

融合 RBF 神经网络的信息系统有限时间跟踪控制研究

毛天麟¹, 邹晓华²

(1. 江苏科技大学 经济管理学院, 江苏 镇江 212100;

2. 常州信息职业技术学院, 江苏 常州 213164)

摘要: 研究对信息系统运行的稳定性与可靠性进行了分析, 采用了一种结合径向基函数与有限时间稳定性理论的控制方法; 通过构建一个基于径向基函数神经网络的控制模型, 并创新性地引入了一个有限时间跟踪控制框架, 该框架能够确保系统状态在有限的时间达到期望的系统跟踪性能; 此外结合了一种非线性映射方法, 并融合反步法对控制方法进行改进, 最终降低信息系统设计的复杂程度与难度; 随着系统运行时间的推移, 当时间趋近于 10.0 s 时, 研究所构建方法的运行稳定性高于 90%; 另外当运行时间达到 35 s 时, 研究所构建方法运行下对系统的控制稳定性趋近于 100%; 经实验测试验证, 在有约束条件下智能信息系统对应曲线的波动幅度较小, 变化的速度也较慢, 信息系统智能体状态运行的误差也较小; 经过实际应用证明了所提出的方法能够对系统展开良好控制, 并且跟踪精度较高, 满足信息工程的需求。

关键词: RBF 神经网络; 有限时间控制; 跟踪控制; 信息系统; 非线性; 状态约束

Limited-Time Tracking Control of Information System Integrating with RBF Neural Network

MAO Tianlin¹, ZOU Xiaohua²

(1. Jiangsu University of Science and Technology, Zhenjiang 212100, China;

2. School of Economics and Management, Changzhou College of Information Technology,
Changzhou 213164, China)

Abstract: This paper analyzes the stability and reliability of the operation of the information system, and presents a control method that combines radial basis function and finite time stability theory, constructs a control model based on radial basis function neural network, and innovatively introduces a finite time tracking control framework, achieving the desired system tracking performance in a limited time. In addition, combined with a nonlinear mapping method, the control method is improved by integrating with the backstepping method, which ultimately reduces the complexity and difficulty of the information system. As the system time runs for a period of time approaching 10.0 s, the stability of the constructed method approaches 100%. Experimental tests have verified that under constrained conditions, the intelligent information system has a small fluctuation amplitude of the corresponding curve, with a slow speed of change and a small error of the state operation of the information system intelligent agent. Practical application has proved that the proposed method has a good control performance of the system, with a high tracking accuracy, which meets the needs of information engineering.

Keywords: RBF neural network; finite time control; tracking control; information system; nonlinear; state constraint

收稿日期:2024-06-20; 修回日期:2024-08-19。

基金项目:2022 年度省教育科学规划课题(B/2022/02/86);2023 年江苏省高等教育教学改革研究课题(2023JSJG619)。

作者简介:毛天麟(2003-),男,大学本科。

通讯作者:邹晓华(1980-),男,研究生,教授。

引用格式:毛天麟,邹晓华. 融合 RBF 神经网络的信息系统有限时间跟踪控制研究[J]. 计算机测量与控制, 2025, 33(8): 120-128.

0 引言

随着数字化时代的到来, 信息系统对社会经济活动与人类生活的影响日益显著。信息系统的稳定性与可靠性直接关系到系统数据的安全与业务的连续性。因此, 对信息系统进行有效的控制与优化, 并确保其能够在复杂的环境下稳定地运行, 已经成为一个迫切需要解决的问题^[1-2]。在现实世界中, 多数系统本质上都是非线性的, 这些系统在引入约束条件时其非线性特性会变得更加显著。同时, 由于受到各种不同的约束与限制, 实际信息系统对应的数学模型通常为具有不确定性参数的高阶系统, 这导致直接应用针对简单线性或低阶系统的现有理论开始变得不切实际^[3-4]。如何设计一个能够确保系统在满足各种约束的同时还能够稳定运行的控制器开始具有一定的挑战。为此众多学者对其进行了研究。Sun 等人^[5]为了提高风力发电系统的发电能力与风能跟踪精度, 提出一种基于改进 RBF 神经网络的风力发电方法。利用 RBF 神经网络的预测能力, 优化风能控制观测器; 最终有效提高了系统的转速跟踪能力与风能捕获效率。Cui 等人^[6]提出一种基于隐性权值与神经网络的方法, 以应对未知约束非线性系统的跟踪与控制。利用神经网络来更新权重的同时, 对参数进行激活调整。结果显示, 该控制方案能够在确保速度约束的条件下, 确保系统仿真位置的跟踪。黄小龙等人^[7]针对外界环境的干扰与智能系统本身参数所带来的影响, 提出一种基于分布式自适应径向基函数的神经网络控制方法。最终通过仿真实验验证了方法的有效性。近年来, 有限时间稳定性理论在控制领域得到了广泛的关注和研究。该理论的核心在于设计能够在有限时间内确保系统状态达到并保持期望的数值范围内的控制策略。在信息系统跟踪控制领域, 有限时间控制策略因其快速响应和高精度跟踪的特点, 逐渐成为研究的热点。国内外学者针对不同的信息系统和控制需求, 提出了多种有关有限时间控制理论的算法。Liu 等人^[8]为了对移动的目标进行视觉跟踪, 提出一种基于有限时间控制技术的移动机器人视觉跟踪方法。结果发现, 该数据能够在一定的时间控制内对移动的目标实现较高精度的跟踪与控制, 性能较优。Tong^[9]的团队提出一种结合自抗扰与有限时间控制策略的非线性控制系统, 以应对一系列控制器的运行控制问题。结果发现该方法有利于节约通信资源, 并且十分有效。Xu 等人^[10]为了解决电液伺服系统中参数不确定性所引起的扰动控制等问题, 提出一种基于终端滑模观测与有限时间控制的方法, 并通过实验验证了该方法对机电系统的控制精度最高。

