中国科学: 信息科学 2024 年 第 54 卷 第 7 期: 1752–1774
SCIENTIA SINICA Informationis
《中国科学》杂志社
SCIENCE CHINA PRESS

论文

基于知识迁移的数据驱动迭代学习模型预测控制

马乐乐[1], 刘向杰[1*], 高福荣[2]

1. 华北电力大学控制与计算机工程学院, 北京 102206
2. 香港科技大学化学与生物分子工程学系, 香港 999077
* 通信作者. E-mail: liuxj@ncepu.edu.cn

收稿日期: 2023–09–22; 修回日期: 2023–11–30; 接受日期: 2024–01–18; 网络出版日期: 2024–07–05

国家自然科学基金 (批准号: 62203170, 62073163)、国家重点研发计划 (批准号: 2021YFE0190900) 和中央高校基本科研业务费专项资金 (批准号: 2023JC002, 2023YQ002) 资助项目

摘要 迭代学习模型预测控制 (iterative learning model predictive control, ILMPC) 作为一种广泛应用于批次生产过程的数据驱动智能控制策略, 能够在沿批次逐步提高跟踪性能的同时沿时间不断抑制实时干扰. 现有 ILMPC 算法的点对点学习机制依赖于批次运行工况的强一致性, 以此保证当前批次与历史批次间的有效信息传递. 然而, 生产需求和生产环境的变化通常会导致各批次的操作轨迹和操作周期存在差异, 从而使得历史批次提供的先验知识对于后续批次呈现出不精确性和不完整性. 为了提高 ILMPC 在变运行工况条件下的适应性和灵活性, 本文提出了一种具有知识迁移机制的数据驱动 ILMPC 策略. 建立自适应深度神经网络 (deep neural network, DNN) 沿批次学习 ILMPC 控制行为, 实现历史控制经验在当前批次工况下的全面转换. 为抑制 DNN 前期估计误差的影响, 在知识迁移机制下进一步构建 Tube 控制结构下的 ILMPC 算法, 保证 ILMPC 系统的时域稳定性和迭代域收敛性. 针对非线性注塑过程的仿真实验验证了在操作轨迹和操作周期同时变化时, 所提方法在跟踪精度和收敛速度方面具有明显优势.

关键词 迭代学习模型预测控制, 知识迁移, 数据驱动, 变运行工况

1 引言

迭代学习模型预测控制 (iterative learning model predictive control, ILMPC) 作为一种二维 (two-dimensional, 2D) 智能控制策略, 近年来在批次工业控制领域受到广泛关注 [1~6]. 批次生产过程通常按照固定生产流程进行重复操作, 随批次不断累积的控制经验可用于在后续批次修正控制信号. ILMPC 的迭代学习控制 (iterative learning control, ILC) [7~9] 结构可以通过挖掘批次过程数据中蕴含的先验知识沿批次逐步提高系统跟踪性能. 此外, ILMPC 时域上采用的模型预测控制 (model predictive control, MPC) [10~13] 滚动优化机制能够增强系统的抗实时干扰能力, 保证时域稳定性.

引用格式: 马乐乐, 刘向杰, 高福荣. 基于知识迁移的数据驱动迭代学习模型预测控制. 中国科学: 信息科学, 2024, 54: 1752–1774, doi: 10.1360/SSI-2023-0279
Ma L L, Liu X J, Gao F R. Data-driven iterative learning model predictive control based on knowledge transfer (in Chinese). Sci Sin Inform, 2024, 54: 1752–1774, doi: 10.1360/SSI-2023-0279

© 2024《中国科学》杂志社

历经二十几年的发展, ILMPC 理论已在非线性系统控制[14,15]、受扰系统控制[16]、不确定性系统控制[17] 等方面取得系列成果. 然而, ILMPC 的点对点学习机制要求各次重复操作的运行工况具有强一致性, 限制了 ILMPC 策略在实际工业环境下的推广和应用. 实际批次生产过程的实时优化 (real time optimization, RTO) 层会根据产品类型、规格及环境扰动等变化同时改变操作轨迹和操作周期[18,19], 这导致基于原始参考轨迹的先验知识对于后续批次而言呈现出不精确性和不完整性. 当新参考轨迹明显偏离原始参考轨迹时, 经典 ILMPC 需要重置迭代学习过程, 造成了学习过程的停滞甚至回退.

在过去十几年间, ILC 领域涌现了许多针对非重复工况问题的解决方案, 其主要思想是将 ILC 与鲁棒控制技术或自适应控制技术结合以提高系统对变化运行工况的适应能力. 针对变操作轨迹问题, 文献 [20] 最早针对离散高阶系统提出一种自适应 ILC 策略, 利用递归最小二乘算法直接结合参考轨迹变化信息设计显式的 ILC 学习律. 基于相似的控制结构, ILC 领域学者进一步设计了一系列改进自适应 ILC 学习律用于数据驱动非线性系统[21]、二维线性 Fornasini-Marchesini 系统[22], 以及二阶非线性系统[23]. 不同于上述的参数化 ILC 策略, 文献 [24] 针对线性随机系统构建了一种基于状态空间模型的最优 ILC 策略, 通过迭代域/时域的 Kalman 滤波实现了变参考轨迹下的迭代状态估计. 针对初始状态偏移这一特殊问题, 文献 [25] 在 ILC 中引入一类修正函数使得参考轨迹向前推移一段时间, 以补偿初始状态的错位. 上述的自适应 ILC 方案均需要显式表达控制律, 因此无法直接推广到具有隐式学习律的有约束 ILMPC 算法中. 文献 [26,27] 将参考轨迹变化视作 ILMPC 系统的二维扰动, 通过引入 H_∞ 控制技术来抑制参考轨迹变化对系统跟踪精度的影响, 首次在有约束 ILMPC 框架下实现了对变参考轨迹的全区间高精度跟踪.

针对变操作周期问题, 文献 [28~30] 初步设计了一种静态补偿方法, 以零值填补各批次的缺失数据, 从而将各批次调整至相同长度. 文献 [31~34] 将用于补偿的零值替换为各批次的终端值, 从而避免了数据陡变导致的跟踪波动. 为改善补偿精度, 文献 [35~37] 进一步提出了动态补偿方案, 采用基于过程模型的预测值填补各批次缺失数据, 实现了数据填补精度的提升. 不同于数据填补这种直接解决方案, 改进学习结构也是一种在变操作周期下推进学习进程的有效手段. 文献 [38] 构建了一种基于指示器的新型学习结构, 使得 ILC 仅从距离最近的具有相当操作周期长度的批次学习控制经验. 文献 [36] 设计了一种基于事件切换的学习结构, 根据相邻批次的长度关系确定学习阶次, 从而实现先验知识最优性和准确性间的平衡. 然而, 已有的研究成果仅能单独解决变操作轨迹或变操作周期问题, 无法在两种问题同时存在时保证沿迭代方向的学习效率和沿时间方向的跟踪精度, 由操作工况变化导致的跟踪偏离将会持续多个批次甚至将造成控制信号发散.

当各生产批次间存在操作轨迹和操作周期差异时, 由于系统动态和时间尺度不匹配, 历史批次的运行数据不能直接应用于当前批次的 ILMPC 控制律更新. 因此, 需要将历史运行数据中包含的先验知识转化为与当前批次工况相适应的形式. 深度神经网络 (deep neural network, DNN) 具有突出的非线性函数逼近能力[39,40], 可以用来实现先验知识在批次间的全区间迁移. 利用 ILMPC 的控制行为数据和被控系统的反馈数据沿批次重复训练 DNN 估计器, 由 DNN 估计器在每个当前批次生成与目标操作轨迹对应的控制参考轨迹, 从而实施 ILMPC 的迭代学习功能. 基于 DNN 估计器修正后的高匹配度先验知识, ILMPC 能够在变运行工况下保持有效的控制律更新, 提高沿批次方向的跟踪误差收敛速度.

批次生产过程的运行数据随批次逐渐累加, 早期批次存在数据量和数据完备度不足的问题[41,42], 会导致 DNN 估计器精度偏低[43]. 为了限制早期批次估计误差对后续批次控制性能的影响, 需要引入干扰抑制机制提高 ILMPC 对 DNN 逼近误差的鲁棒性. Tube 控制策略是一种处理有界干扰的先进技术[44,45], 将其与 ILMPC 融合能够保证控制系统跟踪误差沿批次的有界收敛. 随着批次累加, 历史运

行数据的体量和完备度会逐渐增加, DNN 估计器的精度随之提升, Tube 控制架构的效应会逐渐减弱从而增强 ILMPC 控制的最优性.

因此, 本文针对批次过程变工况导致的历史信息不完整和不准确问题, 构造了一种具有先验知识迁移机制的数据驱动迭代学习模型预测控制策略, 具体创新点体现在以下 3 个方面:

(1) 为处理变运行工况导致的信息不匹配问题, 构造了自适应 DNN 估计器将历史批次蕴含的先验知识迁移至当前批次的运行工况下.

(2) 为抑制早期批次 DNN 估计误差较大带来的不利影响, 建立了基于 Tube 的 ILMPC 控制结构将实际跟踪误差限制在预先设定的不变集内.

(3) 基于二维递归可行性结论, 结合 Tube 不变集理论证明了具有先验知识迁移机制的数据驱动 ILMPC 系统沿批次有界收敛.

2 变工况条件下基于 DNN 的先验知识迁移

2.1 变工况问题描述

描述典型非线性批次过程的数学模型为

$$x_k(t+1) = f(x_k(t),\ u_k(t)) + \omega(t), \tag{1}$$

其中 k 表示迭代次序, $t \in [0, T_k)$ 表示运行时间, T_k 表示第 k 次迭代的操作周期 (即批次长度). $x_k(t) \in \mathbb{X}$ 和 $u_k(t) \in \mathbb{U}$ 分别代表第 k 批次 t 时刻 $n_x \times 1$ 维的状态向量和 $n_u \times 1$ 维的控制输入向量, 其中 $\mathbb{X}$ 和 $\mathbb{U}$ 为系统物理约束构成的集合. $f(x_k(t), u_k(t))$ 代表系统的非线性动态, 且满足 Lipschitz 连续性条件. $\omega(t)$ 代表系统的未知重复性扰动. 批次过程 (1) 的控制任务为在当前第 k 批次在时间范围 $(0, T_k]$ 内跟踪参考状态轨迹 $x_k^r(t)$.

定义跟踪误差为

$$x_k^e(t) = x_k(t) - x_k^r(t). \tag{2}$$

将式 (2) 代入式 (1) 可得

$$x_k^e(t+1) = f(x_k^e(t) + x_k^r(t), u_k(t)) + \omega(t) - x_k^r(t+1),\ t \in [0, T_k). \tag{3}$$

经典 ILMPC 利用前一批次的控制经验更新当前批次的控制律, 因而需要显式描述相邻批次间的迭代关系. 根据式 (3), 第 $k-1$ 批次的系统动态可描述为

$$x_{k-1}^e(t+1) = f\left(x_{k-1}^e(t) + x_{k-1}^r(t), u_{k-1}(t)\right) + \omega(t) - x_{k-1}^r(t+1),\ t \in [0, T_{k-1}). \tag{4}$$

当状态参考轨迹 $x_k^r(t)$ 和操作周期 T_k 随批次 k 随机变化时, 会造成 $x_k^r(t) \neq x_{k-1}^r(t)$ 以及 $T_k \neq T_{k-1}$. 因此, 无法由式 (3) 和 (4) 推导出显式的迭代关系, 即前一批次的运行经验无法直接移植到当前批次的运行工况中. 为解决此问题, 必须完成历史批次的先验知识在当前生产条件下的精确转换, 从而有效推进迭代学习的进程. 这要求控制系统能够在每一当前批次通过历史经验学习获得与新状态参考轨迹 $x_k^r(t)$ 相适应的控制参考轨迹 $u_k^r(t)$ $(t \in [0, T_k))$. 为此, 本节建立自适应 DNN 模型沿批次模拟 ILMPC 的控制行为, 生成 ILMPC 在线 2D 优化所需的先验控制参考轨迹 $u_k^r(t)$. 基于 DNN 的先验知识迁移机制与 ILMPC 控制器的关系如图 1 所示.

