arXiv:2302.04042v1 [math.OC] 8 Feb 2023

使用神经规范控制结构实现数据驱动控制与迁移学习*

Lukas Ecker[1] 和 Markus Sch¨oberl[1]

摘要——本文提出一种间接数据驱动控制与迁移学习方法，该方法基于利用神经规范控制结构实现的数据驱动反馈线性化。通过人工神经网络自编码器结构，对记录的传感器数据进行训练，以近似布鲁诺夫斯基标准形中采样系统的辨识所需的状态变换和输入变换。所辨识的变换与设计好的轨迹控制器可迁移至参数有所变化的系统，并利用新采集的记录数据调整神经网络权重。本文通过一个学术示例和一个受工业应用启发的示例展示了所提出的方法。

I. 引言

近年来，数据驱动控制和迁移学习已成为控制工业系统的有前景的技术，见 [11]。数据驱动控制分为直接方法和间接方法，见 [9], ：直接数据驱动控制直接根据数据推导控制算法，而间接数据驱动控制则根据数据确定模型，再以该模型为基础设计控制算法。迁移学习是一种技术，可以将在一项任务上训练的模型或控制器加以调整，并用于另一项相关任务，如 [2]所示的机器人场景。这些数据驱动方法的基本目标，是减少依赖模型的控制方法所需的建模工作量。一种非常流行且高度依赖精确模型的非线性控制方法是反馈线性化，参见 [8]。不过，反馈线性化在完全基于数据的场景中也受到关注，例如见 [16], ，其中线性化控制律由两个人工神经网络进行函数逼近 [14]。近期相关研究还包括： [6], 提出了在Koopman算子框架下实现反馈线性化的数据驱动方法；[15],提出了一种基于强化学习的反馈线性化方法；[17], 则引入了利用非线性自回归移动平均模型进行线性化的方法。在 [10], 中，研究者采用一种经过修改的神经自编码器结构进行辨识，将非线性动力学嵌入更高维的线性Koopman框架。 [1]提出了一种利用Willems基本引理处理可反馈线性化系统的数据驱动方法。

本文提出了一种间接数据驱动反馈线性化方法，其中规范控制形式所需的变换由人工神经网络自编码器结构实现。通过采用记录数据集所定义的采样时间，对离散时间布鲁诺夫斯基形式进行近似，可免去准连续实现的需要。对变换进行函数逼近后，便形成一种间接方法，使得模型能够与针对布鲁诺夫斯基系统设计的控制器结合进行离线验证。此外，随时可以基于新采集的传感器数据验证模型，这对于时变系统颇具价值。离散时间布鲁诺夫斯基形式具有移位寄存器链这一固有特征，其结构便于直接规划和稳定期望轨迹。当控制器迁移至非标称系统时，可利用新采集的记录数据调整反馈线性化的神经网络权重，直至重新建立布鲁诺夫斯基行为。

除了一个非线性学术示例外，本文提出的数据驱动控制策略还通过仿真在一对弹性单立柱堆垛起重机上进行了验证，这类起重机应用于工业环境中的物料搬运和仓储。值得注意的是，已有多种基于模型的控制器和观测器策略，例如 [5] 和 [13]。与上述参考文献不同，本文考虑的是不带起升单元的单桅杆堆垛起重机线性模型。然而，要为一系列能够应对机械变化和扰动、同时保持高水平控制性能且无需人工调整的起重机设计控制器，仍颇具挑战。本文提出的策略旨在克服这一挑战：先在一台标称单立柱堆垛起重机上训练控制模型，再将所学控制策略迁移到存在偏差的设备上。随后，利用新采集的传感器数据对控制器进行调整，直至设备达到与标称设备相似的行为。

本文结构安排如下：第 2 节的问题陈述介绍了控制策略和数据驱动框架的构想。第 3 节从控制理论视角讨论了该任务，第 4 节则阐述了数据驱动控制与迁移学习的设置，以及神经规范控制结构的实现和训练。第 5 节通过一项学术案例研究，以及一项以单桅杆堆垛起重机为应用背景的工业案例，展示了数据驱动控制器设计方法的结果。

*本研究得到由奥地利联邦政府和上奥地利州州政府资助的林茨机电一体化中心（LCM）COMET-K2中心支持。

[1]Lukas Ecker 和 Markus Sch¨oberl 任职于奥地利林茨 A-4040 Altenberger Str.69 的林茨约翰内斯·开普勒大学自动控制与控制系统技术研究所（电子邮箱：{lukas.ecker,markus.schoeberl}@jku.at）