尽管有限时间控制策略与神经网络在多个领域显示了优越性, 但在实际应用中也存在一些局限性。首

先, 有限时间控制算法的设计通常较为复杂, 需要对系统的动态特性和约束条件有深入的理解。其次, 算法的参数调整和优化可能需要大量的计算资源和时间。此外, 有限时间控制策略在面对强非线性和高不确定性系统时, 其稳定性和鲁棒性仍需进一步验证和改进。针对上述问题, 研究提出了一种融合径向基函数 (RBF, radial basis function network) 的有限时间跟踪控制策略。RBF 神经网络因其强大的非线性映射能力和自主学习能力, 在复杂信息系统的建模与控制中显示出巨大的潜力。通过结合 RBF 神经网络和有限时间控制技术, 研究旨在解决传统控制方法在收敛速度和稳定性方面的不足, 同时满足现代化信息系统对快速响应与高精度控制的需求。研究将对所提出的控制策略进行详细的理论分析和仿真验证, 以展示其在信息系统跟踪控制中的有效性和适用性。

1 基于改进 RBF 神经网络的信息系统有限时间跟踪控制方法

1.1 基于 RBF 神经网络与全状态约束条件的信息系统有限时间跟踪算法

智能信息系统是一个综合性的领域, 它涵盖了多种技术, 包括但不限于人工智能、机器学习、数据挖掘、模式识别等, 这些技术共同作用于信息的收集、处理、分析和决策支持。在智能信息系统中, “智能”主要体现在系统的自适应学习能力、预测与决策支持以及响应等多个方面。在实际应用中, 信息系统常常面临着外部环境因素与内部限制的挑战, 例如在自动驾驶车辆的行驶过程中信息系统必须将周围环境与自身速度的限制考虑在内。因此, 对信息系统状态受限控制问题的研究具有一定的实际研究价值。至今, 为了应对系统输出与状态受限等问题, 众多专家已经提出了多种控制策略。BLF 方法作为一种常见策略, 必须针对系统状态受限条件重新设计李雅普诺夫函数, 但会使得控制器的设计过程变得十分繁琐^[11]。为了设计所得的控制器在运行时能够获得更高的建模精度, 研究引入径向基函数 (RBF) 神经网络对其进行改进。RBF 网络模型如图 1 所示。

图 1 中可以发现, RBF 神经网络分别由 3 个层次组成: 输入层 x 、隐藏层 R 和输出层 y ; v 为输出层权值。输入层与隐藏层之间没有权重连接, 输入数据直接映射到隐藏层^[12]。隐藏层包含非线性函数, 而网络的最终输出是隐藏层输出的加权线性组合^[13]。假设该模型的输入为 $x_m = (x_1, x_2, \dots, x_i)^T$, 对应得到第 j 个隐含节点的输出计算见式 (1):

$$b_j(x_m) = \varphi\left(-\frac{\|x_m - c_j\|}{\sigma_j}\right), j = 1, 2, \dots, K \quad (1)$$

式中, c_j 与 σ_j 分别为第 j 个隐含层神经元的中心与宽度。




图 1 径向基函数神经网络

较大的 σ_j 意味着每个神经元对更广泛的输入区域有响应，而较小的 σ_j 值则使得神经元对输入更加敏感。 c_j 为 n 维度向量，与网络中输入节点的个数相同； $\|\cdot\|$ 则为欧氏距离； $\varphi(\cdot)$ 为径向基函数。由于高斯函数的局部响应特性意味着网络的每个隐层神经元只对输入空间中的一个小区域敏感，这有助于提高网络对输入变化的响应速度。因此实验选取高斯函数 $\varphi(r) = \exp\left(-\frac{r^2}{2\sigma^2}\right)$ 计算网络输出。得到网络输出见式 (2)：

$$\begin{cases} y_m = \sum_{j=1}^K w_{jm} \exp\left(-\frac{\|x_{in} - c_j\|^2}{2\sigma_j^2}\right) + w_{m,0} \\ m = 1, 2, \dots, n \end{cases} \quad (2)$$

神经网络算法通常在处理静态非线性问题时有着较强的适应能力，尤其是在增强神经网络模型的记忆功能方面^[14]。在传统 RBF 函数架构内，研究引入了一种递归极值。通过在模型的输出中融入递归项的超前时刻数据与历史时刻数据分类，提出一种优化 RBF 网络模型，如图 2 所示。




图 2 改进 RBF 神经网络模型

相较于传统 RBF 函数模型，该优化模型将复数基带信号作为输入，从而优化了模型的输入结构。得到的新输入计算见式 (3)：

$$X_{in}(n) = \begin{bmatrix} x_{in}(n), x_{in}(n-1), \dots, \\ x_{in}(n-q), x_{out}(n-1+l), \dots, \\ x_{out}(n-1), \dots, x_{out}(n-1-t) \end{bmatrix}^T \quad (3)$$