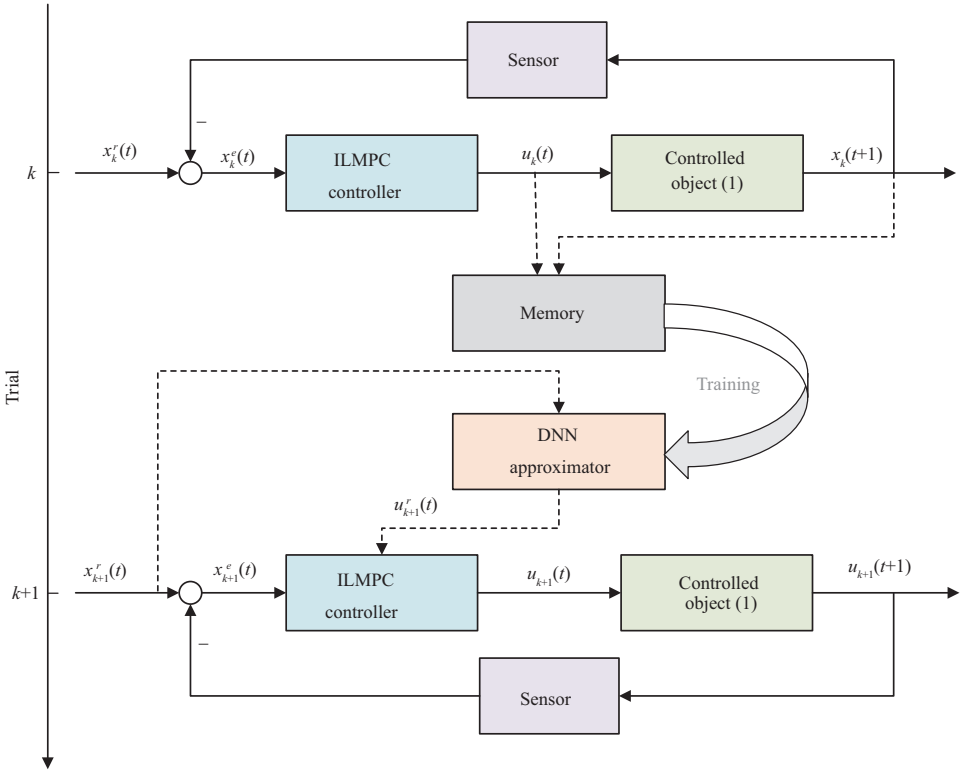

图 1 (网络版彩图) 基于先验知识迁移机制的 ILMPC 构架

Figure 1 (Color online) Scheme of ILMPC based on prior knowledge transfer

2.2 基于 DNN 的先验知识迁移技术

对于确定的批次过程 (1), ILMPC 优化求解得到的控制量取决于系统当前状态和目标状态. 因此, 为模拟 ILMPC 控制行为, 选取 DNN 输入为系统当前状态和次态, 输出为当前控制信号. 实现批次间先验知识迁移的 DNN 网络结构如图 2 所示. 在运行至第 k 批次时, 临近 l 个批次的数据被调用构成输入样本数据 $X_k = [x_i(t)\ \ x_i(t+1)]^{\mathrm{T}}$ 以及输出样本数据 $Y_k{}^* = u_i(t)$, 其中 $i = k-l, k-l+1, \ldots, k-1$, $t = 0, 1, \ldots, T_i - 1$.

第 j 个隐含层的输出 h_j $(j = 1, 2, \ldots, L)$ 表示为

$$h_j = \sigma\left(W_j h_{j-1} + c_j\right), \tag{5}$$

其中 $\sigma(\cdot)$ 为激活函数, W_j 和 c_j 分别为第 $j-1$ 个隐含层和第 j 个隐含层之间的连接权重和偏置.

网络输出表示为

$$Y = N\left(X; \bar{W}\right) = W_o \sigma\left(W_L \sigma\left(W_{L-1} \sigma\left(\cdots\right) + c_{L-1}\right) + c_L\right) + c_o, \tag{6}$$

其中 $\bar{W} = [W_1, c_1, W_2, c_2, \ldots, W_L, c_L, W_o, c_o]$, W_o 和 c_o 分别代表第 L 个隐含层和输出层之间的连接权重和偏置.

为应对批次过程运行数据体量小和非平稳特性, 采用扩展卡尔曼滤波 (extended Kalman filter, EKF) [46] 训练图 2 所示的 DNN 模型. 以第 $k+1$ 批次为例, 在当前批次运行开始前网络权重矩阵 $\bar{W}$

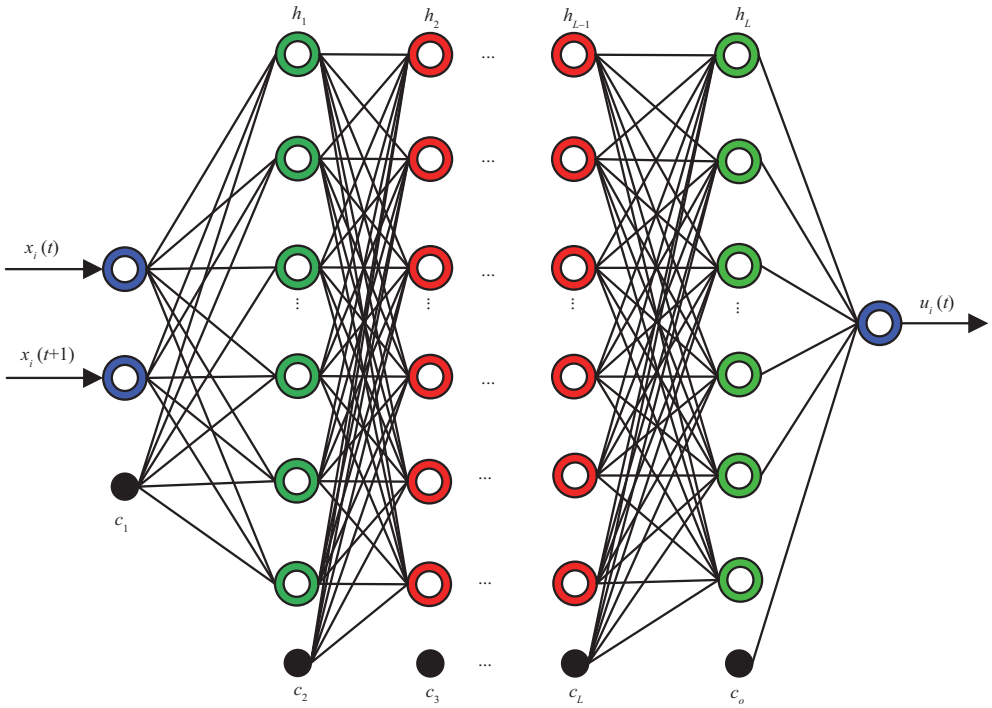

图 2 (网络版彩图) 实现批次间知识迁移的 DNN 网络结构

Figure 2 (Color online) Architecture of DNN for knowledge transfer between batches

通过下式进行自适应更新:

$$\begin{aligned}\bar{W}_{k+1} &= \bar{W}_k - K_k E_k,\\ K_k &= \bar{P}_k J_{Fk}\big(R_{Nk} + {J_{Fk}}^{\mathrm{T}}\bar{P}_k J_{Fk}\big)^{-1},\\ \bar{P}_{k+1} &= Q_{Nk} + \big(1 - K_k {J_{Fk}}^{\mathrm{T}}\big)\bar{P}_k,\end{aligned} \tag{7}$$

其中 K_k 为卡尔曼滤波增益, $\bar{P}_k$ 为估计误差的协方差矩阵, Q_{Nk} 和 $R_{Nk} = r_{Nk}I$ 分别为人工噪声和测量噪声的协方差矩阵, J_{Fk} 表示网络输出 Y_k 对 $\bar{W}_k$ 求导得到的雅可比 (Jacobi) 矩阵, 建模误差 E_k 表示为

$$E_k = Y_k - {Y_k}^*, \tag{8}$$

其中 $Y_k = N\left(X_k; \bar{W}_k\right)$. 协方差矩阵 Q_{Nk} 可通过式 (9) 的最大似然法进行更新以提高网络训练收敛速度:

$$Q_{Nk} = \frac{1}{n_w}\left\{\sum_{j=k-n_w+1}^{k}\left\{\Delta\bar{W}_j\Delta\bar{W}_j^{\mathrm{T}}\right\} + \bar{P}_k - \bar{P}_{k-n_w}\right\}, \tag{9}$$

其中 $\Delta\bar{W}_j = \bar{W}_j - \bar{W}_{j-1}$, n_w 为实施 Q_N 更新的窗口长度.

根据文献 [33] 的定理 1, 当 $\|E_k\| > \sqrt{192\zeta_k}$ 时, 若协方差矩阵 $R_{Nk} = r_{Nk}I$ 中 r_{Nk} 取为

$$r_{Nk} = \frac{1}{2}\left(\frac{3Y_k}{n_o} + \frac{\|E_k\|^2}{64n_o}\right), \tag{10}$$

按照式 (7) 更新的权重矩阵 $\bar{W}_k$ 将沿批次收敛至最优值. 其中, n_o 代表网络输出部分的神经元个数, ζ_k 代表矩阵 $J_{F_k}^{\mathrm{T}}\bar{P}_k J_{Fk}$ 的迹.

将参考状态轨迹输入至训练后的 DNN 模型, 生成近似的控制参考轨迹. 则第 k 批次的控制参考轨迹表达式为

$$\hat{u}_k^r(t) = N\left(x_k^r(t), x_k^r(t+1); \bar{W}_k\right), \tag{11}$$

其中 $\hat{u}_k^r(t)$ 将作为先验控制参考信号加入到 ILMPC 的在线 2D 优化中.

图 2 所示的 DNN 能以任意精度逼近非线性映射关系 [47], 因此必存在上界 ς_k^u 使得控制参考信号的估计误差满足

$$|\hat{u}_k^r(t) - u_k^r(t)| \leqslant \varsigma_k^u, \tag{12}$$

其中符号 $|\cdot|$ 代表取欧几里得范数.

根据 Lipschitz 连续性条件, 可由式 (1) 得

$$|\hat{x}_k^r(t+1) - x_k^r(t+1)| \leqslant \varsigma_k^x, \tag{13}$$

其中,

$$\hat{x}_k^r(t+1) = f\left(x_k^r(t), \hat{u}_k^r(t)\right) + \omega(t), \tag{14}$$

$$x_k^r(t+1) = f\left(x_k^r(t), u_k^r(t)\right) + \omega(t), \tag{15}$$

$$\varsigma_k^x \leqslant L_u \left\|\hat{u}_k^r(t) - u_k^r(t)\right\| \leqslant L_u \varsigma_k^u, \tag{16}$$

L_u 为 Lipschitz 常数.

3 基于先验知识迁移的 Tube ILMPC 策略

早期批次可利用的历史数据较为有限, DNN 估计器的精度通常不足, 会导致估计误差上界 ς_k^u 较大, 严重降低 ILMPC 的收敛性能 [48,49]. 基于式 (12) 和 (13), 可以将 Tube 控制技术融合至 ILMPC 来抑制 DNN 估计误差的影响.

定义 $d_k(t) = \hat{x}_k^r(t+1) - x_k^r(t+1)$. 根据式 (14) 和 (15), 批次过程 (1) 沿批次方向的增量模型可表示为

$$x_k(t+1) = f_a\left(x_k(t), u_k(t)\right) + d_k(t), \tag{17}$$

其中,

$$f_a\left(x_k(t), u_k(t)\right) = x_k^r(t+1) + f_e\left(x_k(t), u_k(t)\right),$$
$$f_e\left(x_k(t), u_k(t)\right) = f\left(x_k(t), u_k(t)\right) - f\left(x_k^r(t), \hat{u}_k^r(t)\right),$$

$|d_k(t)| \leqslant \varsigma_k^x$ 为有界扰动.

系统 (17) 对应的标称模型可描述为

$$z_k(t+1) = f_a\left(z_k(t), v_k(t)\right), \tag{18}$$

其中 $z_k(t)$ 和 $v_k(t)$ 分别代表标称状态和标称输入.