II. 问题陈述

本文讨论了控制问题及其在数据驱动框架中的实现，并探讨了迁移学习。

A. 控制策略

所提出的控制器设计旨在将所研究的系统表示为规范控制形式，并应用线性控制理论方法来抑制扰动和实现轨迹稳定。控制器结构由内环和外环控制组成。内环采用反馈线性化，通过状态和输入变换将模型转换为等效的布鲁诺夫斯基标准形线性控制系统，见 [8],。外环控制回路基于内环得到的线性规范控制系统，用于跟踪控制和扰动抑制。外环控制器根据布鲁诺夫斯基结构设计，而内环中的反馈线性化则根据历史传感器数据推导，而非基于数学模型。采用采样数据的数据驱动方法自然会得到离散时间系统的反馈线性化，如 [7] 和 [12]所述。结合线性化变换数据驱动近似的控制策略具有多项优势，包括目标轨迹的计算简单、在存在扰动和参数变化时仍能保证稳定性和性能，以及通过采用外部线性控制器，将标称系统的相似行为迁移到偏离系统。

B. 数据驱动控制与迁移学习

主要目标是在减少数学建模和控制器设计工作量的同时，使控制模型能够自适应并迁移到其他非标称系统。此外，还应保持相似的控制特性和行为。本文提出的间接内环数据驱动反馈线性化方法，利用历史传感器数据逼近转换至布鲁诺夫斯基标准形的变换。与例如 [16] 中直接逼近线性化控制律的方法不同，此处分别学习状态变换和输入变换，从而实现对采样数据系统的数据驱动辨识。因此，这种间接方法将连续时间物理过程 $\dot{x} = f_c(x,\ u)$ 近似为离散时间系统

$$x_{k+1} = f_d(x_k, u_k), \tag{1}$$

其中，k 表示时间索引，即 $x(kT_a) = x_k$，采样时间 T_a 由记录的传感器数据定义。由状态 $x_k \in \mathcal{D}_x \subset \mathbb{R}^n$、输入 $u_k \in \mathcal{D}_u \subset \mathbb{R}$和状态转移映射 (1) 定义的后继状态，简写为 $x_k^+ = x_{k+1} = f_d(x_k,\ u_k)$。数据驱动建模方法使用先前记录的实验中状态$\mathcal{X} = \{x_i\}_{i=0}^{N_s}$、输入 $\mathcal{U} = \{u_i\}_{i=0}^{N_s}$和后继状态 $\mathcal{X}^+ = \{x_i^+\}_{i=0}^{N_s}$ 的 N_s 个样本。叠加的外环轨迹控制器并非根据数据推导得出，而是基于布鲁诺夫斯基系统，采用线性控制理论中的方法（例如极点配置）进行设计。当控制模型迁移到非标称

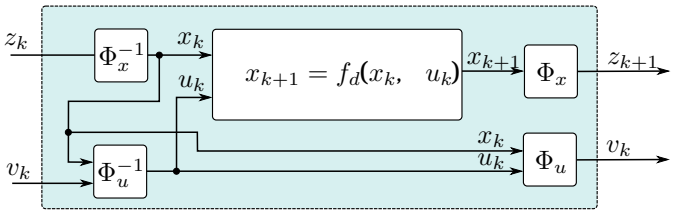


图 1. 根据式 (2) 将采样数据系统转换为布鲁诺夫斯基标准形的示意图。

系统时，必须重新调整变换，以维持内环中的布鲁诺夫斯基形式。利用迁移后系统在标称控制器作用下获取的数据集，将标称网络适配到修改后的系统。

III. 控制结构与策略

本节回顾非线性控制理论中的相关思想，以便将系统变换为布鲁诺夫斯基标准形，并概述生成期望轨迹和设计外环控制器所用的方法。

A. 布鲁诺夫斯基标准形中的变换

考虑通过适当的状态变换 $z_k = \Phi_x(x_k) : \mathcal{D}_x \to \Phi_x(\mathcal{D}_x)$ 和输入变换 $v_k = \Phi_u(x_k,\ u_k) : \mathcal{D}_x \times \mathcal{D}_u \to \Phi_u(\mathcal{D}_x, \mathcal{D}_u)$，将系统变换为

$$z_{k+1} = \Phi_x \circ f_d(\Phi_x^{-1}(z_k), \Phi_u^{-1}(\Phi_x^{-1}(z_k), v_k)) \tag{2}$$

具有新状态 $z_k \in \Phi_x(\mathcal{D}_x)$ 的布鲁诺夫斯基标准形线性离散时间系统

$$z_{k+1} = \begin{bmatrix} 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \\ 0 & 0 & 0 & 0 \end{bmatrix} z_k + \begin{bmatrix} 0 \\ \vdots \\ 0 \\ 1 \end{bmatrix} v_k. \tag{3}$$