式中， q 为输入复基带信号记忆深度； l 与 t 分别为输出递归分量的超前时刻与历史时刻。该优化 RBF 网络模型的输出为一维复数，表达为 $x_{out}(n) = f[X_{in}(n)]$ 。由于研究将高斯函数作为神经网络的转移函数，那么可以对一维输出函数进行改写，计算见式 (4)：

$$x_{out}(n) = w_0 + \sum_{i=1}^K w_i B_i \quad (4)$$

式中， K 为隐含层中神经元的具体个数； w_i 为输出层的权值； B_i 为第 i 个神经元的输出。将神经网络中的转移函数作为高斯函数，具体表达见式 (5)：

$$B_i = \exp\left[-\frac{\sum_{m=1}^{2+q+l+t} \|X_{in}(m,n) - C_i(m)\|^2}{\beta^2}\right] \quad (5)$$

式中， $C_i(m)$ 为隐含层的中心； $X_{in}(m,n)$ 为复数基带信号输入； β 为常数，取值范围在 $[0, 1]$ ； S 为扩展常数。在实际工程实践中，智能信息系统常常面临来自外部环境或内部条件的限制，例如在自动驾驶领域，车辆的导航和速度控制必须兼顾路况和车辆自身的速度限制^[15-16]。因此，探讨状态受限的控制问题不仅在理论上具有重要性，也对实际应用有着深远的影响。至今，为了应对输出约束及状态约束的挑战，众多学者已经研究并提出了多种控制策略。其中，基于 Barbalat 引理的方法是最为常见的，但这种方法需要根据系统的状态约束重新构造 Lyapunov 函数，这就使得控制器的设计过程变得相对复杂^[17-18]。此外，BLF 方法主要被应用于单一系统的状态受限问题。基于上述内容，为了降低控制器设计的复杂程度，研究引入一种非线性映射方法，并将其应用于非线性纯反馈信息系统，提出一种结合 RBF 神经网络与全状态约束条件的信息系统有限时间跟踪算法。研究考虑存在一个高阶非线性智能信息系统，其中分别包含有领导者与跟随者，系统的框架见式 (6)：

$$\begin{cases} \dot{x}_{i,m} = f_{i,m}(\bar{x}_{i,m}, x_{i,m+1}), m = 1, \dots, n-1 \\ \dot{x}_{i,n} = f_{i,n}(\bar{x}_{i,n}) + g_{i,n}(\bar{x}_{i,n})u_i \\ y_i = x_{i,1} \end{cases} \quad (6)$$

式中， $\bar{x}_{i,m}$ 分别为第 i 个跟随者的状态变量； $x_{i,m}$ 为控制输入； $\bar{x}_{i,n}$ 为控制输出。 $f_{i,m}(\cdot)$ 、 m 与 $g_{i,n}(\bar{x}_{i,n})$ 均为系统中未进行求解的连续非线性函数。研究旨在开发一种具有高度一致性的改进跟踪控制策略，以确保所有跟随者的实际输出能够在一定的时间范围内对指定的轨迹进行跟踪与运行，以此来确保系统的输出具有一定的稳定性，并且来保持所有状态与输出值都一直稳定在预设的约束范围内。在智能信息系统中，假设将领导者作为根节点，通常采用领导—跟随结构来实现一致性跟踪控制。

在这种特定的系统架构中，信息的传递是单向的，

即从领导者到跟随者; 而跟随者之间则仅允许信息进行双向流通^[19]。这意味着跟随者能够接收领导者的信号以及来自邻近智能系统的信息反馈, 但系统中的领导者并不能对跟随者的实时状态数据进行获取^[20-21]。因此, 在对系统进行设计时至少需要确保有一条路径是从领导者通向跟随者的, 并且将领导者所在地点作为系统网络的根节点。当领导者的轨迹是连续且有界的前提下, 实际上只需要系统中的些许跟随者可以有效获取领导者的具体位置节点, 这与那些需要所有跟随者都获取领导者轨迹及其所有时间导数信息的方法比较而言, 所构建方法显著减少了系统对传感器数量的需求, 并且有效降低了成本, 最终简化了所需控制器的总体设计流程。同时, 将未知光滑非线性函数作为有界函数, 并将其作为一个系统可控性条件。针对系统状态约束问题, 研究利用所提出的新颖的非线性映射技术, 该技术能够将受全面状态限制的多智能体系统转化为不受状态限制的非线性系统。通过这种转换, 研究可以在新的系统模型基础上设计相应的控制器。以下是系统模型的转换见式 (7):

$$M(b_{m1}, b_{m2}, x_{i,m}) = \log \frac{b_{m1} + x_{i,m}}{b_{m2} - x_{i,m}}, m = 1, \dots, n \quad (7)$$

式中, b_{m1} 与 b_{m2} 为正常数。将新的状态变量 $z_{i,m}$ 与式 (7) 相结合, 其中 $z_{i,m} = M(b_{m1}, b_{m2}, x_{i,m})$ 。可以得到 $\dot{z}_{i,m}$ 的值 $[\dot{z}_{i,m} = q_{i,m}(z_{i,m})\dot{x}_{i,m}]$, 其中 $q_{i,m}(z_{i,m}) = \frac{e^{z_{i,m}} + e^{-z_{i,m}} + 2}{b_{m1} + b_{m2}}$, 综合 $\dot{z}_{i,m}$ 与 $q_{i,m}(z_{i,m})$ 的计算式可以得到系统模型转换见式 (8):

$$\begin{cases} \dot{z}_{i,m} = F_{i,m}(\bar{z}_{i,m}, z_{i,m+1}) + z_{i,m+1} \\ \dot{z}_{i,n} = F_{i,n}(\bar{z}_{i,n}) + q_{i,n}(z_{i,n})G_{i,n}(\bar{z}_{i,n})u_i \\ y_{zi} = z_{i,1}, m = 1, \dots, n-1 \end{cases} \quad (8)$$

