

基于强化学习的自适应 PID 智能控制虚拟仿真平台构建

郑国权

岭南师范学院, 广东省湛江市, 524048;

摘要: PID 控制是工业过程控制中经典且应用广泛的策略, 其参数整定是研究热点。传统整定方法依赖精确数学模型, 面对复杂系统难以获理想效果。强化学习为 PID 参数自适应整定提供新思路。本文综述基于强化学习的自适应 PID 控制器研究进展, 重点探讨虚拟仿真平台构建技术。文章先阐述传统 PID 控制与强化学习结合的必要性及优势; 接着分析强化学习自适应 PID 控制的核心原理与典型算法; 然后提出分层模块化的虚拟仿真平台总体架构, 论述其核心组成模块; 之后通过典型被控对象仿真案例验证平台有效性; 最后总结当前领域面临的主要挑战, 如训练效率等问题, 并对未来发展方向, 如与深度学习融合等进行展望。本文旨在为相关研究人员提供技术参考和实践指南。

关键词: 强化学习; 自适应 PID 控制; 虚拟仿真平台; 数字孪生

DOI: 10. 64216/3080-1516. 25. 04. 079

引言

比例积分微分控制器诞生后, 因结构简单、鲁棒性好等优点, 在超 90% 工业控制系统中占主导。但其控制性能依赖三个参数合理设置, 传统 PID 参数整定方法, 如 ZieglerNichols 法等, 需基于系统阶跃响应模型或频域特性, 在特定工作点附近进行, 存在明显局限: 一是依赖被控对象线性、时不变数学模型, 而实际工业过程特性复杂, 难以精确建模; 二是系统工作点变化或受扰动时, 固定参数的 PID 控制器难以维持最优性能, 甚至致系统失稳。为克服传统 PID 不足, 自适应控制理论出现, 自适应 PID 控制器能根据系统状态自动调整参数。早期自适应 PID 控制策略对模型准确性要求高、算法复杂, 工程推广有困难。近年来, 强化学习发展为智能控制带来新活力。强化学习不依赖先验模型, 通过智能体与环境交互“试错”学习最优策略, 与自适应控制理念契合。将强化学习与 PID 控制结合, 形成新型智能自适应 PID 控制器。不过, 强化学习算法训练需大量数据, 在真实物理系统学习成本高、风险大, 所以构建虚拟仿真平台很重要, 它是验证算法有效性的“试验场”和加速应用的“催化剂”。

1 强化学习自适应 PID 控制原理与算法

1.1 基本框架

将强化学习应用于 PID 参数自适应整定的基本框架。该框架包含两个核心部分: 被控对象(环境)和 RL 智能体(控制器中的参数整定器)。环境: 即被控对象(如

电机、化工过程、飞行器等)及其闭环控制系统。环境的状态通常包括系统的输出误差 $e(t)$ 、误差积分、误差微分、系统输出 $y(t)$ 等。智能体采取的动作会作用与环境, 环境反馈新的状态和奖励。

智能体: 其核心任务是学习一个参数调整策略 π 。在每一个控制时刻 t (或一个控制周期), 智能体观测到当前环境状态 s_t , 并根据其策略选择一个动作 a_t 。这个动作就是 PID 控制器参数的调整量, 即 ΔK_p , ΔK_i , ΔK_d 。随后, PID 控制器的参数更新为 $K_p = K_{p0} + \Delta K_p$, $K_i = K_{i0} + \Delta K_i$, $K_d = K_{d0} + \Delta K_d$ 。

奖励函数: 是引导智能体学习的方向盘。其设计至关重要, 通常需要综合考虑控制系统的多项性能指标。一个典型的奖励函数设计如下: $r_t = -(\alpha e_t^2 + \beta u_t^2 + \gamma (\Delta u_t)^2)$ 其中, e_t^2 惩罚跟踪误差, 保证系统的准确性; u_t^2 惩罚控制量, 避免能量过大; $(\Delta u_t)^2$ 惩罚控制量的变化率, 使控制过程平滑。系数 α , β , γ 用于权衡各项指标的相对重要性。通过不断交互, 智能体的目标是学习到一个最优策略 π^* , 使得调整 PID 参数后, 整个闭环系统能够获得最大的长期累积奖励, 即实现综合控制性能的最优。