图 1 示意性地展示了这种变换。请注意，本文提出的方法侧重于输入状态可线性化情形，其中 $\dim(z_k) = \dim(x_k) = n$，且为单输入系统 $\dim(u_k) = 1$。与连续时间情形不同，布鲁诺夫斯基形式在连续时间情形下对应于积分器链，而在离散时间情形下，其行为等价于移位寄存器，因此简称为$z_{k+1} = A_B z_k + b_B v_k = \sigma(z_k, v_k)$。由于变换满足双射假设，原坐标下的系统 $x_{k+1} = f_d(x_k,\ u_k)$ 可通过规范移位系统及这些变换表示为

$$x_{k+1} = \Phi_x^{-1} \circ \sigma(\Phi_x(x_k), \Phi_u(x_k, u_k)). \tag{4}$$

该方程的示意性解释见图2。由于布鲁诺夫斯基结构由状态 z_k的维数唯一确定，因此近似原系统时只需确定变换 Φ_x和 Φ_u 。这些变换的存在性可通过分布检验来确认，参见 [12] 算法 14.2；随后确定变换需要求解一组常微分方程。所提出的方法旨在通过以下方式克服这一难题：

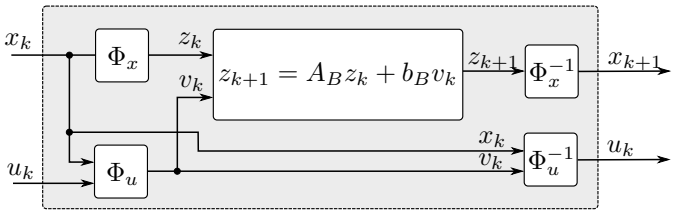


图2. 根据式（4），将采样数据系统表示为布鲁诺夫斯基标准型中的变换后线性系统。

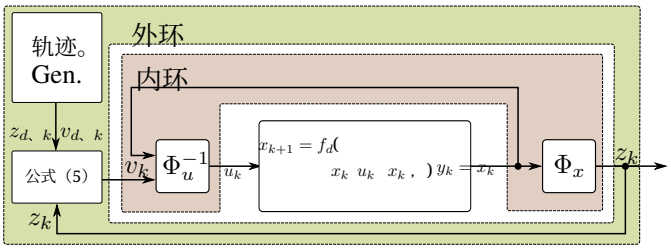


图 3. 采用内层变换为布鲁诺夫斯基规范形以及外部轨迹控制器的控制策略示意图。

将这些变换实现为神经网络，并利用历史传感器数据对其进行训练。此举旨在使原系统呈现布鲁诺夫斯基系统的行为。后续的轨迹规划和外环控制器无需以解析形式表示这些变换，将其实现为神经网络即可满足要求。

B. 轨迹规划

对于工作点从初始位置 x_0 变为最终位置 x_N 、并在 N 个采样步数内完成的目标变化，需在布鲁诺夫斯基坐标中规划轨迹。为此，利用状态参数化确定初始坐标和目标坐标 $z_0 = \Phi_x(x_0)$ 及$z_N = \Phi_x(x_N)$。第一个布鲁诺夫斯基状态 $y_1(k)$ 采用一种$y_{d,\ 1}(k) = \lambda(k)^T\alpha$ 系数线性相关的参数化方法$\alpha \in \mathbb{R}^{n_\alpha}$。参数 $\lambda(k)^T = [\lambda_1(k) \ldots, \lambda_{n_\alpha}(k)]$，其中$\lambda_i \in \mathbb{R}$ 必须满足初始条件和终止条件。选择了一个关于 lambda 的多项式方法，其中 $\lambda(k)^T = [1, k, \ldots, k^{n_\alpha}]$且 $n_\alpha = 2n - 1$ 。由于布鲁诺夫斯基系统具有移位寄存器结构，其余布鲁诺夫斯基状态由 $y_{d,\ i}(k) = \lambda(k + i - 1)^T\alpha$ 对于$i = 1, \ldots, n$ 确定，因此

$$z_d(k) = \begin{bmatrix} y_{d,1}(k) \\ \vdots \\ y_{d,n}(k) \end{bmatrix} = \begin{bmatrix} \lambda(k)^T \\ \vdots \\ \lambda(k+n-1)^T \end{bmatrix} \alpha = \mathcal{S}(k)\alpha.$$

未知系数 α 可通过求解边界条件的线性方程组确定

$$\begin{bmatrix} z_0 \\ z_N \end{bmatrix} = \begin{bmatrix} z_d(0) \\ z_d(N) \end{bmatrix} = \begin{bmatrix} \mathcal{S}(0) \\ \mathcal{S}(N) \end{bmatrix} \alpha.$$