研究基于非线性映射技术, 可以将原本受到状态约束的系统转化为一个不用考虑状态限制的非线性系统。关键在于需要确保所引入的状态变量 $z_{i,m}$ 保持有界, 这样原系统的状态变量 $x_{i,m}$ 便可保持在预定的约束范围内。因此, 控制任务的核心转变为转换后的系统设计有限时间跟踪算法, 即开发一种一致性跟踪控制器, 以确保系统输出 y_{zi} 能在有限时间内跟随预定的运动轨迹, 同时确保闭环系统的稳定性。

1.2 基于 RBF 神经网络-全状态与输入约束下信息系统跟踪算法

研究主要集中于探讨系统的具体控制问题, 而忽视了对系统中的输入约束问题进行分析。但在现实世界的许多应用场景中, 系统中的输入饱和约束同样可以被看作一种普遍存在的重要限制^[22]。鉴于此, 研究进一步对信息系统的跟踪与控制问题进行分析。与常规的反馈控制策略不同, 研究将涉及范围更广泛的非线性系统与实验内容相结合。研究引入双曲正切函数来有效

处理并应对系统的输入饱和问题。对于系统中的未求解非线性函数, 则必须采用 RBF 神经网络进行精确估计计算; 进一步利用非线性映射方法等于系统中受限的状态变量变换为没有受到约束的新型无约束变量; 再与反步法与动态面技术进行结合, 构建一种分布式自适应跟踪控制算法, 该算法不仅考虑了输入和全状态约束, 还巧妙地避免了“微分爆炸”问题的产生^[23]。通过对所构建方法下系统运行的稳定性进行分析, 可以有效确保并控制系统所产生的具体输出、实时状态以及变量变化范围等参数。考虑了一组构建较为全面的多智能体信息系统, 这些系统由一个领导者和多个跟随者组成。这种系统结构在实际应用中非常普遍, 例如在无人机群协同控制、机器人协作任务执行以及智能交通系统中的车辆编队控制等领域^[24]。通过研究提出的控制策略, 可以有效地实现多智能体系统在复杂环境下的一致性跟踪控制, 同时确保系统的稳定性和性能。系统框架见式 (9):


$$\begin{cases} x_{i,m} = f_{i,m}(\bar{x}_{i,m}, x_{i,m+1}) + d_{i,m}(t), m = 1, \dots, n-1 \\ x_{i,n} = f_{i,n}[\bar{x}_{i,n}, u_i(v_i)] + d_{i,n}(t) \\ y_i = x_{i,1} \end{cases} \quad (9)$$

式中, $\bar{x}_{i,m}$ 为系统的状态; $x_{i,m}$ 则为系统的输出。 $d_{i,m}(t)$ 与 m 则表示有外部干扰并且 $d_{i,m}(t)$ 的绝对值小于等于 $\bar{d}_{i,m}$; $d_{i,m}(t)$ 则表示具有饱和特性的第 i 个跟随者的输入, 具体计算见式 (10):

$$\text{sat}(v_i) = u_i(v_i) = \begin{cases} \text{sgn}(v_i)U_N, & |v_i| \geq U_N \\ v_i, & |v_i| < U_N \end{cases} \quad (10)$$

式中, $\text{sat}(\cdot)$ 代表饱和函数; U_N 代表饱和约束界限; v_i 代表所设计的控制器的输入。研究的控制目标是为了确保跟随者的输出与预定轨迹保持一致性, 并且信息闭环系统能够维持稳定。在信息系统的设计和实现过程中, 即使存在输入饱和等限制条件, 系统也必须确保所有状态变量和输出值能够稳定在既定的约束范围 $\Omega_{x_{i,m}}$ 内, 该集合中 b_{m1} 与 b_{m2} 均为已知的正常数^[25]。这不仅关系到系统的稳定性和可靠性, 也是确保系统能够在各种运行条件下正常工作的关键。针对存在输入约束和全状态约束的非仿射纯反馈多智能体系统, 研究采用双曲正切函数和中值定理对输入饱和问题进行解决。随后, 为了简化智能系统控制器的设计, 通过引入一种非线性映射函数, 将原本受到全状态约束的非仿射高阶系统转化为状态不受约束的仿射系统。在此基础上, 针对控制方向已知与未知的两种情况, 分别开发了相应的系统跟踪算法, 另外对系统的稳定性进行了一定的分析。得到的饱和函数与双曲正切函数的关系如图 3 所示。

由图 3 可知, 如果 $|v_i| = U_N$, 在信息系统中, 由于系统的复杂性和不确定性, 必然会存在一些连续但不

图 3 饱和函数 $\text{sat}(v)$ 与双曲正切函数的关系

可导的分段点。这些分段点的存在给系统的控制设计带来了一定的挑战。为了后续研究能够直接利用反步法对高阶系统的输入展开控制与设计,研究采用了双曲正切函数对系统的饱和函数进行优化,以有效地解决分段点所带来的负面影响,提高系统的控制性能。定义一个 $P_i(v_i)$ 作为连续函数对双曲正切函数进行近似处理,得到处理后的连续函数与系统输入计算见式 (11):

$$\begin{cases} P_i(v_i) = U_N \tanh\left(\frac{v_i}{U_N}\right) \\ u_i(v_i) = \text{sat}(v_i) = P_i(v_i) + q_i(v_i) \end{cases} \quad (11)$$