1.2 典型强化学习算法

应用于自适应 PID 控制的 RL 算法主要可分为三类:

1.2.1 基于值函数的方法

这类方法试图学习一个状态-动作值函数 $Q(s, a)$, 表示在状态 s 下执行动作 a 所能获得的期望累积奖励。最具代表性的是 Q-learning 及其扩展算法。Q-learning

g:通过更新 Q 表来学习最优策略。其优点是离线学习、简单有效。但对于连续状态和动作空间 (PID 参数调整通常是连续的), 需要离散化, 这会引发“维度灾难”, 导致学习效率低下、精度受限。

深度 Q 网络: 利用深度神经网络来近似 Q 函数, 成功解决了高维状态空间的问题。但在处理连续动作空间时, 需要结合策略梯度方法 (如 Actor-Critic)。

1.2.2 基于策略搜索的方法

这类方法直接参数化策略 $\pi_\theta(a|s)$, 并通过优化策略参数 θ 来最大化期望回报。代表性算法是 REINFORCE。优点: 天然适用于连续动作空间。

缺点: 采样效率较低, 方差较大, 训练过程可能不稳定。

1.2.3 基于 Actor-Critic 的方法

这是目前最主流、最有效的框架, 它结合了值函数和策略搜索的优点。框架包含两个部分: Actor (执行者): 负责根据当前策略选择动作 (即调整 PID 参数)。

Critic (评价者): 负责评估 Actor 所执行动作的优劣, 即估计状态值函数 $V(s)$ 或优势函数 $A(s, a)$, 并指导 Actor 的策略更新。代表性算法包括: 深度确定性策略梯度: 专为连续控制问题设计。其 Actor 网络直接输出连续的动作值。DDPG 表现出色, 但对超参数敏感。

近端策略优化: 通过引入裁剪机制, 保证了策略更新的稳定性, 使其更易于调参和收敛, 成为当前实践中的首选算法之一。

软演员-评论员: 在目标函数中增加了策略的熵, 鼓励探索, 提高了算法的鲁棒性和采样效率。对于自适应 PID 控制问题, 由于动作空间 (参数调整量) 是连续的, 且需要学习平滑稳定的调整策略, Actor-Critic 框架下的 DDPG、PPO 和 SAC 算法通常能取得比传统方法更好的效果。

2 虚拟仿真平台的构建

一个功能完善、运行高效的虚拟仿真平台是 RL 自适应 PID 控制研究得以深入开展的关键基础设施。其构建应遵循模块化、可扩展、易用性原则。

2.1 总体架构设计

平台应采用分层模块化架构, 通常包括以下四个层次: 数据层: 负责存储和管理所有数据, 包括被控对象模型参数、训练过程中的交互数据 (状态、动作、奖励)、

训练好的智能体模型、仿真结果数据等。

仿真引擎层: 平台的核心计算层, 包含环境动力学模型求解器 (如 ODE 求解器) 和 RL 智能体训练算法库 (如基于 PyTorch/TensorFlow 的实现)。

服务层: 提供核心业务逻辑的接口, 如仿真任务管理、模型训练调度、数据可视化服务、评估指标计算等。

应用层: 用户交互界面, 包括图形化配置界面、实时监控仪表盘、三维可视化场景、结果分析报告生成器等。

2.2 核心模块详解

2.2.1 环境模型库

这是平台真实性的基础。库中应集成多种典型被控对象的数学模型, 涵盖线性与非线性、时变与定常、集中参数与分布参数等不同类型。经典控制系统: 倒立摆、球杆系统、飞行器姿态动力学模型、机械臂模型、直流电机模型等。