3.1 标称 ILMPC 控制器

基于标称模型 (18), 设计标称 ILMPC 控制器通过滚动时域 2D 优化将标称状态 $z_k(t)$ 驱动至参考状态轨迹 $x_k^r(t)$. 标称控制输入信号 $v_k(t)$ 由 ILC 控制信号 $v_k^{\mathrm{ILC}}(t)$ 和 MPC 控制信号 $v_k^{\mathrm{MPC}}(t)$ 两部分组成, 可表示为

$$v_k(t) = v_k^{\mathrm{ILC}}(t) + v_k^{\mathrm{MPC}}(t). \tag{19}$$

在第 $k-1$ 批次和第 k 批次的运行间隔, 求解以下标称 ILC 优化问题:

$$\begin{aligned} &\min_{\Delta \boldsymbol{v}_k^{\mathrm{ILC}}} \quad J_k^{\mathrm{ILC}} = \left\|\boldsymbol{z}_k^e\right\|_Q^2 + \left\|\Delta \boldsymbol{v}_k^{\mathrm{ILC}}\right\|_R^2 \\ &\text{s.t.} \quad z_k(t+1) = f_a\left(z_k(t), \hat{u}_k^r(t) + \Delta v_k^{\mathrm{ILC}}(t)\right), \end{aligned} \tag{20}$$

其中,

$$\boldsymbol{z}_k^e = \begin{bmatrix} z_k^e(1) \\ z_k^e(2) \\ \vdots \\ z_k^e(T_k) \end{bmatrix} = \begin{bmatrix} z_k(1) - x_k^r(1) \\ z_k(2) - x_k^r(2) \\ \vdots \\ z_k(T_k) - x_k^r(T_k) \end{bmatrix}, \ \Delta \boldsymbol{v}_k^{\mathrm{ILC}} = \begin{bmatrix} v_k^{\mathrm{ILC}}(0) - \hat{u}_k^r(0) \\ v_k^{\mathrm{ILC}}(1) - \hat{u}_k^r(1) \\ \vdots \\ v_k^{\mathrm{ILC}}(T_k - 1) - \hat{u}_k^r(T_k - 1) \end{bmatrix},$$

Q 和 R 为权重矩阵.

在每个采样时刻 t, 求解以下标称 MPC 优化问题:

$$\begin{aligned} &\min_{\boldsymbol{v}_k^{\mathrm{MPC}}|_t^{T_k-1}} \quad J_k^{\mathrm{MPC}}(t) = \left\|\boldsymbol{z}_k^e|_{t+1}^{T_k}\right\|_Q^2 + \left\|\delta \boldsymbol{v}_k|_t^{T_k-1}\right\|_R^2 \\ &\text{s.t.} \quad z_k(t+1) = f_a\left(z_k(t),\ v_k^{\mathrm{ILC}}(t) + v_k^{\mathrm{MPC}}(t)\right), \\ &\qquad v_k \in \mathbb{V},\ z_k \in \mathbb{Z},\ z_k^e(T_k) = 0, \end{aligned} \tag{21}$$

其中,

$$\boldsymbol{z}_k^e|_{t+1}^{T_k} = \begin{bmatrix} z_k^e(t+1) \\ z_k^e(t+2) \\ \vdots \\ z_k^e(T_k) \end{bmatrix} = \begin{bmatrix} z_k(t+1) - x_k^r(t+1) \\ z_k(t+2) - x_k^r(t+2) \\ \vdots \\ z_k(T_k) - x_k^r(T_k) \end{bmatrix}, \ \delta \boldsymbol{v}_k|_t^{T_k-1} = \begin{bmatrix} v_k(t) - v_k(t-1) \\ v_k(t+1) - v_k(t) \\ \vdots \\ v_k(T_k - 1) - v_k(T_k - 2) \end{bmatrix},$$

$\mathbb{V} \subseteq \mathbb{U}$ 和 $\mathbb{Z} \subseteq \mathbb{X}$ 分别为关于标称输入 v 和标称状态 z 的收紧约束.

3.2 辅助控制器

标称 ILMPC 优化 (20) 和 (21) 实现了标称系统跟踪误差的最小化, 并保证了标称系统的时域稳定性. 本小节引入辅助控制器最小化实际系统与标称系统间的偏差, 将实际状态 $x_k(t)$ 限制在标称状态 $z_k(t)$ 附近的 Tube 不变集内. 辅助控制器的优化机制基于以下复合系统:

$$\begin{cases} x_k(t+1) = f_a\left(x_k(t), u_k(t)\right), \\ z_k(t+1) = f_a\left(z_k(t), v_k(t)\right). \end{cases} \tag{22}$$

为抑制实际系统 $x_k(t+1)=f_a(x_k(t),u_k(t))+d_k(t)$ 与标称系统 $z_k(t+1)=f_a(z_k(t),v_k(t))$ 间的偏差, 辅助控制器的优化目标函数定义为

$$J_k^{AU}(t)=\left\|\boldsymbol{x}_k^e|_{t+1}^{T_k}-\boldsymbol{z}_k^e|_{t+1}^{T_k}\right\|_Q^2+\left\|\boldsymbol{u}_k|_t^{T_k-1}-\boldsymbol{v}_k|_t^{T_k-1}\right\|_R^2+V_f(x_k^e(T_k)),\tag{23}$$

其中

$$\boldsymbol{x}_k^e|_{t+1}^{T_k}=\begin{bmatrix}x_k^e(t+1)\\x_k^e(t+2)\\\vdots\\x_k^e(T_k)\end{bmatrix}=\begin{bmatrix}x_k(t+1)-x_k^r(t+1)\\x_k(t+2)-x_k^r(t+2)\\\vdots\\x_k(T_k)-x_k^r(T_k)\end{bmatrix},\quad \boldsymbol{u}_k|_t^{T_k-1}=\begin{bmatrix}u_k(t)\\u_k(t+1)\\\vdots\\u_k(T_k-1)\end{bmatrix},$$

$V_f(x_k^e(T_k))$ 为终端代价函数, 相应的控制不变集表示为 $X_f=\{x_k^e|V_f(x_k^e)\leqslant\alpha\},\alpha>0$, 并对任意 $x_k^e\in X_f$ 满足

$$\begin{gathered}\min_{u_k\in\boldsymbol{U}}\left\{V_f'(f_e(x_k,u_k))+\|x_k^e\|_{Q_1}^2+\|\delta u_k\|_{R_1}^2\,\middle|\,x_k^e\in X_f\right\}\leqslant V_f'(x_k^e),\\V_f=\beta V_f',\ \beta\geqslant 1,\end{gathered}\tag{24}$$

其中 Q_1 和 R_1 分别为矩阵 Q 和 R 在单个时刻对应的对角矩阵子块, 维数分别为 $n_x\times n_x$ 和 $n_u\times n_u$. β 为补偿终端约束损失的常数, δu_k 代表控制输入在相邻采样时刻间的增量.

通过求解以下辅助优化问题, 获得实际控制输入 $u_k(t)$:

$$\min_{\boldsymbol{u}_k|_t^{T_k-1}}\ J_k^{AU}(t)\tag{25}$$

$$\text{s.t.}\quad (22),\ u_k\in\mathbb{U},$$

并将优化变量 $\boldsymbol{u}_k|_t^{T_k-1}$ 中的当前时刻控制信号 $u_k(t)=\varphi(x_k(t),t)$ 施加至被控过程.

综上, 在每个运行批次, 基于先验知识迁移的数据驱动 Tube ILMPC 的算法实施可分为以下离线和在线步骤:

Step 1. 设置 $k=1$ 以及 $t=0$.

离线部分:

Step 2. 根据式 (7), 利用前 l 个批次的历史运行数据更新 DNN 估计器的参数. 基于式 (11) 由更新后的 DNN 估计器生成控制参考信号 $\hat{u}_k^r$.

Step 3. 求解标称 ILC 优化问题 (20) 获得标称 ILC 控制信号 v_k^{ILC}.

Step 4. 求解标称 MPC 优化问题 (21) 获得标称 MPC 控制信号 $v_k^{\mathrm{MPC}}(t)$.

Step 5. 根据式 (19) 计算标称控制信号 $v_k(t)$ 并将其施加于标称系统 (18). 若 $t<T_k-1$, 令 $t=t+1$ 并返回至 Step 4; 否则, 转至在线部分并设置 $t=0$.

在线部分:

Step 6. 求解辅助优化问题 (25) 获得实际控制信号 $u_k(t)$.

Step 7. 将求得的 $u_k(t)$ 施加于实际被控系统 (1). 若 $t<T_k-1$, 令 $t=t+1$ 并返回至 Step 6; 否则, 令 $k=k+1$ 并返回至 Step 2.

4 控制器性能分析

4.1 时域稳定性

ILMPC 系统时域稳定性是保障迭代域收敛性的重要前提, 直接关系到批次过程的产品质量和生产安全. 本文提出的基于知识迁移的数据驱动 ILMPC 策略将 DNN 估计误差视作系统的外部干扰, 可以基于鲁棒 Tube 稳定性理论对 ILMPC 系统的时域稳定性进行深入分析. 对标称系统 (18) 和实际系统 (17) 提出以下合理假设.

假设1 设标称系统 (18) 和实际系统 (17) 满足

(a) 非线性函数 $f_e(\cdot)$ 二阶连续可导;

(b) 状态约束集 $\mathbb{X}$ 和控制约束集 $\mathbb{U}$ 分别是 R^{n_x} 和 R^{n_u} 的紧集;

(c) 由 $|d_k(t)| \leqslant \varsigma_k^x$ 定义的 DNN 估计误差集合 $\mathbb{D}$ 为凸紧集并包含原点;

(d) 目标函数 J_k^{ILC}, $J_k^{\mathrm{MPC}}(t)$ 和 $J_k^{AU}(t)$ 均为正定二次型;

(e) 式 (18) 沿参考轨迹的线性化系统可镇定;

(f) 存在 $b > h \geqslant h^*$ 和 $\beta \geqslant \max\{b/\alpha,\ 1\}$, 其中 $b > 0$, $h \in (0,\ b)$, $h^* = b_3\varsigma_k^x/(1-\gamma)$, $\gamma = 1-b_1/b_2$ (参数 b_1, b_2 和 b_3 的意义可参见文献 [31]);

(g) 存在紧约束集 $\mathbb{Z} \subseteq \mathbb{X}$ 和 $\mathbb{V} \subseteq \mathbb{U}$ 使得对于任意可行初态 $x_k(0)$ 和任意 $t \in [0, T_k]$ 有 $S_k^{h^*}(x_k(t)) \subset \mathbb{X}$ 成立, 其中 $S_k^{h^*}(t) = \left\{x_k \middle| J_k^{AU}(t) \leqslant h^*\right\}$.

定理1 若假设 1 成立, 基于知识迁移的数据驱动 Tube ILMPC 系统是鲁棒稳定的, 即对于任意可行初态 $x_k(0)$, 实际系统 (17) 的状态轨迹和控制轨迹分别保持在状态 Tube 不变集 $\mathbb{T}_k^e = \left\{S_k^h(x_k^e(t)) = \left\{x_k^e \middle| J_k^{AU}(t) \leqslant h\right\}, t \geqslant 0\right\}$ 和控制 Tube 不变集 $\mathbb{T}_k^u = \left\{\varphi\left(S_k^h(x_k(t)), t\right), t \geqslant 0\right\}$ 内.

证明 根据文献 [44] 的推论 1 可以推出, 对于所有 $t \geqslant 0$, $x_k^e(t) \in S_k^b(t) = \left\{x_k^e \middle| J_k^{AU}(t) \leqslant b\right\}$ 以及 $x_k^e(t+1) \in f_e(x_k(t), \varphi(x_k(t), t)) + d_k(t)$, 有下式成立:

$$J_k^{AU}(t+1) \leqslant \gamma J_k^{AU}(t) + b_3\varsigma_k^x. \tag{26}$$

因此, 若存在常数 ε 使得 $b_3\varsigma_k^x + \varepsilon \leqslant (1-\gamma) J_k^{AU}(t)$ 成立, 可得

$$J_k^{AU}(t+1) \leqslant \gamma J_k^{AU}(t) + b_3\varsigma_k^x \leqslant J_k^{AU}(t) - \varepsilon. \tag{27}$$

选取常数 $\varepsilon = 0$, 当 $J_k^{AU}(t) \leqslant h$, $b_3\varsigma_k^x \leqslant (1-\gamma) J_k^{AU}(t) \leqslant (1-\gamma) h$ 时, 可由式 (27) 推导得到以下不等式:

$$J_k^{AU}(t+1) \leqslant J_k^{AU}(t) \leqslant h. \tag{28}$$

因此, 对于实际系统 (17), $\mathbb{T}_k^e$ 和 $\mathbb{T}_k^u$ 分别为状态不变集和控制不变集. 当 DNN 估计误差趋近于零时, 即 $h^* \to 0$, $\mathbb{T}_k^e$ 和 $\mathbb{T}_k^u$ 均将收缩至标称轨迹. 如图 3 所示 (以 $n_x = 2$ 为例), Tube ILMPC 控制下标称跟踪轨迹将保持在收紧约束集中, 相应的实际跟踪轨迹保持在原始约束集中.

