

城市交通区域的迭代学习边界控制

金尚泰[†], 丁莹, 殷辰堃, 侯忠生

(北京交通大学 电子信息工程学院, 北京 100044)

摘要: 已有的边界控制方法主要是基于模型的反馈控制算法,其实际应用效果受制于模型参数的标定和环境的影响. 迭代学习控制以完全跟踪为目标,仅利用较少的模型信息就可以沿迭代轴实现对系统期望输出的完全跟踪. 基于城市交通流的重复特性,提出一种城市交通区域的迭代学习边界控制方法,给出跟踪误差收敛性分析. 以日本横滨区域为对象分别进行3种场景的仿真:早高峰、晚高峰和中心区域拥堵. 仿真结果表明,迭代学习控制方法对于各种场景下的区域路网交通均能达到较为理想的控制效果.

关键词: 边界控制; 宏观基本图; 迭代学习控制

中图分类号: TP273

文献标志码: A

Iterative learning perimeter control for urban traffic region

JIN Shang-tai[†], DING Ying, YIN Chen-kun, HOU Zhong-sheng

(School of Electronic and Information Engineering, Beijing Jiaotong University, Beijing 100044, China)

Abstract: At present, macroscopic fundamental diagram(MFD)-based perimeter control methods are mostly based on the feedback control algorithm, and their practical application are susceptible to environment. Iterative learning control(ILC) can be used in repetitive regional perimeter control of urban traffic with the features of tracking completely. Therefore, based on the repetitive nature of urban traffic flow, an iterative learning perimeter control for an urban region is presented, and the convergence of tracking error is analyzed. Three scenarios, namely, morning and evening peak, central area congestion, and inhomogeneous cell, are simulated. The results show that the ILC method for road network can obtain ideal control effects under different scenarios.

Keywords: perimeter control; macroscopic fundamental diagram; iterative learning control

0 引言

1969年,Godfrey^[1]首次提出了宏观基本图(MFD)的物理模型,但直到2007年才由Daganzo^[2]阐述了MFD的理论性原理. MFD可以描述网络中移动车辆总数和网络运行水平之间的普遍关系. MFD是路网中客观存在的普遍规律,任何规模的路网都拥有自己的MFD. 根据MFD理论,相关参数的计算公式^[3]如下:

$$N = \sum_i k_i l_i, \quad (1)$$

$$q^w = \frac{\sum_i q_i l_i}{\sum_i l_i}, \quad (2)$$

$$k^w = \frac{\sum_i k_i l_i}{\sum_i l_i}, \quad (3)$$

$$o^w = k^w s = \frac{\sum_i o_i l_i}{\sum_i l_i}. \quad (4)$$

其中: N 为路网累积车辆数(veh); q^w 、 k^w 、 o^w 分别为加权车流量(veh/s)、加权路网密度(veh/km)和加权时间占有率; i 、 l_i 分别为路段 i 和路段 i 的长度(km); q_i 、 k_i 、 o_i 分别为路段 i 的车流量 veh/s、路网密度(veh/km)和时间占有率; s 为车辆的平均车长(km).

依据上述MFD计算公式,可建立城市路网中加权车流量 q^w 与路网累积车辆数 N 的关系,如图1所

收稿日期: 2017-03-20; 修回日期: 2017-07-05.

基金项目: 国家自然科学基金项目(61573054, 61433002, 61403025).

责任编辑: 王伟.

作者简介: 金尚泰(1976—), 男, 副教授, 从事数据驱动控制理论与应用等研究; 丁莹(1991—), 女, 硕士生, 从事城市交通区域控制方法的研究.

[†]通讯作者. E-mail: shtjin@bjtu.edu.cn

示. 当 $N < N_C$ (临界车辆数) 时, 路网处于非拥堵状态, 随着 N 的增大, q^w 逐步增大, 直到增至 q_C^w (最大加权流量) 时路网处于饱和状态; 当 $N > N_C$ 时, 路网处于拥堵状态, 此时 q^w 随着 N 的增大而减少.