过程控制系统: 液位控制系统、温度控制系统、连续搅拌反应釜模型等。

接口开放: 平台应提供标准接口 (如 Python API、FMI/FMU 标准), 允许用户方便地导入自定义模型或利用 Simulink、Modelica 等专业建模工具建立的模型, 实现与主流仿真软件的协同仿真。

2.2.2 智能体训练引擎

这是平台的“大脑”, 集成了多种 RL 算法。算法库: 应至少包含 DDPG, PPO, SAC, TD3 等主流连续控制算法。

训练管理: 支持分布式并行训练, 以加速学习过程。提供训练过程的实时监控, 如奖励曲线、状态曲线、动作曲线的动态显示。

超参数配置: 提供友好的图形化界面, 方便用户配置网络结构、学习率、折扣因子等超参数。

2.2.3 可视化与人机交互界面

良好的可视化是理解和调试算法的关键。场景可视化: 对于机械系统 (如倒立摆、无人机), 应提供 2D/3D 动画展示, 直观呈现控制效果。

数据可视化: 实时绘制系统输出、控制输入、PID 参数变化曲线、奖励值曲线等。

交互控制: 允许用户在仿真过程中暂停、继续、注入扰动、切换控制器 (对比 RL-PID 与常规 PID), 并实时修改模型参数或控制器参数。

2.2.4 评估与分析系统

平台需提供一套科学的评估体系,用于量化比较不同算法的性能。性能指标:集成多种控制性能指标,如积分绝对误差、积分平方误差、上升时间、超调量、调节时间、控制量消耗等。

鲁棒性测试:支持对训练好的控制器进行测试,如参数摄动测试、外部扰动测试、设定值突变测试等。

对比实验:支持将 RL 自适应 PID 与 Z-N 法整定的 PID、模糊 PID 等控制器的控制效果进行同屏对比,生成详细的对比报告。

2.3 实现技术选型

现代虚拟仿真平台通常基于成熟的技术栈构建。编程语言与框架:Python 是首选,因其在科学计算和机器学习领域的丰富生态。核心仿真计算可用 NumPy/SciPy;RL 算法实现可基于 PyTorch 或 TensorFlow。

物理引擎:对于复杂刚体动力学仿真,可集成 MuJoCo、PyBullet 等专业物理引擎,以获得更高的物理真实性。

图形界面:可采用 Web 技术栈(如 React/Vue+WebGL)构建跨平台的浏览器应用,或使用 PyQt、Tkinter 等构建桌面应用。

云原生与数字孪生:未来平台可向云原生架构演进,利用容器化(Docker)和编排技术(Kubernetes)实现资源弹性调度。并可与数字孪生技术结合,实现与真实物理系统的实时数据交互和同步仿真。

3 典型应用案例仿真分析

在本节中,我们通过两个经典案例来展示基于该仿真平台的 RL 自适应 PID 控制器的应用效果。

案例一:倒立摆起摆与稳摆控制

倒立摆是一个经典的非线性、不稳定系统,是验证控制算法的“试金石”。环境状态: $s=[\theta, \dot{\theta}, x, \dot{x}]$, 即摆杆角度、角速度、小车位置、车速。

动作: $a=[\Delta K_p, \Delta K_i, \Delta K_d]$, 即调整 PID 控制器(控制对象为小车加速度/力,目标为使摆杆直立)的参数。

奖励函数: $r=-(\theta^2+0.1\dot{\theta}^2+0.001x^2+0.001\dot{x}^2)$, 重点惩罚角度偏差。

训练过程:在平台上使用 PPO 算法进行训练。智能体从随机初始状态开始,通过数百万步的交互,逐渐学习到如何调整 PID 参数,使得小车通过左右移动成功地

将摆杆竖起并保持平衡。

结果分析:训练完成后,与 Z-N 法整定的固定参数 PID 进行对比。仿真结果显示,在受到外力冲击后,RL 自适应 PID 控制器能更快地调整参数,使摆杆恢复平衡,且超调更小,表现出更强的鲁棒性和适应性。案例二:四旋翼无人机姿态控制