4.2 迭代域收敛性

迭代收敛性是评估 ILMPC 系统迭代域闭环性能的关键指标. 基于知识迁移的数据驱动 Tube ILMPC 的收敛性与 DNN 估计器的精度紧密相关. 在早期运行批次, DNN 估计误差的上界 ς_k^u 通常较大, 实际控制输入 $u_k(t)$ 仅能收敛至最优值附近的 Tube 不变集内. 随着批次增长, 运行数据不断累积, DNN 估计误差上界 ς_k^u 逐渐趋近于零, 实际控制输入 $u_k(t)$ 将最终收敛至最优值. 基于 Tube 不

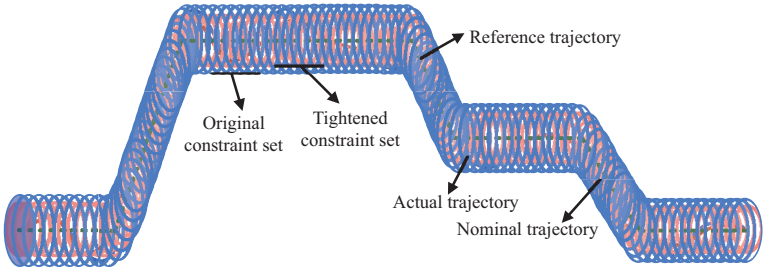

图 3 (网络版彩图) Tube ILMPC 控制下时域跟踪轨迹示意图

Figure 3 (Color online) Tracking trajectories along time under tube-based ILMPC

变集理论和 ILMPC 优化问题的 2D 递归可行性, 基于知识迁移的数据驱动 Tube ILMPC 系统在全批次范围能够实现有界收敛.

定理2 求解优化问题 (20) 和 (21) 获得的标称控制输入 $v_k(t)$ 沿批次收敛至最优值.

证明 $\Delta\boldsymbol{v}_k^{\mathrm{ILC}} = \boldsymbol{0}$ 必为 ILC 优化问题 (20) 的一个可行解. 设第 k 批次的标称 ILC 控制信号为 $\boldsymbol{v}_k^{\mathrm{ILC}*}$, 则有下式成立:

$$J_k^{\mathrm{ILC}}\left(\boldsymbol{v}_k^{\mathrm{ILC}*}\right) \leqslant J_k^{\mathrm{ILC}}\left(\hat{\boldsymbol{u}}_k^r\right), \tag{29}$$

其中 $\hat{\boldsymbol{u}}_k^r = [\hat{u}_k^r(0)\ \ \hat{u}_k^r(1)\ \ \cdots\ \ \hat{u}_k^r(T_k-1)]^{\mathrm{T}}$.

将 $\boldsymbol{v}_k^{\mathrm{ILC}} = \hat{\boldsymbol{u}}_k^r$ 代入式 (20) 可得

$$J_k^{\mathrm{ILC}}\left(\hat{\boldsymbol{u}}_k^r\right) = \left\|\boldsymbol{z}_k^e\left(\hat{\boldsymbol{u}}_k^r\right)\right\|_Q^2. \tag{30}$$

联立式 (20), (29) 和 (30) 可得

$$\left\|\boldsymbol{z}_k^e\left(\boldsymbol{v}_k^{\mathrm{ILC}*}\right)\right\|_Q^2 + \left\|\Delta\boldsymbol{v}_k^{\mathrm{ILC}*}\right\|_R^2 \leqslant \left\|\boldsymbol{z}_k^e\left(\hat{\boldsymbol{u}}_k^r\right)\right\|_Q^2. \tag{31}$$

设 $\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}|_t^{T_k-1}$ 为 MPC 优化问题 (21) 在第 k 批次 t 时刻的最优解, 其相应的目标函数可写作

$$\begin{aligned} J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}\Big|_t^{T_k-1}\right) &= \left\|\boldsymbol{z}_k^e|_{t+1}^{T_k}\left(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}\Big|_t^{T_k-1}\right)\right\|_Q^2 + \left\|\delta\boldsymbol{v}_k|_t^{T_k-1}\right\|_R^2 \\ &= \left\|z_k^e(t+1)\right\|_Q^2 + \left\|\delta v_k(t)\right\|_R^2 + J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}\Big|_{t+1}^{T_k-1}\right), \end{aligned} \tag{32}$$

其中 $J_k^{\mathrm{MPC}}(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}|_{t+1}^{T_k-1}) = \|\boldsymbol{z}_k^e|_{t+2}^{T_k}(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}|_{t+1}^{T_k-1})\|_Q^2 + \|\delta\boldsymbol{v}_k|_{t+1}^{T_k-1}\|_R^2$.

由式 (32) 可进一步推出

$$J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}\Big|_t^{T_k-1}\right) \geqslant \left\|z_k^e(t+1)\right\|_Q^2 + J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}\Big|_{t+1}^{T_k-1}\right). \tag{33}$$

同理, $\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}|_{t+1}^{T_k-1}$ 必为 MPC 优化问题 (21) 在第 k 批次 $t+1$ 时刻的一个可行解. 以 $\boldsymbol{v}_{k,t+1}^{\mathrm{MPC}\,*}|_{t+1}^{T_k-1}$ 代表 $t+1$ 时刻的最优解, 则有下式成立:

$$J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,t+1}^{\mathrm{MPC}\,*}\Big|_{t+1}^{T_k-1}\right) \leqslant J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}\Big|_{t+1}^{T_k-1}\right). \tag{34}$$

联立式 (33) 和 (34) 可得

$$\left\|z_k^e(t+1)\right\|_Q^2 + J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,t+1}^{\mathrm{MPC}\,*}\Big|_{t+1}^{T_k-1}\right) \leqslant J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,t}^{\mathrm{MPC}*}\Big|_t^{T_k-1}\right). \tag{35}$$

由于 $\boldsymbol{v}_k^{\mathrm{MPC}}|_0^{T_k-1}=\mathbf{0}$ 必为 $t=0$ 时刻的可行解, 可得

$$J_k^{\mathrm{MPC}}\left(\boldsymbol{v}_{k,0}^{\mathrm{MPC}^*}\Big|_{t+1}^{T_k-1}\right)\leqslant J_k^{\mathrm{MPC}}(\mathbf{0})=\left\|\boldsymbol{z}_k^e\left(\boldsymbol{v}_k^{\mathrm{ILC}^*}\right)\right\|_Q^2. \tag{36}$$

对式 (35) 和 (36) 进行递归计算可推出

$$\|\boldsymbol{z}_k^e(\boldsymbol{v}_k^*)\|_Q^2\leqslant\left\|\boldsymbol{z}_k^e\left(\boldsymbol{v}_k^{\mathrm{ILC}^*}\right)\right\|_Q^2, \tag{37}$$

其中 $\boldsymbol{v}_k^*=\boldsymbol{v}_k^{\mathrm{ILC}^*}+\boldsymbol{v}_k^{\mathrm{MPC}^*}$ 表示第 k 批次的最优标称控制信号.

联立式 (31) 和 (37) 可得

$$\|\boldsymbol{z}_k^e(\boldsymbol{v}_k^*)\|_Q^2\leqslant\left\|\boldsymbol{z}_k^e\left(\boldsymbol{v}_k^{\mathrm{ILC}^*}\right)\right\|_Q^2\leqslant\|\boldsymbol{z}_k^e(\hat{\boldsymbol{u}}_k^r)\|_Q^2, \tag{38}$$

其中 $\hat{\boldsymbol{u}}_k^r$ 为由历史批次迁移至当前批次的先验知识.

在标称控制系统性能分析中, 由于将干扰项 $d_k(t)$ 视作零, $\|\boldsymbol{z}_k^e(\hat{\boldsymbol{u}}_k^r)\|_Q^2$ 即能代表至第 $k-1$ 批次结束为止系统取得的全部学习成效. 因此, 由式 (38) 可以推出

$$\lim_{k\to\infty}\|\boldsymbol{z}_k^e(\boldsymbol{v}_k^*)\|_Q^2\leqslant\lim_{k\to\infty}\|\boldsymbol{z}_k^e(\hat{\boldsymbol{u}}_k^r)\|_Q^2=\lim_{k\to\infty}\left\|\boldsymbol{z}_k^e\left(\boldsymbol{v}_{k-1}^*\right)\right\|_Q^2, \tag{39}$$

表明 $\|\boldsymbol{z}_k^e(\boldsymbol{v}_k^*)\|_Q^2$ 必存在极限.

对式 (39) 应用夹逼定理可得

$$\lim_{k\to\infty}\left\|\boldsymbol{z}_k^e\left(\boldsymbol{v}_k^{\mathrm{ILC}^*}\right)\right\|_Q^2=\lim_{k\to\infty}\|\boldsymbol{z}_k^e(\boldsymbol{v}_k^*)\|_Q^2=\lim_{k\to\infty}\|\boldsymbol{z}_k^e(\hat{\boldsymbol{u}}_k^r)\|_Q^2. \tag{40}$$

联立式 (31) 和 (40) 有下式成立:

$$\lim_{k\to\infty}\left\|\Delta\boldsymbol{v}_k^{\mathrm{ILC}^*}\right\|_R^2\leqslant\lim_{k\to\infty}\|\boldsymbol{z}_k^e(\hat{\boldsymbol{u}}_k^r)\|_Q^2-\lim_{k\to\infty}\left\|\boldsymbol{z}_k^e\left(\boldsymbol{v}_k^{\mathrm{ILC}^*}\right)\right\|_Q^2=0, \tag{41}$$

其中 $\lim_{k\to\infty}\|\Delta\boldsymbol{v}_k^{\mathrm{ILC}^*}\|_R^2=0$ 表明标称控制信号 $v_k(t)$ 随批次收敛至最优值.

定理3 求解辅助优化问题 (25) 获得的实际控制信号 $u_k(t)$ 随批次收敛至最优值附近的 Tube 不变集.

证明 根据 4.1 小节得出的时域稳定性结论可知, 实际控制信号 $u_k(t)$ 保持在标称控制信号附近的 Tube 不变集 $\mathbb{T}_k^u$ 内. 随着 $v_k(t)$ 逐渐逼近最优值 $v_{k*}(t)$, 实际控制信号 $u_k(t)$ 将收敛至以下 Tube 不变集:

$$\mathbb{T}_{k*}^u=\left\{\varphi\left(S_k^h\left(x_{k*}^e(t)\right),t\right),\ t\geqslant 0\right\}, \tag{42}$$

其中

$$x_{k*}^e(t)\in\mathbb{T}_{k*}^e,\mathbb{T}_{k*}^e=\left\{x_{k*}^e\left|\left\|\boldsymbol{x}_{k*}^e|_{t+1}^{T_k}-\boldsymbol{v}_{k*}^e|_{t+1}^{T_k}\right\|_Q^2+\left\|\boldsymbol{u}_k|_t^{T_k-1}-\boldsymbol{v}_{k*}^e|_t^{T_k-1}\right\|_R^2+V_f\left(x_{k*}^e(T_k)\right)\leqslant h,\,t\geqslant 0\right.\right\}.$$

由定理 1 和 3 可知, Tube 不变集的边界 h 对实际 ILMPC 系统的收敛性能有显著影响. 由于 $h\geqslant h^*=b_3\varsigma_k^x/(1-\gamma)$ 且 $\varsigma_k^x\leqslant L_u\varsigma_k^u$, DNN 估计误差 ς_k^u 一定程度上决定了 Tube 不变集的大小, 进而影响 ILMPC 系统的收敛性能. 当 DNN 估计误差增加时, Tube 不变集的边界随之扩大, 实际控制信号 $u_k(t)$ 沿批次的收敛上界与最优值的差距增大, 收敛性能变差.