目标输入定义为 $v_d(k) = \lambda(k + n)^T\alpha$。

C. 外环控制器

针对布鲁诺夫斯基系统设计外环控制器，旨在使误差动态呈指数稳定

$$\begin{bmatrix} e_{1,k+1} \\ \vdots \\ e_{n,k+1} \end{bmatrix} = \begin{bmatrix} 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \\ -a_0 & -a_1 & \cdots & -a_{n-1} \end{bmatrix} \begin{bmatrix} e_{1,k} \\ \vdots \\ e_{n,k} \end{bmatrix}$$

对于轨迹误差 $e_1 = y_1 - y_{1,\ d}$ 以及第 III-B 节中的期望目标轨迹。相应的控制律可推导为

$$v_k = -[a_0, \ldots, a_{n-1}] \cdot (z_k - z_{d,k}) + v_{d,k} \qquad (5)$$

系数 a_j、 $j = 0, \ldots, n - 1$选取适当。系数对应于误差动态的特征多项式，可通过极点配置等方法确定。图 3 展示了分为内环和外环的整体控制框图。

IV. 神经规范控制结构

与其费力地从数学模型推导出变换 Φ_x 和 Φ_u ，不如将它们定义为人工神经网络，并利用记录的传感器数据进行训练。根据主要优化问题，该变换应尽可能准确地近似图2中示意定义的系统

$$\begin{aligned} \min_{\Phi_x, \Phi_x^{-1}, \Phi_u, \Phi_u - 1} \quad & \|x^+ - \Phi_x^{-1} \circ \sigma(\Phi_x(x), \Phi_u(x,u))\| \\ \text{s.t.} \quad & x = \Phi_x^{-1}(\cdot) \circ \Phi_x(x) \\ & u = \Phi_u^{-1}(x, \cdot) \circ \Phi_u(x,u) \\ & x \in \mathcal{D}_x, \quad u \in \mathcal{D}_u. \end{aligned}$$

变换的可逆性对设计至关重要，否则，无法将系统表示为规范布鲁诺夫斯基形式，也无法实现反馈线性化。在将变换实现为神经网络时，也必须考虑这一点。一种方案是将 Φ_x 实现为解析可逆的神经网络，但这会将该方法限制在使用可逆激活函数、每层单元数恒定 n_l的情形，并且只适用于维数满足 $\dim(x_k) = \dim(z_k)$ 的输入状态可线性化情形。虽然这并不违背既定假设，但如此一来，就无法按计划将这种数据驱动控制方法扩展到离散时间情形下的平坦系统，参见 [3] 和 [4], 。因此， Φ_x 和 Φ_u 以及 Φ_x^{-1}和Φ_u^{-1}分别由独立的人工神经网络实现。如图2所示，这项任务类似于学习一种自编码器结构，其中 Φ_x、 Φ_u 作为编码器，Φ_x^{-1}、 Φ_u^{-1}作为解码器；编码后的布鲁诺夫斯基状态经布鲁诺夫斯基系统（3）移位后，再解码回原始坐标。除了实现较高的预测精度外，还必须确保两个变换 $x = \Phi_x^{-1}(\cdot) \circ \Phi_x(x)$ 和 $u = \Phi_u^{-1}(x, \cdot) \circ \Phi_u(x, u)$ 满足可逆性约束。与自编码器的常见做法相同，参见 [10], ，通过在代价函数中将这些约束与预测损失一并作为惩罚项加入，来实现这一点。这些变换通过前馈人工神经网络进行函数逼近。第五节中的数值结果采用了一个

具有单个隐藏层的网络拓扑和非线性激活函数 $\phi(s) = [\phi_1(s_1), \ldots, \phi_{n_l}(s_{n_l})]^T \in \mathbb{R}^{n_l}$，$s_i \in \mathbb{R}$。因此，这些变换被近似为

$$\hat{\Phi}(x_k; W_{\hat{\Phi},i}, b_{\hat{\Phi},i}) = W_{\hat{\Phi},2}\phi(W_{\hat{\Phi},1}x_k + b_{\hat{\Phi},1}) + b_{\hat{\Phi},2} \quad (6)$$

待优化的参数包括权重 $W_{\hat{\Phi},1} \in \mathbb{R}^{n_l \times n}$，$W_{\hat{\Phi},2} \in \mathbb{R}^{n \times n_l}$ 和偏置 $b_{\hat{\Phi},1} \in \mathbb{R}^{n_l}$，$b_{\hat{\Phi},2} \in \mathbb{R}^{n}$。用于训练自编码器结构的完整损失函数可综合表示为

$$L = \alpha_1 L_{\text{rec},x} + \alpha_2 L_{\text{rec},u} + \alpha_3 (L_{\text{pred},1} + L_{\text{pred},2})$$

其中包含状态重构损失 (7)、输入重构损失 (8)、预测损失 (9) 和 (10)，以及超参数 α_1，α_2，$\alpha_3 \in \mathbb{R}$。

$$L_{\text{rec},x} = ||x - \Phi_x^{-1} \circ \Phi_x(x)||_{\text{MSE}} \quad (7)$$
$$L_{\text{rec},u} = ||u - \Phi_u^{-1} \circ (x, \Phi_u(x,u))||_{\text{MSE}} \quad (8)$$
$$L_{\text{pred},1} = ||x^+ - \Phi_x^{-1} \circ \sigma(\Phi(x), \Phi_u(x,u))||_{\text{MSE}} \quad (9)$$
$$L_{\text{pred},2} = ||\Phi_x(x^+) - \sigma(\Phi(x), \Phi_u(x,u))||_{\text{MSE}} \quad (10)$$

V. 实验结果

所提出的间接数据驱动方法通过两个示例进行演示。第一个示例（V-A）研究一个学术领域中的三维非线性系统。通过比较预测和重构性能，展示该方法的基本能力。第二个示例（V-B）展示该方法在一个结合轨迹控制与迁移学习的工业应用场景中的表现。自编码器结构使用开源机器学习框架 PyTorch 和 Adam优化算法进行训练。

A. 学术示例

将所提出的数据驱动方法应用于一个三维非线性学术示例

$$x_{k+1} = \begin{bmatrix} \frac{x_{2,k}}{x_{1,k}+2} \\ \frac{x_{2,k}x_{3,k}}{x_{1,k}+2} + 2x_{3,k} \\ \frac{u_{1,k}}{x_{2,k}+2} \end{bmatrix}, \quad (11)$$

根据 [7] 中的理论，该示例可通过静态反馈实现精确线性化。根据式（6），使用 Sigmoid 激活函数 $\phi_i(s_i) = \frac{1}{1+e^{-s_i}}$，$s_i \in \mathbb{R}$ 以及$n_l = 80$ 个隐藏层单元，对反馈线性化变换进行近似。使用 $N_S = 50000$ 个随机初始化轨迹和随机输入信号记录的样本训练神经网络。图4展示了经过 10000 训练轮次后验证集的预测和重构结果。左列显示了具有布鲁诺夫斯基形式内部表示的已辨识系统具有极高的准确度。右列显示了所提出控制策略所需自编码器结构的高重构准确度。此示例旨在展示该算法的基本能力，而非作出定性判断。

未对超参数进行调优，也省略了对不同神经元数量的比较

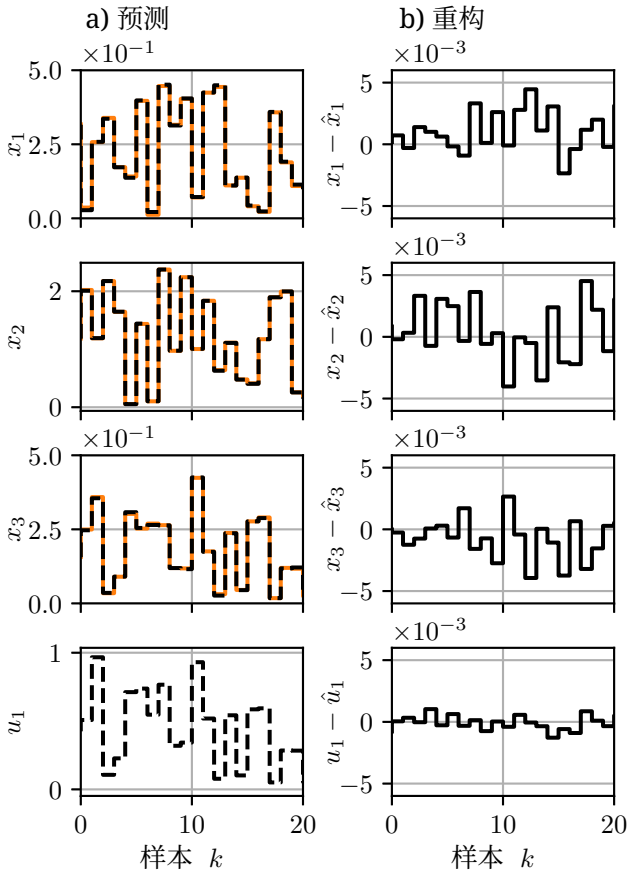


图4. a）预测：采用前馈输入信号和相同初始条件，对比验证轨迹（ ）与辨识模型u_k（ ）。b）重构：验证轨迹 x_k u_k = Φ_u^{-1} x_k Φ_u x_k u_k 与其自编码器重构 $\hat{x}_k = \Phi_x^{-1}(\Phi_x(\,))$ 之间的误差（ ），$\hat{}$(，(，))。

，原因是篇幅有限。尽管如此，在这个学术示例中仍取得了非常好的结果，足以展示该方法的基本性能。

B. 工业应用示例

现以一台不带起升单元的单桅杆堆垛起重机为例，展示数据驱动设计流程。第五节 V-B.1节简要介绍模型。设计流程分为两部分。第一部分如 V-B.2节所述，展示数据驱动控制器的结果，该控制器用于标称起重机 Σ_N，旨在抑制扰动，并使起重机沿规划好的稳定化轨迹运行。第二部分如 V-B.3节所述，展示将标称控制器应用于偏差起重机 Σ_T，以及控制器的迁移学习和自适应。

1) 数学模型：所考虑的不带起升单元的单桅杆堆垛起重机，其主要示意图如图5所示。质量为 m_c 的刚性驱动小车的位置记为 x_c，端部质量 m_h 的水平位置由坐标 x_h表示。忽略起升单元时，该问题可由一个线性常微分方程与偏微分方程系统描述。

表 I 堆垛起重机模型参数。

系统	L / m	m_c / kg	m_h / kg	ρA / kg/m	EI / N m^2
Σ_N	0.53	13.10	0.32	2.10	14.97
Σ_T	0.53	12.72	0.34	2.26	14.28

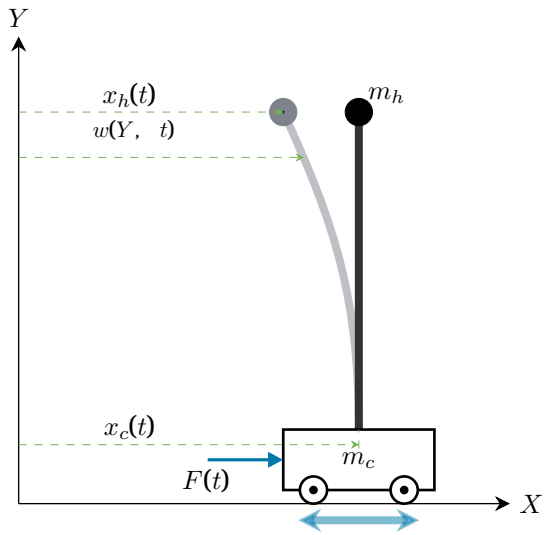


图5. 单桅杆堆垛起重机示意图。

采用变分法推导数学模型的详细过程见 [5] 和 [13]。控制方程包括欧拉-伯努利梁的偏微分方程、驱动单元和端部质量的动量方程，以及边界约束。将梁变形 $w(Y,\ t)$ 近似为一阶瑞利-里茨假设 $w(Y,\ t) = x_c(t) + \Psi(Y)\bar{q}(t)$，并采用适当的空间假设函数 $\Psi(Y)$后，欧拉-拉格朗日方程得到一个具有广义坐标$q = [x_c, \bar{q}]^T$和输入力 $u = F$的有限维机械系统 $M\ddot{q} + Cq = Gu$。其矩阵为

$$M = \begin{bmatrix} m_{11} & m_{12} \\ m_{12} & m_{22} \end{bmatrix},\ C = \begin{bmatrix} 0 \\ c_2 \end{bmatrix},\ \text{and}\ G = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

其中，$m_{11} = \rho AL + m_c + m_h$ $m_{12} = m_h\Psi\ L\ +$、$\rho A\int_0^L \Psi\ Y\ \ Y$ $m_{22} = m_c\Psi\ L\ ^2 + \rho A\int_0^L \Psi\ Y\ ^2\ Y$ ( ) ( )d、( ) ( ) d 和 $c_2 = EI\int_0^L \left(\partial^2\Psi(Y)/\partial Y^2\right)^2 \mathrm{d}Y$，$L$ 表示弹性桅杆的长度，ρA 表示质量密度，EI表示弯曲刚度。该单桅杆堆垛起重机的近似模型作为所提出的数据驱动控制器设计的仿真基准示例。

2）标称控制器：标称系统 Σ_N 的初始控制器设计基于历史传感器数据，这些数据来自约 400 条记录轨迹，包含总体$N_s = 320000$ 个样本，采样时间为 $T_a = 5$毫秒。这些轨迹包括不同工作点的稳定过程、工作点变化，以及在额外随机输入作用下的激励过程；每种情况下均采用简单的 PD 控制律。再次使用了 Sigmoid 激活函数，隐藏层中包含$n_l = 120$ 个神经元。训练得到的

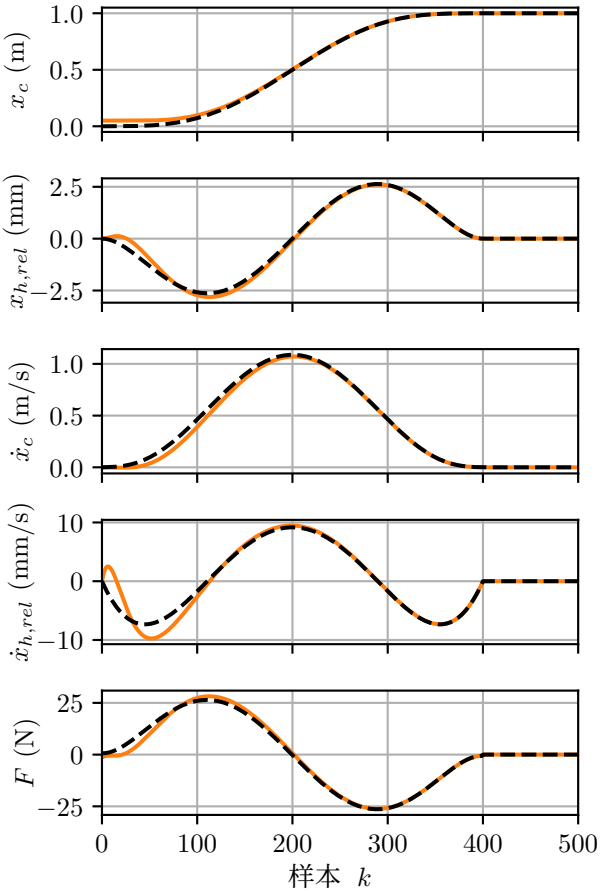


图6. 受控标称系统 Σ_N ( ) 的状态和输入轨迹与期望轨迹 ( ) 的对比。

标称系统 Σ_N 的控制器结果如图 6 所示。图中展示了一条按照第 III-B 节所述流程规划的轨迹：工作点从$x_{c,\ 0} = 0$米变为 $x_{c,\ N} = 1$ 米，整个过程持续 $N = 400$ 个样本，初始定位误差为 0。1 米。初始轨迹误差由稳定外环控制器进行校正，其误差动态极点经过调节，幅值小于 1。通过误差动态，可以轻松调整系统行为。

3）迁移控制器：目标起重机 Σ_T 的参数列于表 I 中。除桅杆长度外，参数偏差均在标称起重机的 $\pm 10\%$ 范围内。将标称控制器应用于目标起重机 Σ_T，其目标与标称起重机相同，即将运行位置从 $x_{c,\ 0} = 0$ m 改变为 $x_{c,\ N} = 1$m。图7展示了参数变化后的起重机 Σ_T 与标称起重机 Σ_N 的状态轨迹。与标称情况相比，控制误差显著增大，而且在给定的参数组合下还出现了不期望的振荡行为。尽管如此，控制器仍成功实现了所需的位置变化。为提高性能，我们采集了使用标称控制器进行的 50 次实验的传感器数据，并用其调整自编码器结构的神经网络权重。迁移学习过程后的结果也显示在图 7中。标称控制器与

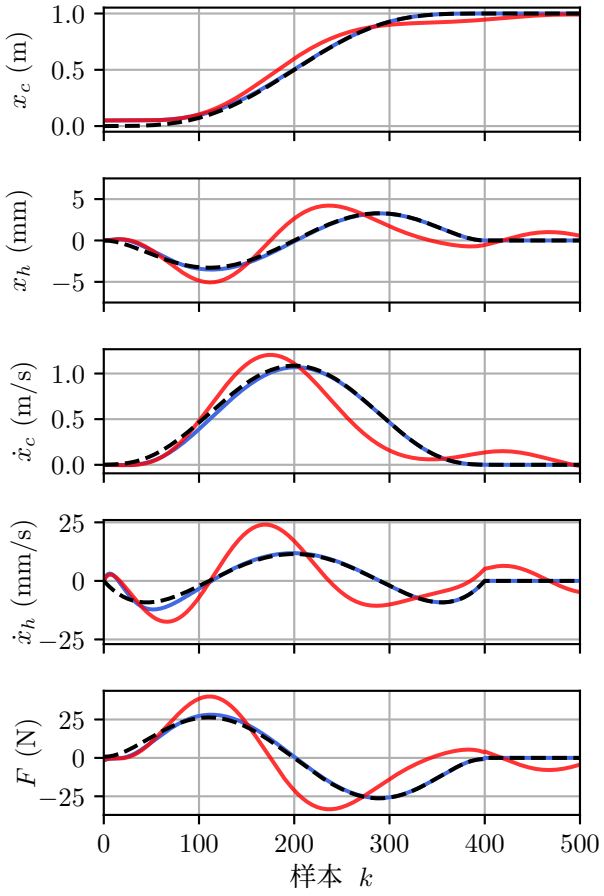


图7. 起重机 Σ_T 上标称控制器的状态和输入轨迹对比（）、控制器学习适应新起重机后的结果（）以及期望轨迹（）。

起重机 Σ_T 上的调优控制器相比，性能有了显著改善。调整后的控制器表现与标称控制器相似，引入的振荡也得到了抑制。不过，目标轨迹相对于标称目标轨迹的细微偏差，是由自编码器结构的调整造成的；这当然也会略微改变目标轨迹。

VI. 结论与展望

本文提出了一种数据驱动控制与迁移学习方法，并通过两个示例进行了验证。其思路是训练一个神经自编码器结构，以布鲁诺夫斯基标准结构表示原始系统，然后应用线性控制理论中的标准控制器设计方法。研究通过对一对单桅杆堆垛起重机进行仿真验证了该设计：先在一台标称起重机上学习标称控制器，再将其迁移到一台结构相同但参数有所改变的起重机上。基于间接数据驱动反馈线性化及由此得到的离散时间布鲁诺夫斯基形式，研究为工作点变化规划并稳定了轨迹。经过重新学习阶段后，迁移控制器能够提升性能并减少人工调整的需求，甚至可以抑制出现的振动。关于未来工作，本文作者指出了若干值得探索的方向，例如将该方法扩展到配备起升单元、构成多输入多输出系统的单桅杆堆垛起重机。在此背景下，研究思路是学习多维标准结构的表示。为此，需要根据历史传感器数据推导移位寄存器链的长度，以避免将链长作为额外的超参数。此外，$\dim(z_k) = \dim(x_k)$这一假设使该方法局限于输入状态可线性化系统；若允许$\dim(z_k) > \dim(x_k)$，则可将其扩展到平坦系统的辨识。同样，作者还计划研究不同及改进的神经网络结构，以加快并改进训练过程，例如纳入先验模型信息，或绕过自编码器的变换约束。

参考文献

[1] M. Alsalti、J. Berberich、V. G. Lopez、F. Allg¨ower 和 M. A. M¨uller，“平坦非线性系统的数据驱动系统分析与控制”，*2021年第60届IEEE决策与控制会议（CDC）*，第1484–1489页，2021年。[2] S. Barrett、M. E. Taylor 和 P. Stone，“在物理机器人上进行强化学习的迁移学习”，载于自适应智能体与多智能体系统，2010年。[3] J. Diwold、B. Kolar 和 M. Sch¨oberl，“门式起重机的离散时间基于平坦性的控制”，《控制工程实践》，第119卷，2022年2月。[4] ——，“离散时间平坦性的基于轨迹的方法”，《*IEEE*控制系统快报》，第6卷，第289–294页，2022年。[5] L. Ecker、T. Malzer、A. Wahrburg 和 M. Sch¨oberl，“单桅杆堆垛起重机的观测器设计”，《自动化技术》，第69卷，第9期，第806–816页，2021年。[6] D. Gadginmath、V. Krishnan 和 F. Pasqualetti，“使用Koopman生成元的数据驱动反馈线性化”，2022年。[7] J. W. Grizzle，“离散时间系统的反馈线性化”，载于《系统分析与优化》。Springer Berlin Heidelberg，1986年，第273–281页。[8] A. Isidori，《非线性控制系统》，通信与控制工程丛书。Springer London，1995年。[9] V. Krishnan 和 F. Pasqualetti，“论直接与间接数据驱动预测控制”，2021年12月，第736–741页。[10] B. Lusch、J. Kutz 和 S. Brunton，“用于非线性动力学通用线性嵌入的深度学习”，《自然·通讯》，第9卷，2018年11月。[11] B. Maschler 和 M. Weyrich，“工业自动化的深度迁移学习：数据驱动机器学习新技术的综述与讨论”，《*IEEE*工业电子杂志》，第15卷，第2期，第65–75页，2021年。[12] H. Nijmeijer 和 A. Schaft, van der，《非线性动态控制系统》，第2版修正版。Springer，1991年。[13] H. Rams、M. Sch¨oberl 和 K. Schlacher，“单桅杆堆垛起重机的最优运动规划与基于能量的控制”，《*IEEE*控制系统技术汇刊》，第26卷，第4期，第1449–1457页，2018年。[14] J. A. K. Suykens、J. Vandewalle 和 B. D. Moor，“用于非线性系统建模与控制的人工神经网络”，1995年。[15] T. Westenbroek、D. Fridovich-Keil、E. Mazumdar、S. Arora、V. Prabhu、S. S. Sastry 和 C. J. Tomlin，“通过强化学习实现不确定系统的反馈线性化”，载于*2020年IEEE*机器人与自动化国际会议（*ICRA*）。IEEE，2020年，第1364–1371页。[16] A. Yes¸ildirek 和 F. Lewis，“使用神经网络实现反馈线性化”，《自动化》，第31卷，第11期，第1659–1664页，1995年。[17] S. ´zAhin，“使用人工神经网络学习反馈线性化”，神经过程快报，第44卷，第3期，第625–637页，2016年12月。