式中, $q_i(v_i)$ 为近似误差,该误差的值是一个有界函数。系统在运行时,必须满足其界限值计算见式 (12):

$$|q_i(v_i)| = |\text{sat}(v_i) - P_i(v_i)| \leq U_N(1 - \tanh(1)) = \bar{q}_i \quad (12)$$

从式 (12) 可以看出, $\bar{q}_i$ 随着 $|v_i|$ 的增加,从 0 上升至达到饱和约束的上限 U_N ; 相反地, $\bar{q}_i$ 随着 $|v_i|$ 的减少,从饱和约束的上限 $\bar{q}_i$ 下降至下限 0。结合中值定理,有一个取值范围在 (0, 1) 范围内的常数,可以得到连续函数的计算见式 (13):

$$P_i(v_i) = \left\| P_i(v_i^0) + \frac{\partial P_i(v_i)}{\partial v_i} \right\| v_i = v_i^{\mu_i}(v_i - v_i^0) \quad (13)$$

为了进一步分析,实验采用领导-跟随架构的信息系统进行验证,并且为了实现一致性控制方法,将跟随者与领导者之间的通信设置为单向,跟随者之间可以进行双向通信。这意味着跟随者能够接收来自信息系统中邻居的相关状态与信息,而信息系统中领导者则无法依赖于跟随者的状态与信息。当对信息系统进行有限时间跟踪控制时,如果涉及领导者期望轨迹的变动,那么对系统进行控制则仅需要部分跟随者的信息即可。通过对信息系统进行连续有界的跟踪控制,最终可以有效减少传感器的需求量,并降低系统运行的成本,最终简化控制器的设计过程,并且提高信息系统控制器的稳定

性^[26-27]。基于连续函数 $P_i(v_i)$ 的计算,得到 $\frac{\partial P_i(v_i)}{\partial v_i} = 1 - \tanh(v_i/U_N)^2$, 当 v_i 趋近于无限大时, $\frac{\partial P_i(v_i)}{\partial v_i}$

便趋近于 0。假设上述所有计算与方程均合理且成立,那么在信息系统控制方向已知的情况下,为了有效解决输入饱和与全状态约束控制的问题,利用双曲正切函数与 NM 对系统模型进行转换,得到改进后系统的方程见式 (14):

$$\begin{cases} \dot{x}_{i,m} = f_{i,m}(\bar{x}_{i,m}, x_{i,m+1}) + d_{i,m}(t) \\ \dot{x}_{i,n} = f_{i,n}(\bar{x}_{i,n}, 0) + g_{i,n}(P_{i,0}v_i + q_i(v_i)) + d_{i,n}(t) \\ y_i = x_{i,1} \end{cases} \quad (14)$$

将所提出方法拓展到智能信息系统中,实现对全状态约束的控制。其中涉及系统状态变量,它们将具有约束的系统状态变量转换为新的不受任何约束的系统状态变量,并以此不断更新。给定非线性映射函数的定义为 $M(b_{m1}, b_{m2}, x_{i,m})$, 其中 b_{m1} 与 b_{m2} 均为正常数,引入一个新的变量 $z_{i,m}$ 到非线性映射函数的定义当中可以得到 $x_{i,m} = \frac{b_{m2}e^{z_{i,m}} - b_{m1}}{e^{z_{i,m}} + 1}$; 由于 $m = 1, \dots, n$, 继而得到

$\dot{z}_{i,m} = h_{i,m}(z_{i,m})\dot{x}_{i,m} \left[h_{i,m}(z_{i,m}) = \frac{e^{z_{i,m}} + e^{-z_{i,m}} + 2}{b_{m1} + b_{m2}} \right]$ 。将 $\dot{z}_{i,m}$ 与 $h_{i,m}(z_{i,m})$ 相互结合,可以对系统进行再一次的转换,得到新的系统模型见式 (15):

$$\begin{cases} \dot{z}_{i,m} = F_{i,m} + z_{i,m+1} + h_{i,m}d_{i,m} \\ \dot{z}_{i,n} = F_{i,n} + h_{i,n}G_{i,n}[P_{i,0}v_i + q_i(v_i)] + h_{i,n}d_{i,n}(t) \\ \hat{y}_i = z_{i,1} \end{cases} \quad (15)$$

研究利用非线性映射和双曲正切函数,将具有全状态和输入约束的原始系统转化为一个状态不受任何约束的系统。通过分析,可以发现只要系统状态保持 $z_{i,m}$ 有界,就可以确保原始系统 $x_{i,m}$ 的状态保持在所期望的集合 $\Omega_{x_{i,m}}$ 中。因此,控制任务的关键在于设计出能够使系统输出跟踪预定轨迹 y_d 并确保闭环系统稳定性的控制算法。

2 信息系统有限时间跟踪控制方法的性能测试与应用效果分析

为了对研究所构建的智能信息系统有限时间跟踪控制算法(命名为 RBF-LTTC, radial basis function network-limited time tracking control)的性能进行验证,选取基于自适应神经网络的一类非线性系统(命名为 RBFNN)^[28]、基于全局自适应神经网络的非线性系统控制方法(RBF-PTC, radial basis function network-predefined time control method)^[29]、基于径向基函数神经网络和傅里叶级数的非线性系统跟踪控制方法

(RBF-FS, radial basis function network-fourier series)^[30]与研究所构建方法进行对比。由于信息系统的多样性和复杂性,研究采用了一个通用的非线性动态系统模型来代表一类典型的智能信息系统。为了避免性能验证过程中主观因素与客观因素带来的偶然误差,对实验仿真环境与参数进行设置,具体参数见表 1。

表 1 相关参数设置

项目	参数/型号
处理器	Intel(R) Core(TM) i7-9700K CPU @ 3.60 GHz
数据分析平台	R Studio 1.4.1104
数据存储	PostgreSQL 12
模拟工具	AnyLogic 8.12.3
仿真软件	Java 11 OpenJDK
内存	64 GB
操作系统	Ubuntu 20.04 LTS
网络架构	TensorFlow 2.4.1
学习率	0.01
迭代次数	150 次
宽度参数	0.5
时间步长	0.01

选取某信息系统中的有效数据共 5 148 条,经过数据预处理后得到 5 013 条,去除 13 条后,得到 5 000 条实验数据。将得到的数据中的 40%作为验证集,剩余 60%作为训练集进行实验,对 4 种算法在该信息系统中运行时达到稳定控制的耗时进行对比,结果如图 4 所示。




图 4 4 种模型的运行耗时比较

图 4 (a) 为验证集上的运行耗时变化。可以发现,随着系统迭代次数的增加,所有算法的平均运行耗时均呈现出正向的增加。当迭代次数增加至第 50 次时,RBF-LTTC 方法的平均运行耗时开始趋向稳定,数值一直处在 4.32 s。而 RBF-FS 方法、RBF-PTC 方法与 RBFNN 方法的平均运行耗时均处于上升的状态,并分别在 71、64 与 74 次开始朝着稳定的方向发展。3 种方法的平均运行耗时均较 RBF-LTTC 方法大。图 4 (b) 为训练集上的运行耗时变化。当算法的平均耗时最小时,RBF-LTTC 方法的迭代次数靠近于 66 次,对应平均运行耗时的时间为 6.11 s。而 RBF-FS 方法、RBF-PTC 方法与 RBFNN 方法的平均运行耗时达到稳定的状态时,迭代分别对应为 77、41 与 67 次。相比于 RBF-LTTC 方法的迭代次数较少,但运行的时间均大于 6.0 s;并且上升的速率较 RBF-LTTC 方法快。以上结果说明,RBF-LTTC 方法的运行耗时最短,说明该方法在实现有限时间跟踪控制时有较高的效率,可以确保系统在有限的时间内达到预定的跟踪控制目标。对比 4 种算法运行下信息系统的稳定性,结果如图 5 所示。




图 5 系统的稳定性测试结果

图 5 (a) 为系统运行稳定性的变化。可以看出,在初始阶段 4 种算法运行下,系统可能需要经过一定的时间来达到稳定的运行状态。当时间趋近于 10.0 s 时,RBF-LTTC 方法运行下系统逐渐进入一个稳定运行的阶段,此时系统的偏差较小,运行稳定性高于 90%。其余 3 种方法下的运行稳定性虽然一直处于变化状态,并且稳定性大于 70%,但一直小于 RBF-LTTC 方法。图 5 (b) 为系统控制稳定性的变化。随着时间的增加,

4 种算法均处于均匀上升的状态。当时间达到 35 s 时, RBF-LTTC 方法运行下系统控制稳定性达到峰值, 并趋近于 100%, 这表明控制策略在这些时刻最为有效。而其他方法的控制稳定性一直小于 RBF-LTTC 方法, 这可能与外部干扰、系统参数的变化有关。综上可知, RBF-LTTC 方法运行下系统的稳定性随着时间的推移而增高, 这为进一步的系统优化和控制策略的改进提供了有价值的信息。为了验证研究所提出的改进跟踪算法对系统状态约束的有效性, 实验将研究所提出的有限时间跟踪控制算法与不具备任何约束的跟踪控制算法进行对比, 将两种算法应用于某非线性信息系统中分析实验所构建方法的具体应用效果。考虑一个智能体系统, 其由一个领导者与 4 个跟随智能体所构成。假设 X_1 、 X_2 为该智能体的状态, U 为输入, Y 则为系统的输出。对比不同控制器下智能体两种状态的表现, 结果如图 6 所示。




图 6 有约束与无约束条件下智能体两种状态 X_1 、 X_2 的表现

图 6 (a) 为系统 X_1 状态的变化。可以看出, 在有约束条件下, 智能体状态 X_1 可能因为受到一定的限制, 对应曲线表现出较小的波动幅度, 并且变化速度也较慢。相比之下, 在无约束条件下, 智能体状态 X_1 的曲线变化表现得更为自由, 并且曲线的波动幅度也较大, 变化速度也较为快速。图 6 (b) 为系统 X_2 状态的变化。智能体状态 X_2 的曲线变化与 X_1 十分相似, 但具体的波动幅度与变化的速度有所不同, 并且在无约束条件下, 系统状态变化的曲线与变化范围更为宽泛。通过一系列的仿真实验, 结果表明, 在实验所构建的 RBF-LTTC 方法运行下, 智能体系统的所有表现状态

都可以稳定地保持在期望的输出范围内, 显示出较强的抗干扰能力。这一结果验证了所提出方法的有效性和鲁棒性, 为智能信息系统的控制设计提供了有力的支持。对比在有限时间与非有限时间控制下智能体两种状态下的运行误差变化, 结果如图 7 所示。