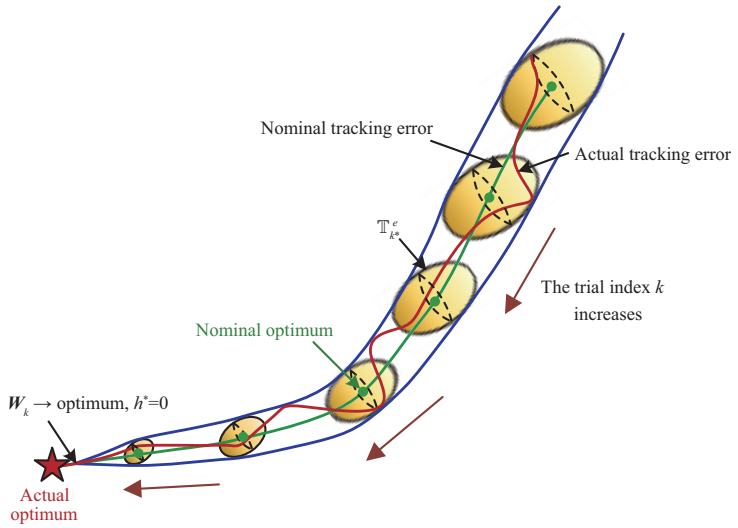

图 4 (网络版彩图) Tube ILMPC 系统沿批次的跟踪误差收敛示意图

Figure 4 (Color online) Tracking error convergence of tube-based ILMPC along trials

图 4 为 $n_x = 3$ 时 Tube ILMPC 系统的跟踪误差轨迹示意图, 其中实际跟踪误差轨迹始终被限制于标称跟踪误差轨迹附近的 Tube 不变集内. 随着批次增加, DNN 参数矩阵 $\bar{W}_k$ 将按照式 (10) 收敛至最优, DNN 估计误差上界 ς_k^u 最终收敛至零, 使得 $h^* \to 0$. 因此, 实际跟踪误差轨迹将与标称跟踪误差轨迹重合, 并在足够多个批次迭代后到达实际最优值. 此时, 标称控制系统 (18) 等价于实际控制系统, 可省略辅助优化问题 (25).

注1 若 Tube 不变集上界 h^* 收敛至零, DNN 估计器生成的参考控制信号 $\hat{u}_k^r$ 将与最优 ILC 控制信号 $u_k^{\mathrm{ILC}*}$ 相等, 表明 DNN 估计器可完全替代 ILC 控制器的功能. 此时, ILC 优化问题 (20) 可被省略, 而 MPC 优化 (21) 需要继续执行以抑制实时干扰并保障 ILMPC 系统的时域稳定性. 当省略 ILC 控制器和辅助控制器后, 简化后的 ILMPC 优化问题可写作

$$\min_{u_k^{\mathrm{MPC}}|_t^{T_k-1}} \quad J_k^{\mathrm{MPC}}(t) = \left\| \boldsymbol{x}_k^e|_{t+1}^{T_k} \right\|_Q^2 + \left\| \delta \boldsymbol{u}_k|_t^{T_k-1} \right\|_R^2 \tag{43}$$

$$\text{s.t.} \quad x_k(t+1) = f_a\left(x_k(t), \hat{u}_k^r(t) + u_k^{\mathrm{MPC}}(t)\right),$$

$$u_k \in \mathbb{U},\ x_k \in \mathbb{X},\ x_k^e(T_k) = 0,$$

其中 $\delta \boldsymbol{u}_k|_t^{T_k-1} = \begin{bmatrix} \delta u_k(t) \\ \delta u_k(t+1) \\ \vdots \\ \delta u_k(T_k-1) \end{bmatrix} = \begin{bmatrix} u_k(t) - u_k(t-1) \\ u_k(t+1) - u_k(t) \\ \vdots \\ u_k(T_k-1) - u_k(T_k-2) \end{bmatrix}$.

5 仿真研究

本节以典型非线性注塑过程 [50] 为例开展仿真实验. 在注塑过程的填料阶段, 注射速度需要以高精度跟踪给定参考轨迹, 其跟踪效果对最终产品质量起到关键作用. 注塑过程中产品规格的多样性和

不可避免的传送误差均会导致各批次的操作轨迹和操作周期发生变化, 使得在点对点学习机制下难以沿批次逐步提高跟踪精度. 因此, 需将基于知识迁移的数据驱动 Tube ILMPC 策略应用于注塑过程, 提高系统对变工况条件的适应性.

注塑过程填料阶段的非线性动态具有以下微分方程描述 [51]:

$$\begin{cases} \frac{\mathrm{d}P_h}{\mathrm{d}t} = \frac{\beta_h}{V_h}\left(q_h - A_h\frac{\mathrm{d}Z}{\mathrm{d}t}\right), \frac{\mathrm{d}v_z}{\mathrm{d}t} = \frac{1}{M}\left(P_hA_h - P_nA_n - f_v\right), \\ \frac{\mathrm{d}Z}{\mathrm{d}t} = v_z, f_v = 2\pi\eta {R_n}^{1-n}\left(l_0 + Z\right)\left[\frac{(s-1)v_z}{k_r^{1-s}-1}\right]^n, \end{cases} \tag{44}$$

其中 P_h 为液压压力, v_z 为注射速度, Z 为螺旋位移, q_h 为液压流量. 其他参数的物理意义及取值参见文献 [52].

定义系统状态为 $x = [x_1\ x_2\ \ x_3]^{\mathrm{T}} = [P_h\ v_z\ Z]^{\mathrm{T}}$, 系统输入为 $u = q_h$. 设置采样时间为 0.25 s, 系统 (44) 的离散状态空间模型可整理为

$$x_k\left(t+1\right) = f\left(x_k\left(t\right), u_k\left(t\right)\right) + \omega, \tag{45}$$

其中

$$f\left(x_k\left(t\right), u_k\left(t\right)\right) = Ax_k\left(t\right) + Bu_k\left(t\right)\ + g\left(x_{k,2}\left(t\right)\right),$$

$$A = \begin{bmatrix} 1 & -0.236 & 0 \\ 1.0805 & 1 & 0 \\ 0 & 1 & 1 \end{bmatrix},\ B = \begin{bmatrix} 0.2225 \\ 0 \\ 0 \end{bmatrix},$$

$$g\left(x_{k,2}\left(t\right)\right) = \begin{bmatrix} 0 & -4.3059{x_{k,2}}^{0.7} & 0 \end{bmatrix}^{\mathrm{T}},\ \omega = [0\ \ 31.3187\ \ 0]^{\mathrm{T}}.$$

关于液压流量的输入约束设置为

$$\begin{aligned} 0 \leqslant u_k\left(t\right) \leqslant 100, \\ -20 \leqslant \Delta u_k\left(t\right) \leqslant 20, \\ -10 \leqslant \delta u_k\left(t\right) \leqslant 10, \end{aligned} \tag{46}$$

其中 $\delta u_k\left(t\right) = u_k\left(t\right) - u_k\left(t-1\right)$.

设定系统参考轨迹 x_k^r 随生产要求和外部环境扰动沿批次不断改变, 第 1~8 批次的参考轨迹变化情况如图 5 所示, 其中操作周期依次设为 80, 75, 85, 75, 85, 80, 75 和 85, 第 6 和 8 批次为低速运行, 第 4 和 5 批次为高速运行, 第 1, 2, 3 和 7 批次为中速运行. 从第 9 批次开始, 注射速度参考轨迹按照第 1~8 批次的变化顺序循环更替.

每个批次的初始状态保持为 $x_k\left(0\right) = [-26.5\ \ 0\ \ 18]^{\mathrm{T}}$. 初始控制输入轨迹设置为 $u_0\left(t\right) = 30\ (t \in [0, 80))$, 初始参考轨迹与第 1 批次一致. 第 1 批次使用经典非线性 ILMPC 控制器生成 DNN 估计器训练所需的最优控制策略信息.

从第 2 批次起, 将基于知识迁移的数据驱动 Tube ILMPC 策略施加至非线性注塑过程. 前 6 个批次通过经验估计确定 DNN 的隐含层层数为 3, 每个隐含层的神经元数为 5. 在第 7 批次, 通过遗传算法基于历史数据确定最优网络结构, 其中隐含层层数设置为 3, 每个隐含层的神经元数设置为 6. 在每个批次开始前, 根据方程 (7) 更新 DNN 估计器的参数矩阵 $\bar{W}_k$, 其中估计误差协方差矩阵 $\bar{P}_k$ 由前一批次的建模结果导出, 过程噪声协方差矩阵 Q_{N_k} 和测量噪声协方差矩阵 R_{N_k} 分别根据方程 (9)

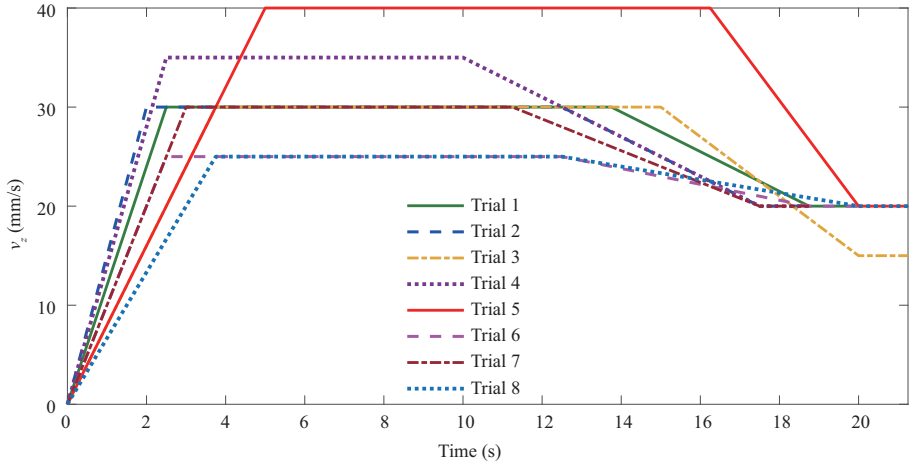

图 5 (网络版彩图) 第 1∼8 批次的注射速度 v_z 参考轨迹变化情况

Figure 5 (Color online) Varying reference trajectories of v_z from the 1st trial to the 8th trial

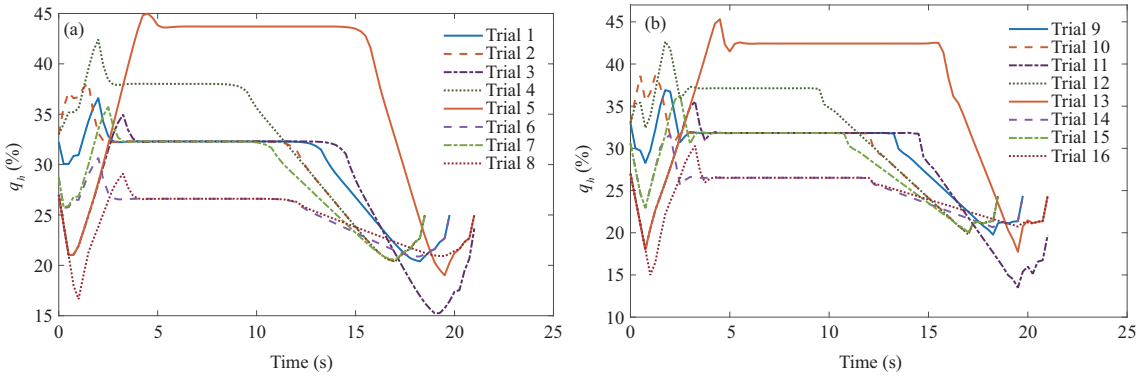

图 6 (网络版彩图) 基于知识迁移的 Tube ILMPC 控制下第 1∼16 批次的标称液压流量 q_h 轨迹. (a) 第 1∼8 批次; (b) 第 9∼16 批次

Figure 6 (Color online) Nominal hydraulic flowrate q_h under tube-based ILMPC with knowledge transfer from the 1st trial to the 16th trial. (a) The 1st∼8th trials; (b) the 9th∼16th trials

和 (10) 进行更新. 将当前参考轨迹序列 x_k^r 输入至训练后的 DNN 估计器, 按照式 (11) 生成参考液压流量信号 $\hat{u}_k^r$. 根据 DNN 估计器的测试结果在每一批次重新确定式 (12) 中的估计误差上界 ς_k^u.

选取优化权重矩阵为 $Q = I_{3T_k\times 3T_k}$ 和 $R_1 = 0.005I_{T_k\times T_k}$, 离线求解标称 ILC 优化问题 (20) 和 MPC 优化问题 (21) 获得标称液压流量轨迹, 如图 6 所示. 第 2 批次的收紧约束设计为

$$\begin{aligned} 5.0 \leqslant u_k(t) \leqslant 95.0, \\ -18.3 \leqslant \Delta u_k(t) \leqslant 18.3, \\ -9.8 \leqslant \delta u_k(t) \leqslant 9.8, \end{aligned} \tag{47}$$

其中 $\delta u_k(t) = u_k(t) - u_k(t-1)$. 计算得到 Tube 不变集的边界为 $h = h^* = 3.67$. 随着批次增加, 约束 (47) 逐渐放松, 边界 h 随之收缩.

基于标称控制结果, 在线求解辅助优化问题 (25) 获得实际注射速度指令, 并在每个采样时刻 $t \in [0, T_k)$ 施加至非线性注塑过程 (44). 在基于知识迁移的数据驱动 Tube ILMPC 控制下, 注射速度 v_z

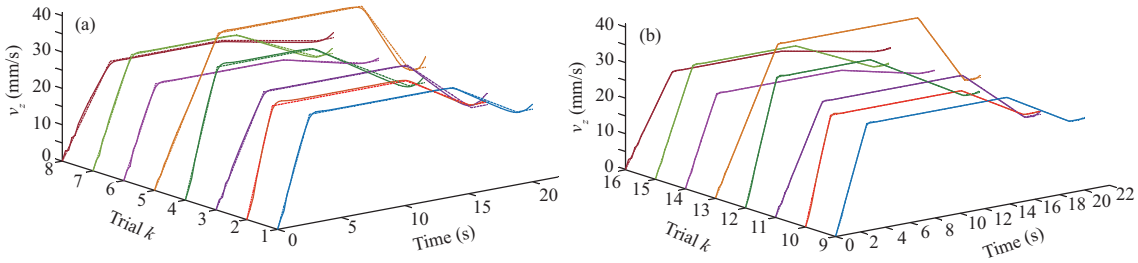

图 7 (网络版彩图) 基于知识迁移的 Tube ILMPC 控制下第 1∼16 批次的注射速度 v_z 轨迹: (a) 第 1∼8 批次; (b) 第 9∼16 批次 (实线: 实际轨迹; 虚线: 参考轨迹)

Figure 7 (Color online) Injection velocity v_z under tube-based ILMPC with knowledge transfer from the 1st trial to the 16th trial. (a) The 1st∼8th trials; (b) the 9th∼16th trials (solid lines: actual trajectories; dashed lines: reference trajectories)

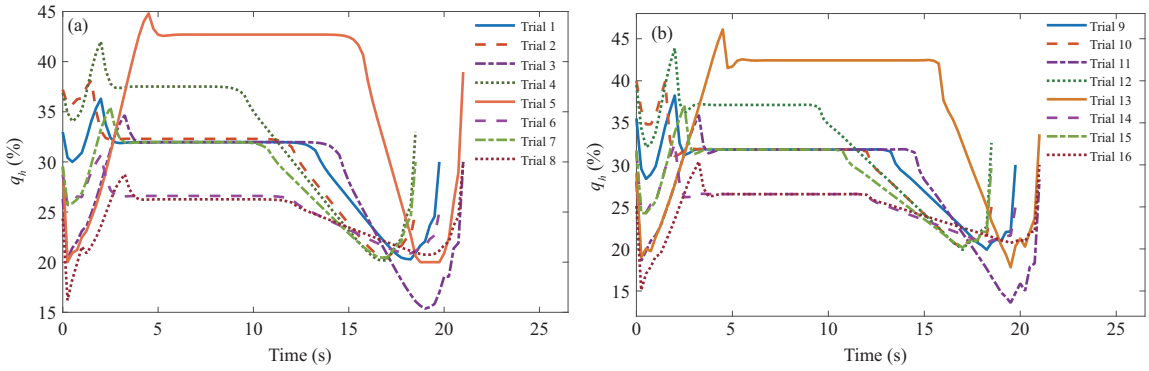

图 8 (网络版彩图) 基于知识迁移的 Tube ILMPC 控制下第 1∼16 批次的实际液压流量 q_h 轨迹. (a) 第 1∼8 批次; (b) 第 9∼16 批次

Figure 8 (Color online) Actual hydraulic flowrate q_h under tube-based ILMPC with knowledge transfer from the 1st trial to the 16th trial. (a) The 1st∼8th trials; (b) the 9th∼16th trials

和液压流量 q_h 的实际动态轨迹分别如图 7 和 8 所示, 相应的 DNN 估计结果如图 9 所示. 从第 1∼16 批次, DNN 的估计误差逐渐下降, 注射速度的跟踪精度显著提高. 在操作轨迹和操作周期持续变化的情况下, DNN 估计器将历史批次的先验知识迁移至当前运行批次, 使 ILMPC 控制器能够克服非重复运行工况问题, 保证控制率沿批次的有效更新. ILMPC 控制器中集成的 Tube 控制策略抑制了前期 DNN 估计误差对跟踪精度的影响, 并保障了系统的有界稳定. 图 10 显示了随着 DNN 估计器精度的不断提高, Tube 不变集沿批次逐渐收缩.

为直观体现注射速度跟踪误差沿批次的变化趋势, 计算每一批次各采样点注射速度跟踪的均方根误差 (root mean square error, RMSE), 并将其沿批次的变化轨迹绘制于图 11, 其中每个批次的 RMSE 值由下式计算:

$$\mathrm{RMSE}_k = \sqrt{\frac{1}{T_k}\sum_{i=1}^{T_k} x_k^e(i)^2}. \tag{48}$$

该仿真结果表明, 当系统运行至第 20 批次时, DNN 估计误差上界 ς_k^u 趋近于零, 标称轨迹与实际轨迹开始重合, 表明此时 ILC 优化 (20) 和辅助优化 (25) 失去作用. 自第 25 批次起, 控制变量保持在最优值, 表明控制器已实现变操作轨迹和操作周期下的跟踪误差最小化任务.

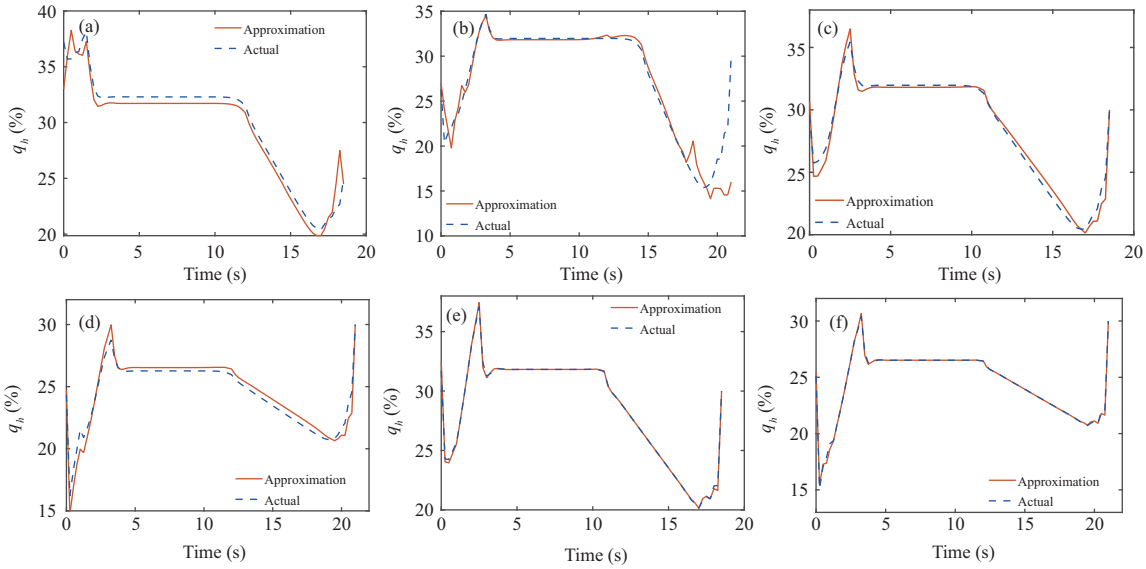

图 9　(网络版彩图) 第 1~16 批次的 DNN 估计结果. (a) 第 2 批次; (b) 第 3 批次; (c) 第 7 批次; (d) 第 8 批次; (e) 第 15 批次; (f) 第 16 批次

Figure 9　(Color online) Approximation results of the DNN from the 1st trial to the 16th trial. (a) The 2nd trial; (b) the 3rd trial; (c) the 7th trial; (d) the 8th trial; (e) the 15th trial; (f) the 16th trial

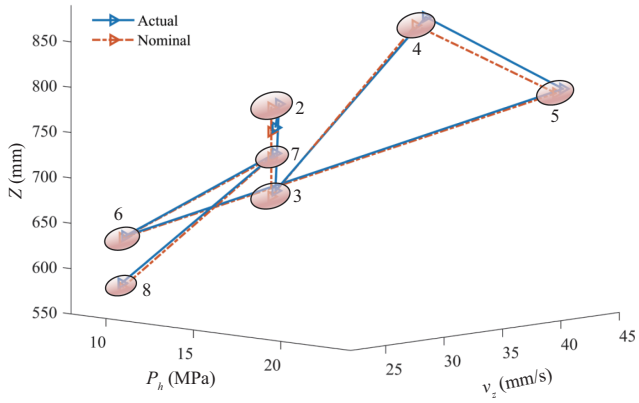

图 10　(网络版彩图) 第 7.5 秒处 Tube 不变集沿批次的收缩过程

Figure 10　(Color online) Contracting Tube invariant sets at 7.5 s along trials

为验证所设 DNN 结构的合理性, 在第 7 批次选取不同隐含层及神经元数目进行建模误差和跟踪误差趋势分析 (第 2~6 批次的网络结构不变), 结果如图 12 所示. 可以发现, 遗传算法求解得到的网络超参数使得 DNN 估计器具有最低的建模误差. 相应地, DNN 建模误差上界 ς_k^u 达到最低, Tube 不变集收缩至最小, 从而 Tube ILMPC 控制下的跟踪误差达到最低.

为验证基于 DNN 的知识迁移技术在提高 ILMPC 变运行工况下学习效率方面的作用, 将其与常数补偿 [28]、预测补偿 [35] 两种常用的处理变操作区间问题的数据补偿方法进行仿真对比. 常数补偿方法使用定值填补各批次缺失数据, 将所有批次的操作区间调整为相同长度, 而预测补偿方法利用基于模型的预测数据填补数据缺失区间. 在知识迁移机制和两种补偿机制的对比仿真实验中, 均采用数据

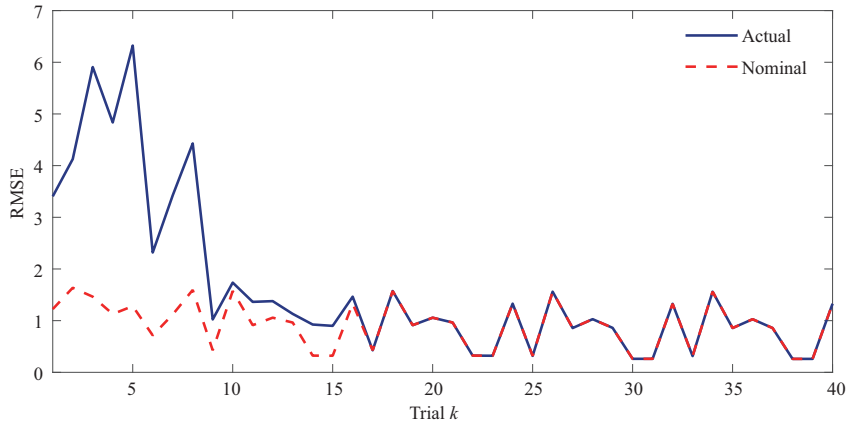

图 11 (网络版彩图) 基于知识迁移的 Tube ILMPC 沿批次的均方根误差轨迹

Figure 11 (Color online) Average RMSE along trials under tube-based ILMPC with knowledge transfer

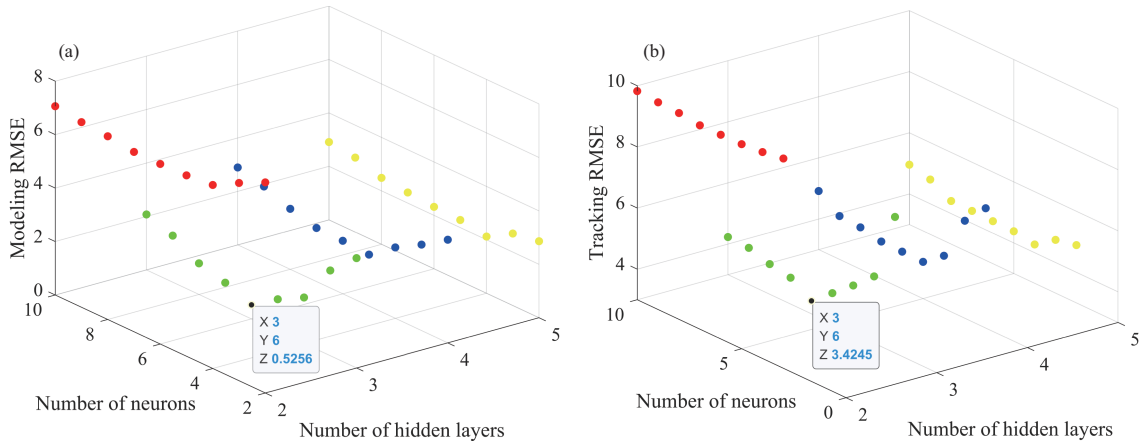

图 12 (网络版彩图) 选取不同隐含层和神经元数目时的建模误差和跟踪误差对比. (a) 建模 RMSE; (b) 跟踪 RMSE

Figure 12 (Color online) Comparison of modeling errors and tracking errors under different numbers of hidden layers and neurons. (a) Modeling RMSE; (b) tracking RMSE

驱动 Tube ILMPC 进行实时控制生成仿真结果, 且所有初始条件及权重矩阵等参数保持不变. 第 9~12 批次的对比跟踪轨迹如图 13 所示, 相应的跟踪 RMSE 值列于表 1.

