

等离子体平衡位形智能控制

——基于中国环流三号的原理演示

报告人：杨宗谕
核工业西南物理研究院

2025年度“中国等离子体物理暑期学校” 安徽·合肥

内容提纲

- 一、托卡马克位形控制
- 二、智能诊断：EFIT-NN
- 三、智能模拟：数据驱动响应模型
- 四、智能控制：强化学习控制器
- 五、总结与展望




■ 位形控制的目的：


- 准确且稳定的位形→支撑实验物理研究
- 减少等离子体-壁相互作用→提升等离子体性能
- 控制热耗散过程→降低第一壁/偏滤器负荷

■ 位形控制的四要素：

- **观测器**：磁诊断/EFIT等反演程序/可见光相机/...
- **控制对象**：位置/形状/打击点/...
- **执行器**：磁体线圈/供电系统/...
- **控制器**：RZIP control/Isoflux/Gap control/强化学习/...





出现位形控制偏差时，等离子体会与壁面发生强烈的相互作用，并容易发展为破裂



■ 平衡位形的测量:

- 等离子体电流、线圈电流与涡流的分布共同决定了周边的电磁场分布→磁诊断→边界条件
- 热压、磁压平衡→嵌套磁面结构→磁面坐标系下的Grad-Shafranov方程
- 线圈电流+磁诊断约束+Grad-Shafranov方程 (+涡流模型) → 等离子体电流分布/位形(EFIT)




$$\mathbf{j} \times \mathbf{B} = \nabla p$$



$$-\mu_0 R^2 p' - \mu_0^2 f f' = \frac{\partial^2 \psi}{\partial Z^2} + R \frac{\partial}{\partial R} \left(\frac{1}{R} \frac{\partial \psi}{\partial R} \right)$$

$$P(\psi) = \psi^m, \quad f^2(\psi) = \psi^n, \quad n, m = 1, 2, \dots$$





■ 常作为控制对象的平衡位形参数

- 水平位置R、垂直位置Z
- 特定控制点磁通
- 等离子体-壁间隙（Gap）
- X点位置
- 偏滤器打击点

■ 平衡位形控制的执行器


- 磁体线圈及其电源/限制器/中性束等动量源/...
- 通过线圈电流与等离子体电流间的作用力调整平衡位形

控制对象	公式表达
水平位置	R_c
垂直位置	Z_c
小半径	$\frac{R_{max} - R_{min}}{2}$
拉长比	$\frac{Z_{top} - Z_{bot}}{R_{max} - R_{min}}$
上三角度	$\frac{R_c - R_{bot}}{R_c - R_{min}}$
下三角度	$\frac{R_c - R_{top}}{R_c - R_{min}}$
等离子体与壁面距离	g




■ 前馈+反馈的RZIp控制器

- 前馈波形通过仿真设计+实验探索获得
- PID反馈对控制偏差进行小幅修正



■ 等磁通控制器

- 调整控制点磁通与最外闭合磁面磁通的偏差
- 能够实现更加精确的边界形状控制




内容提纲

- 一、托卡马克位形控制
- 二、智能诊断：EFIT-NN
- 三、智能模拟：数据驱动响应模型
- 四、智能控制：强化学习控制器
- 五、总结与展望




■ “精度”与“速度”的矛盾：

- HL-3 offline EFIT: 129*129分辨率, 单帧耗时~1s
- RT-EFIT: 33*33分辨率, 单帧耗时~1ms




■ 迭代方法的稳定性问题：

- 多解问题可能会收敛至不正确的分支解
- 迭代过程可能无法正常收敛



■ 用神经网络学习一个从边界条件到位形参数的映射

- 对同一装置而言，GS方程、网格划分、装置构型均不变
- 位形由磁诊断的输入完全确定，用offline EFIT在历史数据库中可以得到大量的映射数据对




$$\mathbf{j} \times \mathbf{B} = \nabla p$$






$$-\mu_0 R^2 p' - \mu_0^2 f f' = \frac{\partial^2 \psi}{\partial Z^2} + R \frac{\partial}{\partial R} \left(\frac{1}{R} \frac{\partial \psi}{\partial R} \right)$$

$$P(\psi) = \psi^m, \quad f^2(\psi) = \psi^n, \quad n, m = 1, 2, \dots$$



■ 用神经网络学习一个从边界条件到位形参数的映射

- 对同一装置而言，GS方程、网格划分、装置构型均不变
- 位形由磁诊断的输入完全确定，用offline EFIT在历史数据库中可以得到大量的映射数据对




速度、精度兼顾

- 迭代过程被转移到了开发阶段（神经网络训练）
- 应用阶段仅需单次正向计算
- HL-3: 129*129分辨率, 单帧0.45ms


无迭代稳定性问题

- 神经网络学习到的是一个确定的映射
- 只能代理多个分支解的其中一个
- 无迭代过程, 不会收敛失败



EFIT-NN重建的磁通剖面与电流剖面

计算宏观位形参数耗时0.1ms, 129*129磁通剖面耗时0.45ms



EFIT-NN自动修正了部分offline EFIT收敛失败引入的错误标签

■ EFIT-NN与数值算法对比:

- 数值算法具有更高的精度和成熟度，其速度上的短板可以通过GPU加速解决，因此P-EFIT等技术仍然是首选方案
- EFIT-NN的优势体现在稳定性，以及更低的边际成本

实时 EFIT 数值算法	EFIT-NN
基于物理, 计算结果可信	数据驱动的黑箱算法
已发展数十年, 具有充足研究基础	新兴方法, 尚需进一步发展
需要作若干假设, 必然导致一定的精度牺牲	万能近似定理, 原则上误差极小
代码复杂, 不易移植和实装	若不对精度作很高要求, 很快就可以训练出可用的模型
想提升分辨率需要大量增加计算消耗	增加输出不会大量增加计算量

■ 代理模型的技术复杂度不会因为待求解问题的复杂化而爆炸式增长:

- Kinetic EFIT的实时化通过GPU加速方法很难实现：更多的代码耦合→更复杂的求解过程、更糟糕的计算稳定性
- NN是Kinetic EFIT实时化很有潜力的路径（Ricardo et al 2024 NF 64 026006）

内容提纲


- 一、托卡马克位形控制
- 二、智能诊断：EFIT-NN
- 三、智能模拟：数据驱动响应模型
- 四、智能控制：强化学习控制器
- 五、总结与展望




■ 响应模型：当前状态+控制指令→未来状态

■ 平衡位形的响应模型

- 当前状态：T时刻的等离子体位置、形状
- 控制指令：T+1时刻投入的线圈电压、电流
- 未来状态：T+1时刻的等离子体位置、形状





位形演化模拟器的输入输出架构示意



平衡位形的演化过程示例

■ HL-3平衡位形的响应模型：

- 使用1627次历史实验放电中的三元组数据，进行神经网络训练
- 基于改进WaveNet架构，捕捉 $(S_T, A_{T+1}) \rightarrow S_{T+1}$ 的映射关系




■ 单步预测: $(S_T, A_{T+1}) \rightarrow S_{T+1}^*$

- 简单的模型便可以做到极好的性能
- 预测结果与实验结果高度一致




■ 自回归预测: $(S_T^*, A_{T+1}) \rightarrow S_{T+1}^*$

- 预测误差会随着时间推移不断累积
- 无特殊优化时, 100ms后的累积误差便会令模型预测逻辑彻底失效





■ 引入一系列解决方案

- 随机游走噪声：训练阶段为输入引入一个随时间不断积累的噪声项
- 多步损失函数：将长周期累积误差引入损失函数
- 教师模型&计划采样：模型输入从 (S_T, A_{T+1}) 逐步过渡为 (S_T^*, A_{T+1})



■ PID控制器与响应模型的闭环交互：

- 完整执行整个放电过程的模拟
- 仿真效果与实验结果基本一致
- 可支撑控制器开发与参数整定




内容提纲

- 一、托卡马克位形控制
- 二、智能诊断：EFIT-NN
- 三、智能模拟：数据驱动响应模型
- 四、智能控制：强化学习控制器**
- 五、总结与展望




■ 前馈+反馈的RZIP控制器


- 前馈波形通过仿真设计+实验探索获得
- PID反馈对控制偏差进行小幅修正




■ 等磁通控制器

- 调整控制点磁通与最外闭合磁面磁通的偏差
- 能够实现更加精确的边界形状控制






19个线圈PID控制方式设计复杂、耗时耗力




传统PID控制器



- 预先计算参考前馈线圈电流和电压
- 设计各线圈负反馈控制器
 - 对需要控制的误差设立单独观察器
 - 选择用于每个被控量的线圈组合
 - 反复迭代调整单独的控制参数

AI强化学习控制器









- 单一集成控制器
- 无需计算参考前馈信号
- 没有单独的前馈误差估计

Shift the focus from the exact specifics on "how" to achieve such goals towards "what" goals should be achieved.


■ 强化学习控制器实现多种复杂放电位形

- 拉长位形/下单零/反三角/先进偏滤器/双环等离子体




■ 算法框架

- 控制对象：等离子体电流、位置与形状
- 仿真环境：数据驱动的等离子体位形演化预测模型
- 训练目标：最小化控制误差+工程约束惩罚项




HL -3 强化学习位形控制总体框架




在HL-3实现400ms强化学习位形控制，可动态调整三角度、拉长比等参数


- 传统的“预设波形+反馈控制”软着陆策略难以应对多样化的工况和破裂原因
- AI解决方案：实时评估软着陆中每个等离子体状态的破裂风险，通过强化学习搜出一条“低风险”路径



从起始等离子体参数向目标着陆点径直前进可能会经过不稳定参数区，因此需要规划一条合理的着陆曲线



强化学习、响应模型、破裂预测等模块的协同 workflow





强化学习控制（红）和传统控制（蓝）时破裂概率随等离子体电流的变化轨迹

内容提纲

- 一、托卡马克位形控制
- 二、智能诊断：EFIT-NN
- 三、智能模拟：数据驱动响应模型
- 四、智能控制：强化学习控制器
- 五、总结与展望





在人工智能的加持下，有望实现对磁面位形、剖面分布、不稳定性三项核心对象的控制闭环与全局优化

感谢聆听!

报告人: 杨宗谕

E-mail: zy-yang@swip.ac.cn

特别致谢:

