基于自适应事件触发分布式模型预测控制的多智能体系统跟踪一致性

王涛¹, 康宇^{1,2*}, 李鹏飞¹

1. 中国科学技术大学自动化系, 合肥 230026;

2. 中国科学技术大学先进技术研究院, 合肥 230088

* E-mail: kangduyu@ustc.edu.cn

收稿日期: 2021-08-16; 接受日期: 2021-11-04; 网络版发表日期: 2022-08-08

国家重点研发项目(编号: 2018YFE0106800)、国家自然科学基金项目(批准号: 62103394, 61725304, 62033012)、安徽重大专项科技项目(编号: 201903a07020012)和中国博士后科学基金(编号: 2020M682036)资助

摘要 基于分布式模型预测控制的多智能体系统跟踪一致是当前的研究热点, 其中, 作为研究难点的外部扰动处理和计算资源消耗降低尚缺少有效的解决方法. 首先, 论文提出了新的约束收缩方案, 建立了新的分布式优化问题; 然后, 利用变时域思想设计了自适应事件触发机制, 提出了多智能体系统跟踪一致的自适应事件触发分布式模型预测控制方法, 有效解决了在受扰多智能体系统跟踪问题中约束不满足和计算资源消耗问题; 最后通过多车辆系统仿真验证了所提方法的有效性.

关键词 多智能体系统, 一致性, 分布式模型预测控制, 事件触发控制, 自适应控制

1 引言

近些年, 多智能体系统在众多领域受到越来越多的研究, 例如一致性问题^[1~3]、集群问题^[4,5]、编队问题^[6]. 其中, 一致性问题重要的研究课题, 一致性是多个通过物理结构或者通信网络连接的系统经过一段时间最终使得这些系统的某些状态趋于相等^[7]. 多智能体一致性在许多实际应用中被广泛关注, 如水下机器人^[8,9]、无人机^[10]等. 所以研究多智能体系统的一致性具有理论意义和实际价值.

另一方面, 模型预测控制(MPC)由于其在处理多

变量和约束问题方面的优势而受到越来越多的关注^[11,12]. 在多智能体系统上应用MPC时, 传统的中心化MPC就会存在高计算资源消耗问题. 分布式MPC(Distributed MPC, DMPC)相对于中心化MPC具有灵活性高和低计算资源消耗的优势, 所以在多智能体系统的研究中多采用DMPC^[13~16]. 在文献^[17]中, 作者基于DMPC分别对单积分和双积分动态系统的多智能体系统一致性进行研究, 考虑了系统的输入约束, 并创新地使用了智能体最优路径的几何性质分析了系统的一致性, 解决了系统整体代价函数不能作为Lyapunov函数来分析系统一致性的难题. 但是文献^[17]的研究中

引用格式: 王涛, 康宇, 李鹏飞. 基于自适应事件触发分布式模型预测控制的多智能体系统跟踪一致性. 中国科学: 技术科学, 2022
Wang T, Kang Y, Li P F. Adaptive event-triggered distributed model predictive control for tracking consensus of multiagent systems (in Chinese).
Sci Sin Tech, 2022, doi: 10.1360/SST-2021-0379

制时域是固定的值, 减少了控制器设计的自由度, 文献[18]进一步地对带有切换拓扑的双积分动态系统提出了具有可调整控制时域的DMPC方案, 增加了控制器设计的自由度. 文献[19]针对二阶非线性多智能体系统提出了新的DMPC方案, 此方案设计了正定不变的终端区域和一个时变的兼容性约束, 进而使得分布式优化问题的可行性和系统的一致性得以保证. 然而文献[3]的作者认为, 兼容性约束使得在优化问题求解的每一时刻都需要传输上一时刻的最优状态信息, 造成了通信负载, 因此文献[3]对线性受扰多智能体系统跟踪一致性的研究中提出直接利用智能体邻居的延迟状态, 避免了使用兼容性约束.

在DMPC算法中需要通过在线求解优化问题来获得最优控制输入. 注意到上述基于DMPC的多智能体系统一致性研究都采用时间驱动的方式, 这使得在每个时刻都需要求解优化问题, 造成高的计算资源消耗. 为了降低计算资源消耗, 可以遵循两条路线^[20]: 减少优化问题的求解次数; 降低优化问题的复杂度.

第一条路线可以通过事件/自触发机制实现, 形成事件/自触发DMPC. 在事件/自触发DMPC中, 优化问题的求解只会发生在特定的触发时刻, 即事先设计的触发条件满足的时刻, 而不是每一时刻. 关于事件/自触发DMPC的研究相对较多, 可参考文献[15,16,20~22]. 第二条路线可以通过调整优化问题的预测时域实现^[23], 关于自适应时域DMPC的研究可参考文献[20,22].

上述事件/自触发DMPC的工作都是研究多智能体系统的稳定性, 基于事件/自触发DMPC的多智能体一致性研究相对较少. 文献[24]基于自触发DMPC研究了线性多智能体的动态一致性, 文献[25]基于事件触发DMPC的多智能体系统的一致性, 注意到研究中存在以下问题^[24,25]: 首先, 为了保证优化问题的可行性, 在上述两个研究中都加入了时变的兼容性约束, 然而这样的约束减小了优化问题解的可行域; 其次, 实际系统中通常存在外部扰动, 扰动的存在使得系统约束难以满足, 然而目前的研究并没有考虑扰动的影响; 最后, DMPC算法中的预测时域是固定的, 计算资源没有得到充分的降低.

基于上述考虑, 本文研究受扰多智能体系统的一致性, 提出了自适应事件触发DMPC方法. 本文的具体贡献如下.

(1) 提出了自适应事件触发DMPC方法. 该方法一方面通过事件触发机制确定分布式优化问题的求解时刻, 另一方面通过递减的预测时域降低优化问题的计算复杂度. 因此, 该方法相对于文献[24,25]更有效地降低了计算资源的消耗;

(2) 定义了新的分布式优化问题. 该优化问题一方面加入了收缩约束, 使得在外部扰动存在的情况下实际状态约束仍然满足; 另一方面去除了兼容性约束, 扩大了优化问题解的可行域;

(3) 建立了分布式优化问题可行性和多智能体系统一致性的充分条件, 该条件相对于文献[24]中的条件更易成立.

2 问题描述

考虑由 M 个智能体组成的多智能体系统, 第 i 个智能体的系统动态方程为:

$$x_i(k+1) = Ax_i(k) + Bu_i(k) + w_i(k), \quad k \geq 0, \quad (1)$$

其中 $i=1, \dots, M$, $(A, B) \in \mathbb{R}^{n \times n} \times \mathbb{R}^{n \times m}$. 智能体 i 的状态 $x_i(k) \in \mathbb{R}^n$, 控制输入 $u_i(k) \in \mathbb{R}^m$ 和外部扰动 $w_i(k) \in \mathbb{R}^n$ 分别受到以下约束:

$$x_i(k) \in \mathbb{X}_i, \quad u_i(k) \in \mathbb{U}_i, \quad w_i(k) \in \mathbb{W}_i, \quad (2)$$

其中, 状态约束 $\mathbb{X}_i$ 和控制约束 $\mathbb{U}_i$ 是包含原点的紧集, 外部扰动集 $\mathbb{W}_i \triangleq \{w_i \in \mathbb{R}^n : \|w_i\|_{\rho_i} \leq \rho_i\}$, 常数 $\rho_i > 0$ 表示扰动的上界.

智能体需要跟踪虚拟参考信号的动态方程为^[3]:

$$x_r(k+1) = Ax_r(k). \quad (3)$$

为了描述多智能体系统(1)的通信拓扑, 定义图 $\mathcal{G} = \{\mathcal{V}, \mathcal{E}, \mathcal{A}\}$, 其中 $\mathcal{V} = \{1, \dots, M\}$ 是顶点集, $\mathcal{E} \subseteq \{(i, j) : i, j \in \mathcal{V}, j \neq i\}$ 是边集, $\mathcal{A} = [a_{ij}] \in \mathbb{R}^{M \times M}$ 是邻接矩阵. 如果智能体 i 能收到智能体 j 的信息, 则称智能体 j 是智能体 i 的邻居, 并且 $a_{ij} = 1$; 否则 $a_{ij} = 0$. $\mathcal{N}_i = \{j \in \mathcal{V}, a_{ij} = 1\}$ 表示智能体 i 的邻居集.

基于上述准备, 下面给出多智能体系统(1)的跟踪一致性定义.

定义^[26]: 考虑具有通信拓扑 $\mathcal{G}$ 的多智能体系统(1). 给定初始条件 $x_i(0)$, $i \in \mathcal{V}$, 如果智能体与参考信号之间

的状态差满足:

$$\lim_{k \rightarrow \infty} \|x_i(k) - x_r(k)\| \leq \delta, \forall i \in \mathcal{V}, \quad (4)$$

其中 δ 是一个可调参数, 则称多智能体系统(1)达到跟踪一致.

假设1: 系统(1)是可控的.

本文的研究目标是设计一个DMPC算法使得多智能体系统(1)达到定义中的一致性, 同时1) 满足(2)中的系统约束; 2) 降低DMPC的计算资源消耗.

3 自适应事件触发DMPC方法

本节给出用来使得多智能体系统达到一致的自适应事件触发DMPC方法, 其包括分布式优化问题的定义和自适应事件触发策略的设计.

3.1 分布式优化问题

由于在DMPC中, 各个智能体之间存在信息交换, 从而相对于无协作的分散式MPC有更好的控制性能^[13], 但是在智能体 i 的优化问题的当前求解时刻, 其并不能获得其邻居 $j, j \in \mathcal{N}_i$ 的未来预测状态信息, 所以智能体 i 利用的是邻居 j 的假设信息. 为了更好地描述每个智能体 i 的行为, 定义以下符号.

由于采用事件触发策略, 每个智能体的信息更新时刻可能是异步的, 即每个智能体的优化问题可能在不同的触发时刻求解, 定义序列 $\{k_i^l, l \in \mathbb{N}\}$ 表示智能体 i 优化问题的第 l 个触发时刻. 基于定义的触发时刻, 每个智能体 $i, i \in \mathcal{V}$ 的不同状态和控制输入轨迹表示如下:

$\bar{u}_i(k_i^l + m | k_i^l), \bar{x}_i(k_i^l + m | k_i^l), m \in \mathbb{N}$: 分别是智能体 i 在当前触发时刻 k_i^l 对 $k_i^l + m$ 时刻的预测控制输入和预测状态轨迹;

$\bar{u}_i^*(k_i^l + m | k_i^l), \bar{x}_i^*(k_i^l + m | k_i^l)$: 分别是智能体 i 在当前触发时刻 k_i^l 求解优化问题得到的最优控制输入和最优状态轨迹;

$x_i^a(k_i^l + m | k_i^l)$: 智能体 i 的假设状态轨迹, 其具体形式将在下面内容定义.

基于上述定义, 对于每个智能体 i , 在 $k = k_i^l$ 时刻,

其控制输入通过求解以下优化问题产生:

$$\begin{aligned} \min_{\bar{U}_i(k_i^l)} & J_i(x_i(k_i^l), \bar{U}_i(k_i^l), X_j^a(k_i^l), N(k_i^l)) \\ \text{s. t. } & \bar{x}_i(k_i^l | k_i^l) = x_i(k_i^l), \\ & \bar{x}_i(k_i^l + m + 1 | k_i^l) = A\bar{x}_i(k_i^l + m | k_i^l) \\ & \quad + B\bar{u}_i(k_i^l + m | k_i^l), \\ & \bar{x}_i(k_i^l + m | k_i^l) \in \mathbb{X}_i \ominus \mathbb{B}_i(m), \\ & \bar{u}_i(k_i^l + m | k_i^l) \in \mathbb{U}_i, \\ & \bar{x}_i(k_i^l + N(k_i^l) | k_i^l) \in \mathbb{X}_{f_i} \end{aligned} \quad (5)$$

其中 $\ominus$ 表示的是Pontryagin差集符号, $m = 0, \dots, N(k_i^l) - 1$, $N(k_i^l)$ 是在 k_i^l 时刻的预测时域. $\bar{U}_i(k_i^l) = \{\bar{u}_i(k_i^l | k_i^l), \dots, \bar{u}_i(k_i^l + N(k_i^l) - 1 | k_i^l)\}$ 是预测控制输入序列, 类似地, 对应的预测状态轨迹为 $\bar{X}_i(k_i^l) = \{\bar{x}_i(k_i^l | k_i^l), \dots, \bar{x}_i(k_i^l + N(k_i^l) | k_i^l)\}$. 在触发时刻 k_i^l 求解上述优化问题得到最优解 $\bar{U}_i^*(k_i^l)$ 和与之对应的最优预测状态轨迹 $\bar{X}_i^*(k_i^l)$. $\mathbb{X}_{f_i}$ 是终端约束集, 定义为终端预测状态与参考信号 x_r 的差, 即

$$\mathbb{X}_{f_i} \triangleq \left\{ x_i \in R^n : \|x_i - x_r(k_i^l + N(k_i^l))\|_{p_i} \leq \alpha \varepsilon_i \right\}, \quad (6)$$

其中 $0 < \alpha < 1, \varepsilon_i > 0$.

$X_j^a(k_i^l) = \{x_j^a(k_i^l | k_i^l), \dots, x_j^a(k_i^l + N(k_i^l) | k_i^l)\}$ 是智能体 j 的假设状态轨迹. 设计如下:

$$\begin{aligned} x_j^a(k_i^l + m | k_i^l) = & \begin{cases} x_j^*(k_i^l + m | \eta_j(k_i^l)), & m = 0, \dots, \eta_j(k_i^l) + N(\eta_j(k_i^l)) - k_i^l \\ Ax_j^a(k_i^l + m - 1 | k_i^l) + Bu_j^a(k_i^l + m - 1 | k_i^l), & \\ m = \eta_j(k_i^l) + N(\eta_j(k_i^l)) - k_i^l + 1, \dots, N(k_i^l). \end{cases} \end{aligned} \quad (7)$$

其中, $\eta_j(k_i^l) \triangleq \max\{k_j^l : k_j^l < k_i^l, l \in \mathbb{N}\}$ 表示智能体 j 距离 k_i^l 最近的触发时刻,

$$\begin{aligned} u_j^a(k_i^l + m - 1 | k_i^l) = & K_j(x_j^a(k_i^l + m - 1 | k_i^l) \\ & - x_r(k_i^l + m - 1)), \end{aligned}$$

$\mathbb{X}_i \ominus \mathbb{B}_i(m)$ 为收缩约束, 其是用保证状态约束(2)能在扰动存在的情况下满足, 收缩集 $\mathbb{B}_i(m)$ 定义为:

$$\mathbb{B}_i(m) \triangleq \left\{ x_i \in R^n : \|x_i\|_{P_i} \leq \sum_{n=0}^{m-1} \mathbf{A}^n \mathbf{P}_i \rho_i \right\}. \quad (8)$$

代价函数设计为:

$$\begin{aligned} & J_i(x_i(k_i^l), \bar{U}_i(k_i^l), X_j^a(k_i^l), N(k_i^l)) \\ &= \sum_{m=0}^{N(k_i^l)} \left\{ \left\| \bar{x}_i(k_i^l + m | k_i^l) - x_r(k_i^l + m) \right\|_{Q_i}^2 \right. \\ &+ \left\| \bar{u}_i(k_i^l + m | k_i^l) \right\|_{R_i}^2 \\ &+ \left\| \bar{x}_i(k_i^l + m | k_i^l) - \bar{x}_j^a(k_i^l + m | k_i^l) \right\|_{Q_{ij}}^2 \\ &+ \left\| \bar{x}_i(k_i^l + N(k_i^l) | k_i^l) - x_r(k_i^l + N(k_i^l)) \right\|_{P_i}^2 \Big\}, \end{aligned}$$

其中 Q_i, R_i, Q_{ij}, P_i 都是正定矩阵.

注1: 1): 考虑(8)中收缩集 $\mathbb{B}_i(m)$ 的定义, 如果真实状态与预测状态差 $(x_i(k_i^l + m) - \bar{x}_i(k_i^l + m | k_i^l)) \in \mathbb{B}_i(m)$ 且 $\bar{x}_i(k_i^l + m | k_i^l) \in \mathbb{X}_i \ominus \mathbb{B}_i(m)$, 那么子系统 i 的真实状态满足(2)中的约束 $x_i(k_i^l + m) \in \mathbb{X}_i$; 2): 上述定义的代价函数中含有的耦合项 $\left\| \bar{x}_i(k_i^l + m | k_i^l) - \bar{x}_j^a(k_i^l + m | k_i^l) \right\|_{Q_{ij}}^2$ 表示的是智能体之间的协作交流, 目的是为了获得更好的控制性能^[13]; 3): 注意到在一些DMPC研究中^[14,15], 为了保证整个系统的稳定性或者优化问题的可行性要求每个智能体 $i, i \in \mathcal{V}$ 的真实状态轨迹 x_i 与预测状态轨迹 $\bar{x}_i$ 不能偏差太远, 所以在这些研究中优化问题加入了兼容性约束 $(\left\| \bar{x}_i(k_i^l + m | k_i^l) - \bar{x}_i^a(k_i^l + m | k_i^{l-1}) \right\| \leq c, c > 0)$, 这样的约束会导致优化问题的求解变得更复杂, 然而本文中智能体的一致性可以由预测时域的更新得到保证(将会在第四节分析中给出证明), 避免了兼容性约束的使用, 从而降低了DMPC中优化问题求解的复杂度.

3.2 事件触发策略

本部分给出具体的事件触发策略设计, 包括决定触发时刻的触发条件以及预测时域 $N(k_i^l)$ 的更新方式.

由于外部扰动 w_i 的存在, 智能体 $i, i \in \mathcal{V}$ 的真实状态轨迹 $x_i(k_i^l + m)$ 与预测状态轨迹 $\bar{x}_i(k_i^l + m | k_i^l)$ 之间存在偏差, 如果此偏差过大, 可能会导致智能体 i 的真实状态轨迹过分偏离参考信号 x_r , 从而达不到多智能体

的跟踪一致性. 基于这样的事实, 触发条件设计为:

$$\left\| x_i(k) - \bar{x}_i(k | k_i^l) \right\|_{P_i} > \frac{\sigma_i - \rho_i}{\|A\|_{P_i}}, \quad (9)$$

$$k - k_i^l = N(k_i^l),$$

其中 $\|A\|_{P_i} = \sqrt{\lambda_{\max}(P_i^{-1/2} A^T P_i A P_i^{-1/2})}$, $\lambda_{\max}(\cdot)$ 表示最大特征值, $(\sigma_i - \rho_i) / \|A\|_{P_i}, i \in \mathcal{V}$ 是触发阈值, 常数 $\sigma_i > 0$, 是有待设计的智能体 i 的控制参数. 如果条件(9)中的任意一个条件满足, 那么事件被触发, (5)中的优化问题将被求解. 注意到预测时域 $N(k_i^l)$ 是时变的, 定义如下:

$$N(k_i^{l+1}) = N(k_i^l) - \Delta(k_i^l) + 1, \quad (10)$$

其中 $\Delta(k_i^l) = k_i^{l+1} - k_i^l$ 是相邻两次触发间隔.

注2: 由预测时域的更新方式(10)可知, $N(k_i^{l+1}) \leq N(k_i^l)$ 和 $N(k_i^l) \geq 1, \forall l \in \mathbb{N}$ 恒成立. 进一步地, 如果有 $\Delta(k_i^l) \geq 2, \forall l \in \mathbb{N}$, 则 $N(k_i^{l+1}) < N(k_i^l)$ 成立, 即预测时域是单调递减的. 此外, 条件(9)中的触发阈值的设计 $(\sigma_i - \rho_i) / \|A\|_{P_i}$ 是使得触发时刻依旧有不等式 $\left\| x_i(k_i^{l+1}) - \bar{x}_i(k_i^{l+1} | k_i^l) \right\|_{P_i} \leq \sigma_i$ 成立^[27,28], 是可行性的一个保证, 将在下述分析部分予以说明.

基于设计的触发条件(9)和预测时域更新方式(10), 具体方法总结为以下的自适应事件触发DMPC算法. 为了保证多智能体系统的一致性, 本文采用双模MPC方案^[29], 即在当前时刻 k , 如果测量得到的智能体 $i, i \in \mathcal{V}$ 的真实状态轨迹满足 $x_i(k) \in \Omega_i, \Omega_i \triangleq$

$$\left\{ x_i \in R^n : \left\| x_i - x_r(k) \right\|_{P_i} \leq \varepsilon_i \right\}, \text{ 则应用到系统的控制输入}$$

$$\lambda u_i(k) = K_i(x_i(k) - x_r(k)); \text{ 否则, 应用控制输入 } u_i(k) = \bar{u}_i^*(k | k_i^l), k \in [k_i^l, k_i^{l+1} - 1].$$

4 方法分析

本节将对本文提出的多智能体系统的自适应事件触发DMPC算法的可行性和整个多智能体系统的一致性进行分析.

4.1 方法可行性分析

事件触发DMPC算法的可行性确保了优化问题(5)

算法1: 自适应事件触发DMPC算法

初始化: 对于每个智能体 $i, i \in \mathcal{V}$, 给定初始状态 $x_i(0)$, 权重矩阵 $\mathbf{Q}_i, \mathbf{R}_i, \mathbf{Q}_y, \mathbf{P}_i$; 局部反馈增益 K_i ; 集合 Ω_i 和终端约束集; 控制参数 σ_i 和初始预测时域 $N(k_i^0)$.

步骤1: 在 $k=0$ 时刻, 对于全部智能体 i , 初始值 $\bar{x}_i(0 | 0) = x_i(0)$, 其邻居的假设状态 $\bar{x}_j^a(0 | 0) = 0, \forall j \in \mathcal{N}_i^l$; 求解优化问题(5), 得到最优解 $\bar{U}_i^*(0)$ 和与其相关的最优状态轨迹 $\bar{X}_i^*(0)$, 将控制量 $u_i(0) = \bar{u}_i^*(0 | 0)$ 应用到系统(1); 将 $\bar{X}_i^*(0)$ 传递给智能体 i 的邻居 $j, j \in \mathcal{N}_i$, 并接受其邻居的状态信息 $\bar{X}_j^*(0)$.

步骤2: 在 $k>0$ 时刻, 测量当前状态 $x_i(k)$, 如果 $x_i(k) \in \Omega_i$, 则控制输入切换到局部控制律 $u_i(k) = K_i(x_i(k) - x_r(k))$; 否则, 进入步骤3.

步骤3: 检测触发条件(9)是否满足, 如果(9)满足, 则根据(10)计算当前预测时域, 并令 $l=l+1$ 和 $k_i^l = k$, 构造邻居 $j, j \in \mathcal{N}_i^l$ 的假设状态轨迹 $\bar{x}_j^a(k_i^l + m | k_i^l)$, 智能体 i 求解优化问题(5), 得到最优解 $\bar{U}_i^*(k_i^l)$ 和 $\bar{X}_i^*(k_i^l)$, 向其邻居 $j, j \in \mathcal{N}_i^l$ 传递 $\bar{X}_i^*(k_i^l)$, 进行下一步; 否则, 直接进入步骤4.

步骤4: 应用控制输入量 $\bar{u}_i^*(k | k_i^l)$ 到系统(1), 并令 $k=k+1$, 进入步骤2.

在每个触发时刻 $k_i^l, l \in \mathbb{N}$ 都存在解. 本文采用数学归纳法证明, 具体地, 对于每个智能体 i , 假设在当前触发时刻 k_i^l , 优化问题(5)存在解, 如果在 k_i^{l+1} 触发时刻仍然存在解, 即可说明优化问题(5)在任何时刻都有解.

首先, 对于智能体 i , 基于触发时刻 k_i^l 的最优控制输入 $\bar{U}_i^*(k_i^l)$, 构造 k_i^{l+1} 时刻的可行控制输入 $\bar{U}_i(k_i^{l+1}) = \{\bar{u}_i(k_i^{l+1} | k_i^{l+1}), \dots, \bar{u}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1})\}$ 如下:

$$\bar{u}_i(k_i^{l+1} + m | k_i^{l+1}) = \begin{cases} \bar{u}_i^*(k_i^{l+1} + m | k_i^l), & m = 0, \dots, N(k_i^{l+1}) - 2, \\ K_i(\bar{x}_i(k_i^{l+1} + m | k_i^{l+1}) - x_r(k_i^{l+1} + m)), & \\ m = N(k_i^{l+1}) - 1. \end{cases} \quad (11)$$

与可行控制输入对应的可行状态序列为 $\bar{X}_i(k_i^{l+1}) = \{\bar{x}_i(k_i^{l+1} | k_i^{l+1}), \dots, \bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) | k_i^{l+1})\}$, 其满足的动态方程为:

$$\begin{aligned} \bar{x}_i(k_i^{l+1} + m + 1 | k_i^{l+1}) \\ = A\bar{x}_i(k_i^{l+1} + m | k_i^{l+1}) + B\bar{u}_i(k_i^{l+1} + m | k_i^{l+1}), \end{aligned}$$

其中 $\bar{x}_i(k_i^{l+1} | k_i^{l+1}) = x_i(k_i^{l+1})$. 以下定理1说明在 k_i^{l+1} 时刻构造的可行控制输入是优化问题(5)在 k_i^{l+1} 时刻的可行解, 进一步地可以转化为证明可行的控制输入序列 $\bar{U}_i(k_i^{l+1})$ 和状态序列 $\bar{X}_i(k_i^{l+1})$ 满足(5)中的约束.

定理1: 对于智能体 $i, i \in \mathcal{V}$, 给定初始值 $x_i(0)$, 如果在初始时刻优化问题(5)有解且满足以下条件:

$$K_i(x_i - x_r) \in \mathbb{U}_i, \forall x_i \in \Omega_i, \quad (12)$$

$$\begin{aligned} \|A\|_{\mathbf{P}_i}^{N(k_i^0)-1} \sigma_i + \alpha \varepsilon_i \leq \varepsilon_i, \\ \|A + BK_i\|_{\mathbf{P}_i} \left(\|A\|_{\mathbf{P}_i}^{N(k_i^0)-1} \sigma_i + \alpha \varepsilon_i \right) \leq \alpha \varepsilon_i, \end{aligned} \quad (13)$$

则优化问题(5)是可行的.

证明: 为了更清晰地表达, 我们将证明分为三个部分, 第一部分说明状态序列满足收缩约束 $\bar{x}_i(k_i^{l+1} + m | k_i^{l+1}) \in \mathbb{X}_i \ominus \mathbb{B}(m), m = 0, \dots, N(k_i^{l+1}) - 1$; 第二部分说明终端约束 $\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) | k_i^{l+1}) \in \mathbb{X}_{f_i}$ 满足; 最后是控制输入满足约束 $\bar{U}_i(k_i^{l+1}) \in \mathbb{U}_i$;

$\bar{x}_i(k_i^{l+1} + m | k_i^{l+1}) \in \mathbb{X}_i \ominus \mathbb{B}(m)$: 首先计算真实状态 $x_i(k_i^l + m), m = 0, \dots, \Delta(k_i^l)$ 与最优预测值 $\bar{x}_i^*(k_i^l + m | k_i^l)$ 之间的偏差. 由系统动态方程(1)和优化问题(5)可得:

$$\begin{aligned} x_i(k_i^l + m) - \bar{x}_i^*(k_i^l + m | k_i^l) \\ = Ax_i(k_i^l + m - 1) + Bu_i(k_i^l + m - 1) + w_i(k_i^l + m - 1) \\ - A\bar{x}_i^*(k_i^l + m - 1 | k_i^l) + B\bar{u}_i^*(k_i^l + m - 1 | k_i^l) \\ = A(x_i(k_i^l + m - 1) - \bar{x}_i^*(k_i^l + m - 1 | k_i^l)) \\ + w_i(k_i^l + m - 1) \\ \dots \\ = A^m(x_i(k_i^l) - \bar{x}_i^*(k_i^l | k_i^l)) + \sum_{n=0}^{m-1} A^n w_i(k_i^l + m - n). \end{aligned}$$

由 $x_i(k_i^l) = \bar{x}_i^*(k_i^l | k_i^l)$ 和 $\|w_i\|_{\mathbf{P}_i} \leq \rho_i$ 可得:

$$\begin{aligned} \|x_i(k_i^l + m) - \bar{x}_i^*(k_i^l + m | k_i^l)\|_{\mathbf{P}_i} \\ \leq \sum_{n=0}^{m-1} \|A^n\|_{\mathbf{P}_i} \rho_i. \end{aligned} \quad (14)$$

然后计算 k_i^{l+1} 时刻的可行状态 $\bar{x}_i(k_i^{l+1} + m | k_i^{l+1})$ 与

最优状态 $\bar{x}_i^*(k_i^{l+1} + m | k_i^l)$ 的误差:

$$\begin{aligned}
 & \bar{x}_i(k_i^{l+1} + 1 | k_i^{l+1}) - \bar{x}_i^*(k_i^{l+1} + 1 | k_i^l) \\
 &= A\bar{x}_i(k_i^{l+1} | k_i^{l+1}) + B\bar{u}_i(k_i^{l+1} | k_i^{l+1}) \\
 &\quad - A\bar{x}_i^*(k_i^{l+1} | k_i^l) + B\bar{u}_i^*(k_i^{l+1} | k_i^l) \\
 &= A(x_i(k_i^{l+1}) - A\bar{x}_i^*(k_i^{l+1} | k_i^l)), \\
 & \bar{x}_i(k_i^{l+1} + 2 | k_i^{l+1}) - \bar{x}_i^*(k_i^{l+1} + 2 | k_i^l) \\
 &= A\bar{x}_i(k_i^{l+1} + 1 | k_i^{l+1}) + B\bar{u}_i(k_i^{l+1} + 1 | k_i^{l+1}) \\
 &\quad - A\bar{x}_i^*(k_i^{l+1} + 1 | k_i^l) + B\bar{u}_i^*(k_i^{l+1} + 1 | k_i^l) \\
 &= A^2(x_i(k_i^{l+1}) - A\bar{x}_i^*(k_i^{l+1} | k_i^l)), \\
 & \dots \\
 & \bar{x}_i(k_i^{l+1} + m | k_i^{l+1}) - \bar{x}_i^*(k_i^{l+1} + m | k_i^l) \\
 &= A^m(x_i(k_i^{l+1}) - \bar{x}_i^*(k_i^{l+1} | k_i^l)). \tag{15}
 \end{aligned}$$

令式(14)中 $m = \Delta(k_i^l)$ 并代入式(15)可得:

$$\begin{aligned}
 & \|\bar{x}_i(k_i^{l+1} + m | k_i^{l+1}) - \bar{x}_i^*(k_i^{l+1} + m | k_i^l)\|_{\mathbf{P}_i} \\
 &= \|A^m\|_{\mathbf{P}_i} \sum_{n=0}^{\Delta(k_i^l)-1} \|A^n\|_{\mathbf{P}_i} \rho_i \leq \sum_{n=m}^{m+\Delta(k_i^l)-1} \|A\|_{\mathbf{P}_i}^n \rho_i. \tag{16}
 \end{aligned}$$

因为 $\bar{x}_i^*(k_i^{l+1} + m | k_i^l) \in \mathbb{X}_i \ominus \mathbb{B}_i(m + \Delta(k_i^l))$, 所以由式(16)有

$$\begin{aligned}
 & \bar{x}_i(k_i^{l+1} + m | k_i^{l+1}) \in \mathbb{X}_i \ominus \mathbb{B}_i(m + \Delta(k_i^l)) \\
 & \oplus \sum_{n=m}^{m+\Delta(k_i^l)-1} \|A\|_{\mathbf{P}_i}^n \rho_i \in \mathbb{X}_i \ominus \mathbb{B}_i(m).
 \end{aligned}$$

$\oplus$ 表示的是Minkowski和集符号.

$\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) | k_i^{l+1}) \in \mathbb{X}_{f_i}$: 首先需要说明 $\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) \in \Omega_i$, 这允许反馈增益 K_i 的使用. 由(15)式和触发条件(9)可得:

$$\begin{aligned}
 & \|\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) - \bar{x}_i^*(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^l)\|_{\mathbf{P}_i} \\
 & \leq \|A^{N(k_i^{l+1})-1}(x_i(k_i^{l+1}) - \bar{x}_i^*(k_i^{l+1} | k_i^l))\|_{\mathbf{P}_i} \\
 & \leq \|A\|_{\mathbf{P}_i}^{N(k_i^{l+1})-1} \sigma_i.
 \end{aligned}$$

另一方面, 最优状态 $\bar{x}_i^*(k_i^l + N(k_i^l) | k_i^l)$ 在 k_i^l 时刻满足终端约束, 即

$$\begin{aligned}
 & \|\bar{x}_i^*(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^l) - x_r(k_i^{l+1} + N(k_i^{l+1}) - 1)\|_{\mathbf{P}_i} \\
 &= \|\bar{x}_i^*(k_i^l + N(k_i^l) | k_i^l) - x_r(k_i^l + N(k_i^l))\|_{\mathbf{P}_i} \leq \alpha \varepsilon_i.
 \end{aligned}$$

因此, 考虑条件(13), 有下式成立:

$$\begin{aligned}
 & \bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) - x_r(k_i^{l+1} + N(k_i^{l+1}) - 1) \\
 & \leq \|A\|_{\mathbf{P}_i}^{N(k_i^0)-1} \sigma_i + \alpha \varepsilon_i \leq \varepsilon_i.
 \end{aligned}$$

所以 $\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) \in \Omega_i$. 进而终端状态满足:

$$\begin{aligned}
 & \bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) | k_i^{l+1}) - x_r(k_i^{l+1} + N(k_i^{l+1})) \\
 &= A\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) \\
 &\quad + BK_i(\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) \\
 &\quad - x_r(k_i^{l+1} + N(k_i^{l+1}) - 1)) - Ax_r(k_i^{l+1} + N(k_i^{l+1}) - 1) \\
 &= (A + BK_i)(\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) \\
 &\quad - x_r(k_i^{l+1} + N(k_i^{l+1}) - 1)) \\
 &= (A + BK_i)(\bar{x}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) \\
 &\quad - \bar{x}_i^*(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^l) \\
 &\quad + \bar{x}_i^*(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^l) - x_r(k_i^{l+1} + N(k_i^{l+1}) - 1)) \\
 &\leq \|(A + BK_i)\|_{\mathbf{P}_i} \left(\|A\|_{\mathbf{P}_i}^{N(k_i^0)-1} \sigma_i + \alpha \varepsilon_i \right).
 \end{aligned}$$

结合条件(13), 可证终端约束满足.

$\mathcal{U}_i(k_i^{l+1}) \in \mathbb{U}_i$: 可行控制输入构造如式(11)所示, 所以当 $m = 0, \dots, N(k_i^{l+1}) - 2$ 时, k_i^{l+1} 时刻的可行控制输入等于上一触发时刻 k_i^l 的最优控制输入, 即 $\bar{u}_i(k_i^{l+1} + m | k_i^{l+1}) = \bar{u}_i^*(k_i^{l+1} + m | k_i^l) \in \mathbb{U}_i$; 另一方面, 当 $m = N(k_i^{l+1}) - 1$ 时, 由条件(12)可得 $\bar{u}_i(k_i^{l+1} + N(k_i^{l+1}) - 1 | k_i^{l+1}) \in \mathbb{U}_i$.

注3: 条件(12)和(13)是容易满足的. 对于条件(12), 如果控制输入为 $\mathbb{U}_i \triangleq \{u_i \in \mathbb{R}^m : \|u_i\| \leq u_{\max}\}$, 由于 $\|x_i - x_r\|_{\mathbf{P}_i} \leq \alpha \varepsilon_i$, 那么只要设计 K_i 和 $\mathbf{P}_i$ 使得不等式 $\sqrt{\lambda_{\max}(K_i^T K_i)} \sqrt{\lambda_{\min}(\mathbf{P}_i)} \alpha \varepsilon_i \leq u_{\max}$ 成立即可. 其他形式的控制输入约束类似. 对于条件(13), 由于 (A, B) 是可控的, 所以可以设计适合的 K_i 和 $\mathbf{P}_i$ 使得条件(13)满足.

4.2 多智能体一致性分析

本部分对多智能体系统(1)的一致性进行分析, 目的是给出在算法1下多智能体系统达到一致性的充分条件.

定理2: 如果假设1和定理1中的条件满足, 并且以下条件

$$\sigma_i \geq \|A\|_{P_i}(1 + \|A\|_{P_i})\rho_i + \rho_i, \quad (17)$$

$$\|A + BK_i\|_{P_i}\varepsilon_i + \rho_i \leq \varepsilon_i \quad (18)$$

满足, 那么多智能体系统(1)在算法1下能达到定义1中的一致性.

证明: 1) 首先证明如果条件(17)满足, 则触发间隔 $\Delta(k_i^l) \geq 2, \forall l \in \mathbb{N}$, 这样的最小触发间隔是一致性的充分保证. 由触发条件(9), 不等式(14)和条件(17)易得 $\Delta(k_i^l) \geq 2, \forall l \in \mathbb{N}$, 从而预测时域满足 $N(k_i^{l+1}) < N(k_i^l)$, 预测时域会一直递减到1, 这意味着每个智能体的状态 $x_i(k)$ 会有限时间进入集合 Ω_i .

2) 其次证明 Ω_i 是鲁棒不变集. 由 Ω_i 的定义可知:

$\|x_i(k) - x_r(k)\|_{P_i} \leq \varepsilon_i$, 那么根据双模策略有:

$$\begin{aligned} & \|x_i(k+1) - x_r(k+1)\|_{P_i} \\ &= \|Ax_i(k) + BK_i(x_i(k) - x_r(k)) + w_i(k) - Ax_r(k)\|_{P_i} \\ &= \|(A + BK_i)(x_i(k) - x_r(k)) + w_i(k)\|_{P_i} \\ &\leq \|(A + BK_i)\|_{P_i}\varepsilon_i + \rho_i \\ &\leq \varepsilon_i, \end{aligned}$$

其中最后一行不等式由条件(18)得到. 结合1), 2), 令定义1中 $\delta = 1 / \sqrt{\lambda_{\min}(P_i)}$, 则多智能体系统(1)最终能达到定义中的一致.