在相同的初始条件和控制器设计下, 应用基于 DNN 的知识迁移技术时系统跟踪明显低于其他两种数据补偿方案, 尤其是在先验知识不充分的第 3, 5, 8, 9 和 11 批次. 知识迁移机制下的跟踪 RMSE 沿批次逐步下降, 而其他两种数据补偿机制下的跟踪 RMSE 陷入周期性的波动. 由于预测补偿采用了精确度更高的动态补偿措施, 其跟踪 RMSE 相较于常数补偿下降更快, 对变操作周期问题具有更强的适应性. 然而, 由于预测补偿方法无法处理变操作轨迹问题, 该方案下的系统跟踪精度要显著低于知识迁移机制. 基于 DNN 的知识迁移实现了变操作轨迹和变操作周期下相邻批次间的精确信息转换, 因此能够避免系统出现严重的跟踪偏移, 并加快了跟踪误差沿批次方向的收敛速度.

为验证 Tube 控制策略在抑制早期批次估计误差影响、保证系统有界收敛方面的作用, 在相同的 DNN 知识迁移机制下进一步将 Tube ILMPC 与经典 ILMPC 进行控制仿真对比. 在经典 ILMPC

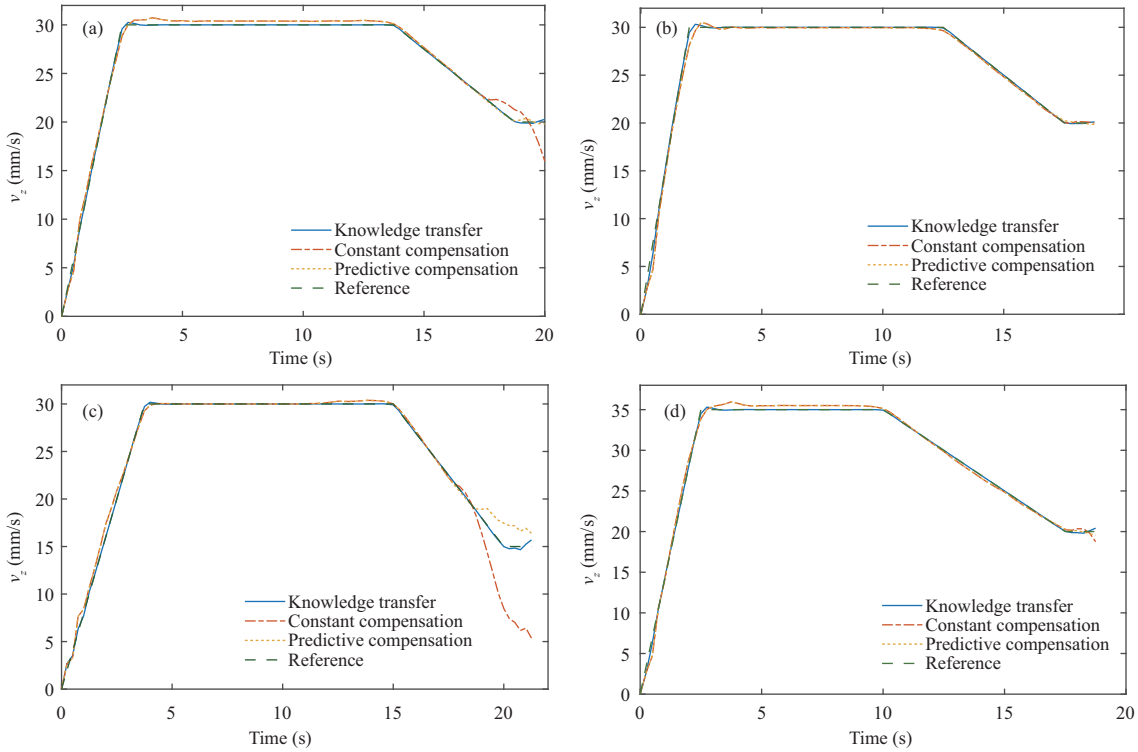

图 13　(网络版彩图) 第 9∼12 批次基于知识迁移和数据补偿的 Tube ILMPC 方法的跟踪轨迹对比. (a) 第 9 批次; (b) 第 10 批次; (c) 第 11 批次; (d) 第 12 批次

Figure 13　(Color online) Comparing tracking trajectories of tube-based ILMPC in the 9th∼12th trials between the DNN-based knowledge transfer method and the data compensation methods. (a) The 9th trial; (b) the 10th trial; (c) the 11th trial; (d) the 12th trial

表 1　基于 DNN 的知识迁移机制和数据补偿机制下 Tube ILMPC 跟踪 RMSE

Table 1　Tracking RMSE of tube-based ILMPC under DNN-based knowledge transfer method and data compensation methods

Trial	DNN-based knowledge transfer	Constant compensation	Predictive compensation
1	3.4048	3.4048	3.4048
2	4.1266	4.5609	4.5609
3	5.9070	21.3362	9.8242
4	4.8353	4.5729	4.4619
5	6.3230	37.5522	16.1828
6	2.3184	11.4122	10.1715
7	3.4245	3.4450	3.4206
8	4.4291	35.5461	5.4147
9	1.0233	6.4456	3.7289
10	1.7361	3.9607	3.9642
11	1.3634	21.9407	6.8659
12	1.3778	4.5719	4.4065

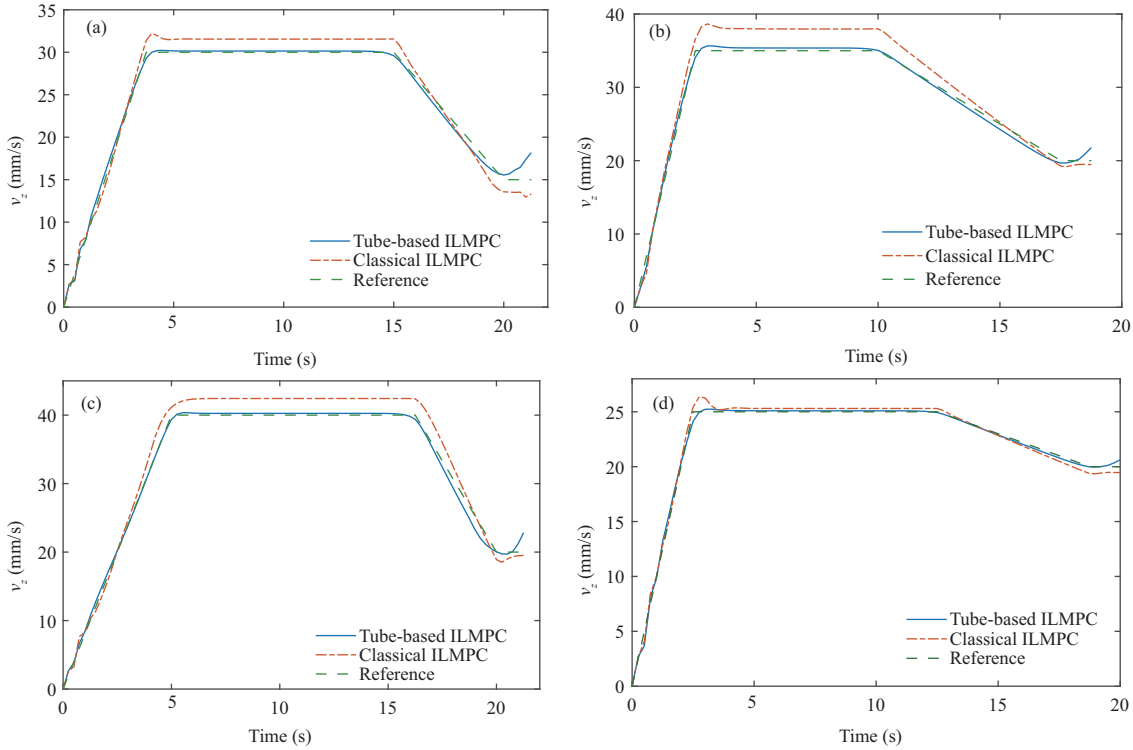

图 14 (网络版彩图) 第 3~6 批次 Tube ILMPC 和经典 ILMPC 的跟踪轨迹对比. (a) 第 3 批次; (b) 第 4 批次; (c) 第 5 批次; (d) 第 6 批次

Figure 14 (Color online) Comparing tracking trajectories of the 3rd~6th trials between tube-based ILMPC and classical ILMPC. (a) The 3rd trial; (b) the 4th trial; (c) the 5th trial; (d) the 6th trial

表 2 Tube ILMPC 和经典 ILMPC 控制下的跟踪 RMSE 和 CPU 时间

Table 2 Comparing tracking RMSE and CPU time of tube-based ILMPC and classical ILMPC

Trial	Tube-based ILMPC		Classical ILMPC	
	RMSE	CPU time (s)	RMSE	CPU time (s)
1	3.4048	0.0127	3.4048	0.0127
2	4.1266	0.0179	12.1971	0.0174
3	5.9070	0.0152	12.7268	0.0149
4	4.8353	0.0162	19.0665	0.0159
5	6.3230	0.0148	19.0231	0.0146
6	2.3184	0.0157	3.8644	0.0155
7	3.4245	0.0156	10.3790	0.0156
8	1.3778	0.0178	5.4282	0.0175

中, 将求解优化问题 (20) 和 (21) 得到的标称控制输入 $v_k(t)$ 直接施加于注塑系统. 图 14 显示了在操作轨迹和操作周期都明显变化的第 3~6 批次, Tube ILMPC 与经典 ILMPC 控制下系统跟踪轨迹的对比情况. 表 2 列出了相应的跟踪 RMSE 值以及在线优化的平均 CPU 时间 (所用计算机参数为 Intel Core i7 CPU, 8GB RAM).

图 14 的仿真结果表明, 在早期批次 DNN 估计器存在较大误差时, Tube ILMPC 的跟踪精度明显高于经典 ILMPC. 表 2 同样反映出, 在前 8 个批次, Tube ILMPC 通过设计 Tube 不变集成功将系统跟踪 RMSE 限制在较小范围内, 而经典 ILMPC 控制下跟踪 RMSE 频频出现大幅度增长. 同时, 由于 Tube ILMPC 的主要计算环节均在批次间隔内离线完成, 其在线 CPU 时间与经典 ILMPC 保持在同等水平.

综上, 本文所提出的基于知识迁移的数据驱动 Tube ILMPC 在处理变运行工况方面具有显著优势, 能够有效提高注塑系统等典型批次过程的生产效益.

6 结论

针对经典 ILMPC 方法受限于批次运行工况一致性的问题, 本文提出了一种基于知识迁移的数据驱动 Tube ILMPC 策略. 该策略中构建的自适应 DNN 估计器能够在变操作轨迹和变操作周期下实现相邻批次间先验知识的有效转换, 设计的 Tube ILMPC 控制结构能够将早期批次 DNN 估计误差造成的跟踪轨迹偏离限制在 Tube 不变集内. 针对典型注塑过程的仿真结果验证了所提出的基于知识迁移的数据驱动 Tube ILMPC 策略能够在复杂变运行工况下保证对参考轨迹的高精度跟踪, 实现沿批次方向的有界收敛.

本文采用的 Tube ILMPC 策略有利于在 DNN 估计误差较大的早期批次维持系统有界稳定. 然而, 随着历史运行经验沿批次不断积累, DNN 估计器的精度将逐步提高, Tube ILMPC 优化计算负担较大的问题会愈发明显. 为提高计算效率, 建立标称 ILMPC 优化解沿批次的显式迭代关系将成为未来研究的一个重要方向. 此外, 未来研究需要设计 DNN 逼近器达到足够精度的有效判定条件, 当满足判定条件时以结构较为简单的传统 MPC 替换 Tube ILMPC, 从而最大限度地规避 Tube ILMPC 的计算负担问题.

参考文献

1 Lee K S, Chin I S, Lee H J, et al. Model predictive control technique combined with iterative learning for batch processes. AIChE J, 1999, 45: 2175–2187

2 Shi J, Gao F, Wu T J. Single-cycle and multi-cycle generalized 2D model predictive iterative learning control (2D-GPILC) schemes for batch processes. J Process Control, 2007, 17: 715–727

3 Oh S K, Lee J M. Iterative learning model predictive control for constrained multivariable control of batch processes. Comput Chem Eng, 2016, 93: 284–292

4 Oh S K, Park B J, Lee J M. Point-to-point iterative learning model predictive control. Automatica, 2018, 89: 135–143

5 Ma L, Liu X, Kong X, et al. Iterative learning model predictive control based on iterative data-driven modeling. IEEE Trans Neural Netw Learn Syst, 2021, 32: 3377–3390

6 Ma L L, Liu X J, Gao F R. Status and challenges of iterative learning model predictive control. Acta Automat Sin, 2022, 48: 1385–1401 [马乐乐, 刘向杰, 高福荣. 迭代学习模型预测控制研究现状与挑战. 自动化学报, 2022, 48: 1385–1401]

7 Arimoto S, Kawamura S, Miyazaki F. Bettering operation of robots by learning. J Robotic Syst, 1984, 1: 123–140

8 Li X, Shen D, Ding B. Iterative learning control for output tracking of nonlinear systems with unavailable state information. IEEE Trans Neural Netw Learn Syst, 2022, 33: 5085–5092

9 Sun M X, Wang D W, Chen P N. Repetitive learning control for finite-interval nonlinear systems. Sci Sin Inform, 2010, 40: 433–444 [孙明轩, 王郸维, 陈彭年. 有限区间非线性系统的重复学习控制. 中国科学: 信息科学, 2010, 40: 433–444]

10 Xi Y G, Li D W, Lin S. Model predictive control—status and challenges. Acta Automat Sin, 2013, 39: 222–236 [席裕庚, 李德伟, 林姝. 模型预测控制 —— 现状与挑战. 自动化学报, 2013, 39: 222–236]

11 Nagy Z K, Braatz R D. Robust nonlinear model predictive control of batch processes. AIChE J, 2003, 49: 1776–1786

12 Ma M M, Li Y M, Cui J, et al. Event-triggered distributed model predictive load frequency control of an interconnected power system. Sci Sin Inform, 2023, 53: 1392–1403 [马苗苗, 李钰梅, 崔婧, 等. 基于事件触发的互联电力系统分布式负荷频率预测控制. 中国科学: 信息科学, 2023, 53: 1392–1403]

13 Kong X B, Liu X J, Han M. Hierarchical distributed model predictive control of hybrid wind and solar generation system. Sci Sin Inform, 2018, 48: 1316–1332 [孔小兵, 刘向杰, 韩梅. 风光互补发电系统的分级递阶分布式预测控制. 中国科学: 信息科学, 2018, 48: 1316–1332]

14 Liu X, Ma L, Kong X, et al. An efficient iterative learning predictive functional control for nonlinear batch processes. IEEE Trans Cybern, 2022, 52: 4147–4160

15 Ma L L, Liu X J. A high efficiency iterative learning predictive functional control for nonlinear fast batch processes. Acta Automat Sin, 2022, 48: 515–530 [马乐乐, 刘向杰. 非线性快速批次过程高效迭代学习预测函数控制. 自动化学报, 2022, 48: 515–530]

16 Rosolia U, Zhang X, Borrelli F. Robust learning model-predictive control for linear systems performing iterative tasks. IEEE Trans Automat Contr, 2022, 67: 856–869

17 Li D, He S, Xi Y, et al. Synthesis of ILC-MPC controller with data-driven approach for constrained batch processes. IEEE Trans Ind Electron, 2020, 67: 3116–3125

18 Lu P C, Chen J, Xie L. Iterative learning control (ILC)-based economic optimization for batch processes using helpful disturbance information. Ind Eng Chem Res, 2018, 57: 3717–3731

19 Lee J H, Lee K S. Iterative learning control applied to batch processes: an overview. Control Eng Pract, 2007, 15: 1306–1318

20 Chi R, Hou Z, Xu J. Adaptive ILC for a class of discrete-time systems with iteration-varying trajectory and random initial condition. Automatica, 2008, 44: 2207–2213

21 Chi R, Hou Z, Jin S. A data-driven adaptive ILC for a class of nonlinear discrete-time systems with random initial states and iteration-varying target trajectory. J Franklin Inst, 2015, 352: 2407–2424

22 Wan K, Li X D. High-order internal model-based iterative learning control for 2-D linear FMMI systems with iteration-varying trajectory tracking. IEEE Trans Syst Man Cybern Syst, 2021, 51: 1462–1472

23 Boudjedir C E, Bouri M, Boukhetala D. Model-free iterative learning control with nonrepetitive trajectories for second-order MIMO nonlinear systems-application to a delta robot. IEEE Trans Ind Electron, 2021, 68: 7433–7443

24 Oh S K, Lee J M. Stochastic iterative learning control for discrete linear time-invariant system with batch-varying reference trajectories. J Process Control, 2015, 36: 64–78

25 Jin X. Fault tolerant nonrepetitive trajectory tracking for MIMO output constrained nonlinear systems using iterative learning control. IEEE Trans Cybern, 2019, 49: 3180–3190

26 Liu X, Ma L, Kong X, et al. Robust model predictive iterative learning control for iteration-varying-reference batch processes. IEEE Trans Syst Man Cybern Syst, 2021, 51: 4238–4250

27 Ma L L, Liu X J. Robust model predictive iterative learning control with iteration-varying reference trajectory. Acta Automat Sin, 2019, 45: 1933–1945 [马乐乐, 刘向杰. 变参考轨迹下的鲁棒迭代学习模型预测控制. 自动化学报, 2019, 45: 1933–1945]

28 Li X, Xu J X, Huang D. An iterative learning control approach for linear systems with randomly varying trial lengths. IEEE Trans Automat Contr, 2014, 59: 1954–1960

29 Shen D, Zhang W, Wang Y, et al. On almost sure and mean square convergence of P-type ILC under randomly varying iteration lengths. Automatica, 2016, 63: 359–365

30 Meng D, Zhang J. Deterministic convergence for learning control systems over iteration-dependent tracking intervals. IEEE Trans Neural Netw Learn Syst, 2018, 29: 3885–3892

31 Shen D, Xu J X. Adaptive learning control for nonlinear systems with randomly varying iteration lengths. IEEE Trans Neural Netw Learn Syst, 2019, 30: 1119–1132

32 Yu Q, Hou Z. Adaptive fuzzy iterative learning control for high-speed trains with both randomly varying operation lengths and system constraints. IEEE Trans Fuzzy Syst, 2021, 29: 2408–2418

33 Liu G, Hou Z. Adaptive iterative learning fault-tolerant control for state constrained nonlinear systems with randomly varying iteration lengths. IEEE Trans Neural Netw Learn Syst, 2022. doi: 10.1109/TNNLS.2022.3185080

34 Shen M, Wu X, Park J H, et al. Iterative learning control of constrained systems with varying trial lengths under

alignment condition. IEEE Trans Neural Netw Learn Syst, 2023, 34: 6670–6676
35 Lin N, Chi R, Huang B. Auxiliary predictive compensation-based ILC for variable pass lengths. IEEE Trans Syst Man Cybern Syst, 2021, 51: 4048–4056
36 Ma L, Liu X, Gao F, et al. Event-based switching iterative learning model predictive control for batch processes with randomly varying trial lengths. IEEE Trans Cybern, 2023, 53: 7881–7894
37 Hou R, Jia L, Bu X, et al. Dynamic neural network predictive compensation-based point-to-point iterative learning control with nonuniform batch length. IEEE Trans Neural Netw Learn Syst, 2023. doi: 10.1109/TNNLS.2023.3265930
38 Jin X. Iterative learning control for MIMO nonlinear systems with iteration-varying trial lengths using modified composite energy function analysis. IEEE Trans Cybern, 2021, 51: 6080–6090
39 Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks. Science, 2006, 313: 504–507
40 Chai R, Tsourdos A, Savvaris A, et al. Design and implementation of deep neural network-based control for automatic parking maneuver process. IEEE Trans Neural Netw Learn Syst, 2022, 33: 1400–1413
41 Zhang S, Zhao C, Gao F. Incipient fault detection for multiphase batch processes with limited batches. IEEE Trans Contr Syst Technol, 2019, 27: 103–117
42 Windmann S. Data-driven fault detection in industrial batch processes based on a stochastic hybrid process model. IEEE Trans Automat Sci Eng, 2022, 19: 3888–3902
43 Goodfellow I, Bengio Y, Courville A. Deep Learning. Cambridge: MIT Press, 2016
44 Mayne D Q, Kerrigan E C, van Wyk E J, et al. Tube-based robust nonlinear model predictive control. Intl J Robust Nonlinear, 2011, 21: 1341–1353
45 Cannon M, Buerger J, Kouvaritakis B, et al. Robust tubes in nonlinear model predictive control. IEEE Trans Automat Contr, 2011, 56: 1942–1947
46 Wang X, Huang Y. Convergence study in extended Kalman filter-based training of recurrent neural networks. IEEE Trans Neural Netw, 2011, 22: 588–600
47 Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators. Neural Networks, 1989, 2: 359–366
48 Lee K S, Lee J H. Convergence of constrained model-based predictive control for batch processes. IEEE Trans Automat Contr, 2000, 45: 1928–1932
49 Han H G, Wang C Y, Sun H Y, et al. Iterative learning model predictive control with fuzzy neural network for nonlinear systems. IEEE Trans Fuzzy Syst, 2023, 31: 3220–3234
50 Wang Y, Zhou D, Gao F. Iterative learning model predictive control for multi-phase batch processes. J Process Control, 2008, 18: 543–557
51 Lu J, Cao Z, Gao F. Multipoint iterative learning model predictive control. IEEE Trans Ind Electron, 2019, 66: 6230–6240
52 Rafizadeh M, Patterson W I, Kamal M R. Physically-based model of thermoplastics injection molding for control applications. Int Polym Processing, 1996, 11: 352–362

Data-driven iterative learning model predictive control based on knowledge transfer

Lele MA[1], Xiangjie LIU[1*] & Furong GAO[2]

1. *School of Control and Computer Engineering, North China Electric Power University, Beijing* 102206*, China*;
2. *Department of Chemical and Biomolecular Engineering, Hong Kong University of Science and Technology, Hong Kong* 999077*, China*
* Corresponding author. E-mail: liuxj@ncepu.edu.cn

Abstract Iterative learning model predictive control (ILMPC) has become an excellent data-driven intelligent control strategy for batch manufacturing, featured by progressively improving tracking performance along trials while persistently rejecting stochastic disturbance along time. The point-to-point learning mechanism of the existing ILMPCs generally relies on the strict identity of operating conditions along trials to guarantee the integrity and accuracy of historical data. However, the variation of production requirements and environments usually leads to trial-varying reference trajectories and operating durations, resulting in incomplete and inaccurate historical information for the iterative learning of subsequent trials. To promote the adaptability and flexibility of ILMPC under unconformable prior information, this paper proposes an innovative data-driven ILMPC based on knowledge transfer. The control actions of ILMPC are imitated along trials by an adaptive deep neural network (DNN), based on which the prior operation data are transformed to accommodate the condition of each current trial. Under this knowledge transfer mechanism, the tube control scheme is further integrated into ILMPC to restrain the influence of the considerable DNN approximation error in the early trials, which ensures the time-domain stability and iteration-domain convergence of the ILMPC system. Simulations on the nonlinear injection molding process verify that the proposed method has noticeable advantages in the aspects of tracking accuracy and convergence rate when faced with significant changes of operating reference and duration.

Keywords iterative learning model predictive control, knowledge transfer, data-driven, trial-varying operating conditions