机变异，二为外部工件刚度突变。控制器在每轮训练后记录系统响应变化，分析其对扰动变化的跟踪与恢复能力。

### 3.5 性能指标评估

对控制器的综合性能指标进行量化分析，考察其在任务执行过程中的超调率、稳态误差、响应速度以及训练时间成本，便于评估控制器的实时性与工程可部署性。

表 3 深度学习控制器关键性能指标分析

性能指标	测试值	工程参考值	是否达标
最大超调量 (%)	4.7%	≤5%	是
稳态误差 (mm)	0.12	≤0.2	是
响应时间 (s)	0.39	≤0.5	是
平均训练时长 (min/ePOCH)	2.6	≤3	是

表 3 结果表明，深度学习控制器在保持较高控制精度的同时，能够满足工程对实时性和资源消耗的约束条件，验证了该算法在航空制造场景中实际部署的可行性和高适配性。综上，仿真实验充分证明了所提控制策略在复杂动态环境中的控制能力和工程应用潜力。

## 4 工业场景适应性与部署探讨

### 4.1 算法在真实航空制造系统中的部署需求

将基于深度学习的自适应控制策略从

仿真平台推广到真实的航空制造现场，必须首先考虑算法与工业设备之间的适配问题。部署过程中需满足控制实时性、高可靠性与系统兼容性等核心要求。由于航空制造系统运行环境复杂且任务节奏紧凑，控制算法必须能够在毫秒级的响应时间内完成状态感知、特征提取与控制指令生成，且不能对原有设备运行产生干扰。部署需支持模块化集成、在线学习更新与远程维护功能，确保控制策略能在不同型号机械设备之间快速迁移与复用。特别是在复合材料加工、结构件装配等高精度工序中，

对控制精度与响应时效的要求更加严格，这对深度学习算法的结构设计与硬件部署提出了更高标准。

#### 4.2 与工业 PLC/嵌入式控制系统的接口设计

深度学习控制算法的落地部署，需与现场已有的 PLC（可编程逻辑控制器）或嵌入式控制平台实现有效接口集成。通常采用的方案包括将神经网络模型封装为模块化 DLL 或动态链接库，通过工业以太网或 RS485 通信总线与 PLC 进行信息交互，也可以通过 OPC UA 标准协议与 SCADA 系统实现数据协同。在嵌入式环境中，需将神经网络模型转化为边缘计算兼容的轻量化版本，并通过 TensorRT、ONNX Runtime 或 TFLite 等框架完成部署，以降低模型运行时的计算负载与内存占用。为了保证数据传输的稳定性与延迟可控性，接口设计还应包括缓存机制、错误恢复机制与调试通道，确保系统在复杂工业现场中的稳定运行。

#### 4.3 资源消耗与计算延迟分析

部署深度学习算法在工业控制系统中最大挑战之一是资源受限与计算时延问题。尽管当前神经网络具备强大建模能力，但其对处理器频率、内存空间及 I/O 吞吐能力均提出较高要求，特别是在需要实时推理与在线更新的场景下。为应对这一挑战，研究中采用了网络压缩、模型剪枝与量化技术，在保持预测精度的前提下显著减少模型参数量与运行复杂度。同时结合多线程调度机制与 GPU/FPGA 加速方法，有效缩短了单次前向推理时间，将平均延迟控制在 5ms 以内。通过对系统在不同平台上的运行性能测试发现，在支持深度学习加速的嵌入式平台上，资源占用控制良好，算法具备较高部署灵活性与运行可持

续性，满足典型工业实时控制要求。

#### 4.4 应用于典型制造流程的实际意义

将该控制策略应用于典型航空制造流程，如精密铣削、自动钻孔及柔性装配线作业，可显著提升设备智能水平与作业效率。在自动钻孔过程中，深度学习模型可实时预测钻头与材料间接触状态并动态调节进给速度与旋转速率，实现破损最小化与精度最大化；在复杂结构件的装配任务中，控制器可结合多源传感数据动态调整装配路径与力控策略，显著提高装配质量并降低人工干预。更为重要的是，在多工位协作制造场景中，深度学习控制策略可通过共享模型参数与反馈数据，打通多台设备间的信息壁垒，推进“协同—自适应—优化”控制机制在复杂产线上的全面部署，从而显著增强制造流程的柔性响应能力。

#### 4.5 推动智能制造系统升级的价值

将深度学习自适应控制策略全面嵌入航空制造机械系统，不仅为设备运行提供了全新的智能核心，也为制造企业的数字化转型与智能化升级奠定了技术基础。一方面，该策略突破了传统模型控制在应对非结构化工况时的瓶颈，使控制系统具备更强的环境感知、知识学习与自主决策能力，极大地拓宽了自动化控制的适用范围；另一方面，算法支持与数字孪生、工业大数据平台联动，实现多源信息融合与全过程动态优化，有望构建以“数据驱动+自主学习”为特征的智能制造生态体系。随着边缘计算硬件性能的持续提升与智能算法部署门槛的降低，基于深度学习的自适应控制策略将逐步从实验验证走向大规模工业实施，推动传统制造模式向高效、柔性、自主的第四代智能制造范式转型。

## 5 结论

本文围绕“基于深度学习的航空制造机械系统自适应控制策略研究”展开系统性探讨，旨在提升航空制造设备在复杂工况下的智能控制能力与运行稳定性。首先从系统建模与控制需求出发，分析了航空制造机械系统中存在的多变量耦合、非线性扰动和高精度控制挑战。随后构建了融合深度神经网络的自适应控制器架构，设计了面向动态环境的状态预测机制、误差反馈模块与增量学习策略，有效提升了控制系统的精度、鲁棒性和自适应能力。通

过与传统控制方法的对比仿真验证表明，该策略在不同工况下均具备更优的误差控制性能与扰动恢复能力，并在资源消耗与实时性方面满足工业部署需求。最后结合嵌入式平台和典型制造流程分析了算法的工程适应性，为该控制策略在航空制造实际场景中的应用推广奠定了理论与实验基础。综合来看，本文提出的深度学习自适应控制方法为高端制造系统的智能化升级提供了一种可行路径，具有显著的工程价值与推广前景。

### 参考文献

- [1] 罗飞, 艾俊强, 胡志勇, 等. 飞行器对接技术的引导与控制: 现状与智能化展望[J/OL]. 电光与控制, 1-10[2025-05-23].
- [2] 石纯一. 基于深度学习的轴承加工机械臂自适应控制优化[J]. 自动化应用, 2025, 66(06): 22-24.
- [3] 罗金超, 周文杰, 郑波. 航空零部件再制造技术研究进展[J]. 长沙航空职业技术学院学报, 2025, 25(01): 11-16.
- [4] 余文浩, 齐立哲, 梁瀚文, 等. 基于深度强化学习的分层自适应PID控制算法[J]. 计算机系统应用, 2024, 33(09): 245-252.
- [5] 夏元清, 王晔, 高润泽, 等. 云网边端协同云控制研究进展及挑战[J]. 信息与控制, 2024, 53(03): 273-286.