注4: 不等式(17), (18)是容易成立的. 对于条件(17), 在给定扰动和已设计权重矩阵 P_i 的情况下, σ_i 设计为满足(17)即可. 对于条件(18), 由于 (A, B) 可控, 可以设计 K_i 和 P_i 使得 $\|A + BK_i\|_{P_i} < 1$, 那么 ε_i 设计满足 $(1 - \|A + BK_i\|_{P_i})\varepsilon_i \geq \rho_i$ 即可使得(18)成立.

注5: 注意到本文提出的优化问题可行性充分条件(13)和多智能体系统一致性条件(18)是以诱导范数 $\|\cdot\|_{P_i}$ 形式给出, 而文献[24]中的条件是矩阵2-范数形式, 文献[24]中的条件是本文提出的充分条件的一种特殊情况, 即: P_i 为单位阵; 另一方面, 要使得本文中的条件(13)和(18)成立, 可以设计反馈增益 K_i 和权重矩阵 P_i 两个参数, 由于 (A, B) 可控, 必然存在 K_i 和 P_i 使得 $\|A + BK_i\|_{P_i} < 1$, 而类似的条件在文献[24]中只能通过设计反馈增益 K_i , 且不一定存在 K_i 使得 $\|A + BK_i\| < 1$, 所以本文提出的优化问题可行性充分条件和多智能体系统一致性条件相对于文献[24]更易成立.

5 方法验证

本节主要是通过仿真案例验证算法1的有效性. 考虑的仿真案例是由四个车辆 ($M=4$) 组成的多智能体系统如图1所示, 其中每个车辆的动态方程如文献[24]所示, 经过采样周期 1 s 离散化后为:

$$\begin{cases} r_i(k+1) = r_i(k) + v_i(k) + 0.5u_i(k), \\ v_i(k+1) = v_i(k) + \frac{1}{m_i}u_i(k) + w_i(k), \end{cases} \quad (19)$$

其中 r_i 和 v_i 分别是车辆 $i, i \in \mathcal{V}$ 的位置和速度, m_i 为车辆 i 的质量, $m_i = 1$ kg, w_i 是外部扰动. 车辆的速度约束为 $|v_i| \leq 16$ m/s, 控制约束为 $|u_i| \leq 10$ N, 外部扰动的上界 $\rho_i = 0.01$. 最终的目标是使得每个车辆之间保持恒定的距离, 速度保持相同恒定的值, 即

$$\lim_{k \rightarrow \infty} r_i(k) - d_{ir} = \lim_{k \rightarrow \infty} r_j(k) - d_{jr},$$

$$\lim_{k \rightarrow \infty} v_i(k) = \lim_{k \rightarrow \infty} v_j(k), \forall i, j \in \mathcal{V},$$

其中 d_{ir} 是车辆 i 与虚拟参考信号 x_r 之间期望的相对距离.

初始化每个车辆的初始值. 令状态值 $x_i = [r_i - d_{ir}; v_i]$,

图1 (网络版彩图)四个车辆组成的多智能体系统, 其中的虚线表示车辆之间的信息传输

Figure 1 (Color online) A multi-agent system consisting of four vehicles, where the dashed line represents information transmission between vehicles.

其中每个车辆的起始位置分别是 $r_1(0)=-60$ m, $r_2(0)=-50$ m, $r_3(0)=50$ m, $r_4(0)=70$ m; 起始速度分别为 $v_1(0)=4$ m/s, $v_2(0)=1.5$ m/s, $v_3(0)=1$ m/s和 $v_4(0)=0.5$ m/s; 期望的相对距离为 $d_{1r}=-20$ m, $d_{2r}=-10$ m, $d_{3r}=10$ m, $d_{4r}=20$ m. 参考信号初始值为 $r_r(0)=0$ m, $v_r(0)=2$ m/s.

仿真中, 初始预测时域 $N(k_i^0) = 6$, 权重矩阵 $Q_i = I_2$, $R_i = 1$, $Q_{ij} = 0.1I_2$, $\forall i \in \mathcal{V}, j \in \mathcal{N}_i$. 根据文献[30]中的引理1, $\mathbf{P}_i$ 可以设计为 $\mathbf{P}_i = [2.85 \ 1.27; 1.27 \ 3.09]$. 进而为了满足一致性条件, 根据(17)式, 可以设计 $\sigma_i = 0.052$, 最后根据式(12), (13)和(18), 设计 $K_i = [-0.5354 \ -1.1923]$, $\varepsilon_i = 2.1$, $\forall i, i \in \mathcal{V}$, $\alpha = 0.72$.

使用MATLAB的fmincon函数求解分布式优化问题, 仿真结果如图2和图3所示. 从图2(b)和图3(a)可以看

出, 系统的状态约束和控制输入约束是满足的. 图2(a)和(b)说明了智能体系统达到了一致, 即每个车辆与参考信号的位置保持了设定值的相对距离, 与参考信号的速度保持相等. 图3(b)中显示了4个车辆的触发时刻和预测时域, 可以发现, 一方面优化问题的求解只发生在特定的触发时刻, 另一方面预测时域随着状态靠近终端区域而逐渐减小, 从而算法1有效降低了DMPC算法的计算资源消耗.

6 结论

本文针对线性受扰多智能体系统提出了基于自适应事件触发DMPC方法, 该方法使得多智能体达到一致的同时, 一方面通过事件触发机制减少分布式优化问题

图2 (网络版彩图)四辆车的位置和速度轨迹. (a) 位置图; (b) 速度图

Figure 2 (Color online) Position and velocity trajectories of four vehicles. (a) Positions; (b) velocities.

图3 (网络版彩图)四辆车的控制输入和触发时刻. (a) 控制输入; (b) 触发时刻和预测时域

Figure 3 (Color online) Control inputs and prediction horizons of four vehicles. (a) Control inputs; (b) triggering instants and prediction horizons.

的求解次数, 另一方面通过预测时域的递减降低优化问题求解复杂度, 从而更为有效地降低了DMPC的计算资源消耗. 同时通过收缩的约束方法使得系统的真实状态

在扰动存在下依旧满足状态约束, 系统能够安全运行. 建立了优化问题的可行性和系统一致性的充分条件, 最终用数值案例说明了提出方法的有效性.

参考文献

- 1 Olfati-Saber R, Fax J A, Murray R M. Consensus and cooperation in networked multi-agent systems. *Proc IEEE*, 2007, 95: 215–233
- 2 Ni W, Cheng D. Leader-following consensus of multi-agent systems under fixed and switching topologies. *Syst Control Lett*, 2010, 59: 209–217
- 3 Su Y, Shi Y, Sun C. Distributed model predictive control for tracking consensus of linear multiagent systems with additive disturbances and time-varying communication delays. *IEEE Trans Cybern*, 2021, 51: 3813–3823
- 4 Yazdani S, Haeri M. Robust adaptive fault-tolerant control for leader-follower flocking of uncertain multi-agent systems with actuator failure. *ISA Trans*, 2017, 71: 227–234
- 5 Zhang H T, Zhai C, Chen Z. A general alignment repulsion algorithm for flocking of multi-agent systems. *IEEE Trans Automat Contr*, 2010, 56: 430–435
- 6 Dunbar W B, Murray R M. Distributed receding horizon control for multi-vehicle formation stabilization. *Automatica*, 2006, 42: 549–558
- 7 Xie G Q, Zhang Y. Survey of consensus problem in cooperative control of multi-agent systems (in Chinese). *Appl Res Comput*, 2011, 28: 20352039 [谢光强, 章云. 多智能体系统协调控制一致性问题研究综述. *计算机应用研究*, 2011, 28: 20352039]
- 8 Li S, Wang X. Finite-time consensus and collision avoidance control algorithms for multiple AUVs. *Automatica*, 2013, 49: 3359–3367
- 9 Yuan C, Licht S, He H. Formation learning control of multiple autonomous underwater vehicles with heterogeneous nonlinear uncertain dynamics. *IEEE Trans Cybern*, 2017, 48: 2920–2934
- 10 Liao F, Teo R, Wang J L, et al. Distributed formation and reconfiguration control of VTOL UAVs. *IEEE Trans Contr Syst Technol*, 2016, 25: 270–277
- 11 Rawlings J B, Mayne D Q, Diehl M. *Model Predictive Control: Theory, Computation, and Design*. 2nd ed. Madison: Nob Hill Publishing, 2017
- 12 García C E, Prett D M, Morari M. Model predictive control: Theory and practice—A survey. *Automatica*, 1989, 25: 335–348
- 13 Li H, Shi Y. Robust distributed model predictive control of constrained continuous-time nonlinear systems: A robustness constraint approach. *IEEE Trans Automat Contr*, 2013, 59: 1673–1678
- 14 Dunbar W B. Distributed receding horizon control of dynamically coupled nonlinear systems. *IEEE Trans Automat Contr*, 2007, 52: 1249–1263
- 15 Mi X, Zou Y, Li S. Event-triggered MPC design for distributed systems toward global performance. *Int J Robust Nonlinear Control*, 2018, 28: 1474–1495
- 16 Li H, Yan W, Shi Y, et al. Periodic event-triggering in distributed receding horizon control of nonlinear systems. *Syst Control Lett*, 2015, 86: 16–23
- 17 Ferrari-Trecate G, Galbusera L, Marciandi M P E, et al. Model predictive control schemes for consensus in multi-agent systems with single- and double-integrator dynamics. *IEEE Trans Automat Contr*, 2009, 54: 2560–2572
- 18 Cheng Z, Zhang H T, Fan M C, et al. Distributed consensus of multi-agent systems with input constraints: A model predictive control approach. *IEEE Trans Circuits Syst I*, 2014, 62: 825–834
- 19 Gao Y, Dai L, Xia Y, et al. Distributed model predictive control for consensus of nonlinear second-order multi-agent systems. *Int J Robust Nonlinear Control*, 2017, 27: 830–842
- 20 Ma A, Liu K, Zhang Q, et al. Event-triggered distributed MPC with variable prediction horizon. *IEEE Trans Automat Contr*, 2021, 66: 4873–4880
- 21 Zou Y, Su X, Li S, et al. Event-triggered distributed predictive control for asynchronous coordination of multi-agent systems. *Automatica*, 2019, 99: 92–98
- 22 Zhan J, Hu Y, Li X. Adaptive event-triggered distributed model predictive control for multi-agent systems. *Syst Control Lett*, 2019, 134: 104531
- 23 Hashimoto K, Adachi S, Dimarogonas D V. Event-triggered intermittent sampling for nonlinear model predictive control. *Automatica*, 2017, 81: 148–155
- 24 Zhan J, Jiang Z P, Wang Y, et al. Distributed model predictive consensus with self-triggered mechanism in general linear multiagent systems.

- IEEE Trans Ind Inf, 2018, 15: 3987–3997
- 25 Yang Y, Ding B. Event-triggered distributed receding horizon control for tracking and formation of homogeneous multi-agent systems. *ISA Trans*, 2019, 85: 151–160
- 26 Qian Y Y, Liu L, Feng G. Distributed event-triggered adaptive control for consensus of linear multi-agent systems with external disturbances. *IEEE Trans Cybern*, 2018, 50: 2197–2208
- 27 Li P, Wang T, Kang Y, et al. Event-triggered adaptive horizon model predictive control for perturbed nonlinear systems. In: IEEE Conference on Decision and Control. Jeju Island, 2020. 2392–2397
- 28 Wang T, Kang Y, Li P, et al. Robust approximation-based event-triggered MPC for constrained sampled-data systems. *J Syst Sci Complex*, 2021, <https://doi.org/10.1007/s11424-021-0073-9>
- 29 Michalska H, Mayne D Q. Robust receding horizon control of constrained nonlinear systems. *IEEE Trans Automat Contr*, 1993, 38: 1623–1633
- 30 Chen H, Allgöwer F. A quasi-infinite horizon nonlinear model predictive control scheme with guaranteed stability. *Automatica*, 1998, 34: 1205–1217

Adaptive event-triggered distributed model predictive control for tracking consensus of multiagent systems

WANG Tao¹, KANG Yu^{1,2} & LI PengFei¹

¹ Department of Automation, University of Science and Technology of China, Hefei 230026, China;

² Institute of Advanced Technology, University of Science and Technology of China, Hefei 230088, China

The tracking consensus of multiagent systems based on distributed model predictive control (DMPC) is a current research hotspot. However, as a research difficulty, effective solutions to deal with external disturbances and reduce computational resource consumption are lacking. This paper proposes a new constraint tightening scheme and establishes a new distributed optimization problem. Moreover, an adaptive event-triggering mechanism is designed using the idea of variable prediction horizon, and an adaptive event-triggered DMPC approach for the tracking consensus of multiagent systems is proposed, effectively solving the problems of the unsatisfaction of constraints and computational resource consumption in the tracking consensus of multiagent systems. The effectiveness of the proposed approach is validated by a multivehicle system simulation.

multiagent systems, consensus, distributed model predictive control, event-triggered control, adaptive control

doi: [10.1360/SST-2021-0379](https://doi.org/10.1360/SST-2021-0379)