图 7 在有限时间与非有限时间控制下智能体两种状态下的误差变化

图 7 (a) 为系统 X_1 状态下的误差。可以看出, 在有限时间控制策略下, 智能体状态 X_1 的误差可以更快地缩小在一个较小的值, 并且在有限时间内误差的变化较小。这表明有限时间控制策略能够有效地实现快速且精准地跟踪。与非有限时间控制策略相比, 误差的减小可能需要更多的时间来使得误差达到一个稳定的状态。图 7 (b) 为系统 X_2 状态下的误差。观察可知, 在有限时间控制策略运行下, 智能体状态 X_2 的误差变化较小, 并且误差的变化保持得更加趋于稳定。结合上述的分析可知, 仿真结果证实了所提出的控制算法能够有效地保障所有系统状态在所期望的约束范围内。此外, 部分误差可以在有限的时间内被有效控制, 在接近零的区域内。系统显示出更高的收敛精度和更快的收敛速率, 同时具备出色的抗干扰能力。最后以智能信息系统 X_2 为研究对象, 对 RBF-LTTC 方法运行下, 系统具有约束时 X_2 的跟踪控制轨迹进行分析, 结果如图 8 所示。

图 8 中可以看出, 当系统满足初始运行状态的要求时, 在智能信息系统的运行过程中, RBF-LTTC 算法能够确保所有状态变量和系统输出在运行过程中不仅维持在预定的约束范围内, 而且展现出良好的稳定性。这种稳定性对于智能信息系统的长期运行至关重要, 因为




图 8 RBF-LTTC 方法运行下, 具有约束时对智能体状态 X_2 的跟踪控制轨迹

它直接影响到系统的可靠性和效率。进一步观察可以发现, 即使在面对动态变化的外部环境和内部扰动时, RBF-LTTC 方法依然能够实现对智能体状态 X_2 的精确跟踪。这表明该方法具有较强的鲁棒性, 能够在不确定因素存在的情况下, 保持对控制目标的有效跟踪。这一特性对于确保系统的稳定性和可靠性至关重要, 也是设计系统时所需要重点考虑的问题。

3 结束语

为了提升智能信息系统的运转稳定性, 研究提出一种结合 RBF 网络与有限时间控制的方法。将 RBF 与全状态约束下的信息系统相结合, 引入有限时间跟踪控制策略, 降低智能信息系统控制器设计的复杂程度; 并利用双曲正切函数简化信息系统控制器的设计流程, 最终实现对信息系统的有效控制。数据显示, 在验证集与训练集上, 当迭代次数分别迭代至第 50 次与第 66 次时, 研究所构建方法的平均运行耗时分别对应为 4.32 s 与 6.11 s。随着系统运行时间的推移, 当时间趋近于 10.0 s 时, 研究所构建方法的运行稳定性高于 90%; 另外当运行时间达到 35 s 时, 研究所构建方法运行下对系统的控制稳定性趋近于 100%。无论信息系统处于有约束条件还是有限时间条件内, 系统曲线的波动均较小, 并且误差数值也较小。以上结果说明所提出方法能够在保证系统稳定性的同时, 实现对动态目标跟踪的误差也较小, 具有较强的工程应用价值。但现实中, 信息系统所受到的实际约束是有限制的, 对系统受到的不同限制进行分析将会是未来的重点研究方向。

参考文献:

- [1] 董 显, 魏万鹏. 基于 RBF 神经网络 PID 控制的列车 ATO 系统优化 [J]. 电子测量与仪器学报, 2021, 35 (1): 103 - 109.
- [2] LIU L, ZHAO W, LIU Y J, et al. Adaptive finite-time neural network control of nonlinear systems with multiple objective constraints and application to electromechanical system [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32 (12): 5416 - 5426.
- [3] LIU Y J, ZHAO W, LIU L, et al. Adaptive neural network control for a class of nonlinear systems with function constraints on states [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 34 (6): 2732 - 2741.
- [4] 马 东, 董力元, 王立玲, 等. 移动机器人 RBF 神经网络自适应 PD 跟踪控制 [J]. 控制工程, 2020, 27 (12): 2092 - 2098.
- [5] SUN J, HE H, YI J, et al. Finite-time command-filtered composite adaptive neural control of uncertain nonlinear systems [J]. IEEE Transactions on Cybernetics, 2020, 52 (7): 6809 - 6821.
- [6] CUI Q, SONG Y. Tracking control of unknown and constrained nonlinear systems via neural networks with implicit weight and activation learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32 (12): 5427 - 5434.
- [7] 黄小龙, 陈阳舟. 高阶非线性不确定多智能体系统自适应 RBF 神经网络协同控制 [J]. 北京工业大学学报, 2020, 46 (9): 1008 - 1017.
- [8] LIU L, GAO T, LIU Y J, et al. Time-varying asymmetrical BLFs based adaptive finite-time neural control of nonlinear systems with full state constraints [J]. IEEE/CAA Journal of Automatica Sinica, 2020, 7 (5): 1335 - 1343.
- [9] TONG D, LIU X, CHEN Q, et al. Observer-based adaptive finite-time prescribed performance NN control for non-strict-feedback nonlinear systems [J]. Neural Computing and Applications, 2022, 34 (15): 12789 - 12805.
- [10] XU F, TANG D, WANG S. Research on parallel nonlinear control system of PD and RBF neural network based on U model [J]. Automatika, 2020, 61 (2): 284 - 294.
- [11] WANG J, YAN Y, LIU Z, et al. Neural network-based event-triggered finite-time control of uncertain nonlinear systems with full-state constraints and actuator failures [J]. International Journal of Robust and Nonlinear Control, 2023, 33 (3): 1683 - 1703.
- [12] 姜海洋, 陈 明. 严格反馈非线性系统有限时间模糊漏斗控制 [J]. 控制工程, 2020, 27 (12): 2137 - 2142.
- [13] YUAN X, CHEN B, LIN C. Neural adaptive fixed-time control for nonlinear systems with full-state constraints [J]. IEEE Transactions on Cybernetics, 2021, 53 (5): 3048 - 3059.
- [14] 赵 岩, 周秦源, 邵念锋, 等. 基于 RBF 神经网络模糊 PID 控制的电液伺服系统 [J]. 机电工程, 2022, 39

- (2): 244–249.
- [15] 陈 军, 姜卫东. 改进 RBF 神经网络的机械臂轨迹跟踪控制方法 [J]. 机械设计与制造, 2022 (12): 269–272.
- [16] ZHANG Y, WANG F, ZHANG J. Adaptive finite-time tracking control for output-constrained nonlinear systems with non-strict-feedback structure [J]. International Journal of Adaptive Control and Signal Processing, 2020, 34 (4): 560–574.
- [17] 李 磊, 任 元, 陈晓岑, 等. 基于 ADRC 和 RBF 神经网络的 MSCSG 控制系统设计 [J]. 北京航空航天大学学报, 2020, 46 (10): 1966–1972.
- [18] SHANG Y, CHEN B, LIN C. Fast finite-time adaptive neural control of multi-agent systems [J]. Journal of the Franklin Institute, 2020, 357 (15): 10432–10452.
- [19] GAO S, JING Y, LIU X, et al. Chebyshev neural network-based attitude-tracking control for rigid spacecraft with finite-time convergence [J]. International Journal of Control, 2021, 94 (10): 2712–2729.
- [20] 潘陈志, 夏 晗, 冯加章. 基于数字孪生的电力系统自动化管理系统的研究 [J]. 自动化应用, 2023, 64 (20): 64–66.
- [21] ZHU X, HUANG J, DING W, et al. Finite-time command filter-based adaptive tracking control for nonstrict feedback nonlinear systems with full-state restrictions and unmodeled dynamics [J]. Asian Journal of Control, 2023, 25 (4): 3192–3207.
- [22] CUI D, WU Y, XIANG Z. Finite-time adaptive fault-tolerant tracking control for nonlinear switched systems with dynamic uncertainties [J]. International Journal of Robust and Nonlinear Control, 2021, 31 (8): 2976–2992.
- [23] FEI J, CHEN Y, LIU L, et al. Fuzzy multiple hidden layer recurrent neural control of nonlinear system using terminal sliding-mode controller [J]. IEEE Transactions on Cybernetics, 2021, 52 (9): 9519–9534.
- [24] 朱威汉. 基于卷积神经网络的机械臂抓取控制系统设计 [J]. 计算机测量与控制, 2023, 31 (11): 181–186.
- [25] GUO C, XIE X J, HOU Z G. Removing feasibility conditions on adaptive neural tracking control of nonlinear time-delay systems with time-varying powers, input, and full-state constraints [J]. IEEE Transactions on Cybernetics, 2020, 52 (4): 2553–2564.
- [26] LU W. Finite-time adaptive neural control for nonlinear systems under state-dependent sensor attacks [J]. International Journal of Robust and Nonlinear Control, 2021, 31 (10): 4689–4704.
- [27] 杨 婧, 宋 强, 石云辉. 一种基于机器学习的电力能耗异常检测与预测的方法 [J]. 微型电脑应用, 2023, 39 (11): 190–193.
- [28] 刘德玉, 邹坤霖, 贺力克. 一类 MIMO 非线性系统的自适应神经网络鲁棒跟踪控制 [J]. 计算机应用与软件, 2022, 39 (11): 66–72.
- [29] ZHANG Y, NIU B, ZHAO X, et al. Global predefined-time adaptive neural network control for disturbed pure-feedback nonlinear systems with zero tracking error [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 34 (9): 6328–6338.
- [30] 吴 健, 孙永波, 赵前进. 基于神经网络的周期扰动非线性系统自适应渐近跟踪控制 [J]. 控制与决策, 2022, 37 (4): 922–932.
- [26] HUANG Q, ZHOU K, YOU S, et al. Learning to prune filters in convolutional neural networks [C] // 2018 IEEE Winter Conference on Applications of Computer Vision, IEEE, 2018: 709–718.
- [27] MOLCHANOV P, MALLYA A, TYREE S, et al. Importance estimation for neural network pruning [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 11264–11272.
- [28] LIU Z, LI J, SHEN Z, et al. Learning efficient convolutional networks through network slimming [C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 2736–2744.
- [29] FANG G, MA X, SONG M, et al. Depgraph: towards any structural pruning [C] // Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Piscataway: IEEE, 2023: 16091–16101.

(上接第 119 页)

- [22] HACENE G B, LASSANCE C, GRIPON V, et al. Attention based pruning for shift networks [C] // 2020 25th International Conference on Pattern Recognition (ICPR). IEEE, 2021: 4054–4061.
- [23] WANG A, CHEN H, LIU L, et al. Yolov10: Real-time end-to-end object detection [J]. Advances in Neural Information Processing Systems, 2024, 37 (1): 107984–108011.
- [24] HE K, GKIOXARI G, DOLLAR P, et al. Mask r-CNN [C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961–2969.
- [25] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2980–2988.