无人机姿态系统是一个多变量、强耦合的非线性系统。控制设计:为俯仰、滚转、偏航三个通道分别设计一个 RL 自适应 PID 控制器。

状态与动作:每个控制器的状态包括对应通道的欧拉角误差和角速度误差,动作为该控制器 PID 参数的调整量。

挑战与策略:耦合效应是主要挑战。在奖励函数中,除了本通道的误差,还需轻微惩罚其他通道的误差,以引导智能体学习解耦控制。

仿真结果:平台上的三维可视化清晰展示了控制效果。RL 自适应 PID 控制器在面对阵风扰动时,能显著减小姿态角的波动,相比固定参数 PID,控制品质提升明显。平台的多变量数据曲线也直观揭示了 RL 控制器在抑制通道间耦合方面的优势。

4 挑战与未来展望

尽管 RL 自适应 PID 控制展现出巨大潜力,但其发展和应用仍面临诸多挑战。

4.1 当前面临的主要挑战

训练效率与稳定性:RL 算法的训练通常需要大量样本,耗时较长。训练过程可能不稳定,收敛性难以保证。

奖励函数设计:奖励函数的设计高度依赖于专家经验,被称为“奖励工程”。不合理的奖励函数可能导致智能体学习到不符合预期的“捷径”行为。

安全性保障:在探索过程中,智能体可能会执行危险动作,导致仿真中系统发散。如何引入安全约束,实现安全强化学习,是走向实际应用的关键。

仿真到现实的迁移:仿真模型与真实世界之间存在不可避免的“现实差距”。在仿真中训练好的控制器,直接部署到实物上可能性能下降。域随机化、系统辨识和在线自适应学习是解决该问题的重要方向。

4.2 未来研究方向展

望算法融合与改进:将 RL 与模型预测控制、模糊逻辑、专家系统等传统方法深度融合,利用先验知识引

导学习,提高采样效率和稳定性。

平台技术深化:发展更高保真的仿真技术,结合数字孪生,实现虚拟与现实的实时交互与迭代优化。构建云边端协同的仿真平台,支持大规模、分布式训练。

自动化与智能化:研究自动化的奖励函数学习、超参数优化技术,降低平台的使用门槛,使其成为更通用的智能控制器自动设计工具。

新兴应用场景拓展:将 RL 自适应 PID 控制应用于更复杂的场景,如能源互联网、智能交通、生物医学等领域的复杂系统控制。

5 总结

本文系统综述了基于强化学习的自适应PID控制方法及其虚拟仿真平台的构建。RL 方法为解决复杂不确定环境下的PID参数在线自整定问题提供了强有力的数据驱动工具,而虚拟仿真平台则为该技术的研发、测试和验证提供了不可或缺的支撑环境。通过对核心原理、平台架构、关键技术和应用案例的分析,可以看出,RL

自适应PID控制技术在提升系统控制性能、鲁棒性和自适应性方面具有显著优势。

尽管在训练效率、安全性和仿真到现实的迁移等方面仍存在挑战,但随着强化学习算法本身的不断进步、计算能力的提升以及仿真技术的日益精进,基于强化学习的自适应智能控制必将迎来更广阔的发展前景。未来,一个集成了高性能计算、高保真仿真、智能算法和友好交互的虚拟仿真平台,将成为推动智能控制从理论创新走向工程实践的核心基础设施。

参考文献

- [1]陈学松,杨宜民.基于执行器-评价器学习的自适应PID控制[J].控制理论与应用,2011,28(8):6. DOI:10.7641/j.issn.1000-8152.2011.8.ccta100618.
- [2]谢琪琦.基于强化学习的半主动悬架PID控制[J].汽车电器,2024(12):29-32.
- [3]吕铁良,张运涵,袁凯平.一种基于强化学习的自适应PID温度控制算法:202510020286[P][2025-10-13].