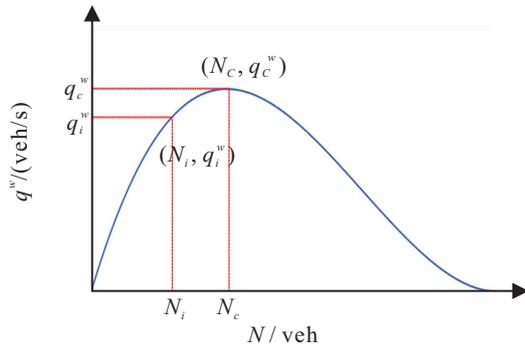


图1 宏观基本图^[3]

Gerolimimis等^[4]首次在日本横滨发现MFD在拥堵的城市网络中的动态特性. 此后, 围绕MFD的研究不断展开, 相关研究主要集中在对MFD的存在性、形状、适用条件、影响因素以及运用方向进行验证与研究. Keyvan-Ekbatani等^[5]设计了一种基于城市网络基本图(FD)的反馈门控制方法, 并将这一方法用于希腊的哈尼亚市, 仿真结果显示交通网络的延时显著下降, 车流的平均速度增大. Aboudolas等^[6]设计了多变量反馈调整器和积分反馈调整器来调节若干个拥堵程度不同的小区, 使各小区的拥堵程度尽可能相同, 并使吞吐量达到最大化, 以美国的旧金山市区域为对象进行仿真, 结果表明, 在状态可观测的条件下, 该方法的重大优势在于计算量小且不需要未来的交通需求数据. Gerolimimis等^[7]设计了模型预测控制方法(MPC), 用于解决两个区域的边界控制问题, 并与反馈控制方法作了对比, 结果显示, 相比于基于贪婪算法的反馈控制方法, 模型预测控制方法的控制性能有了显著提高. Haddad等^[8]设计了一种鲁棒边界控制器, 不同于已有的研究成果, 该控制器可以用于同时解决MFD的不确定性和控制约束问题. 随后, 杜怡曼等^[9]提出了基于宏观基本图和反馈门的区域总量动态调控为主、传统优化为辅的交通管理新手段, 通过区域边界设置的“反馈门”控制网络流入量, 将网络车辆总数维持在合理可行范围内, 以提高或维持网络流量, 结果证明, 区域总量动态调控能够保障区域交通流的稳定和有序, 并能提高区域交通流通行效率.

综合分析, 已有的边界控制方法主要是基于模型的反馈控制算法, 其实际应用效果受制于模型参数的

标定和环境的影响. 而本文所采用的迭代学习控制算法则不依赖于精确的模型, 尤其适用于具有重复性的交通控制中.

迭代学习控制(ILC)由Arimoto等^[10]在1984年首次提出, 用于解决有限区间内重复运行系统的跟踪控制问题. 之后, 一系列关于ILC的理论与应用的重大研究成果相继被多位学者所发现并提出^[11-12]. ILC通过应用先前操作的信息获得能够产生期望输出轨迹的控制输入, 以改善控制质量. 它不依赖于动态系统精确的数学模型, 仅需较少的先验知识和计算量, 同时适应性强, 易于实现, 适用于有着强非线性、难以建模的系统以及高精度轨迹控制问题.

2007年以来, Hou等^[13-15]利用城市交通流的重复特性, 将迭代学习控制应用于快速路匝道控制, 并取得了很好的控制效果. 戴喜生等^[16]基于快速路交通流常微分模型设计了PD型迭代学习控制方法, 给出算法收敛性分析, 通过数值仿真验证了算法有效性. 闫飞等^[17]基于城市交通流明显的重复性特征提出了一种基于迭代学习控制的城市区域交通信号控制策略, 通过对交通信号的迭代控制, 使路段的平均占有率收敛于期望占有率, 从而使绿灯时间得到充分利用并防止交通拥堵的发生. 随后, 闫飞等^[18]结合路网宏观基本图的特性, 分析了基于迭代学习的交通信号控制策略对路网交通态势的影响. Wang等^[19]研究了在饱和和交通条件下考虑车辆吞吐量和剩余排队车辆长度的信号迭代整定(IT)方案, 并进行了收敛性分析. 与传统的预定时策略不同, 在IT策略中可通过迭代算法自动进行信号微调. 最后选取新加坡交通繁忙的联邦大道进行仿真实验, 结果验证了所提出方案的有效性和鲁棒性.

本文介绍了基于MFD的城市交通区域模型, 基于城市区域交通流的重复运行特性提出了一种基于MFD的城市交通区域迭代学习边界控制方法, 用于缓解城市中心区域的拥堵问题, 并进行了收敛性分析. 迭代学习边界控制方案是一种开闭环迭代学习控制算法, 它能同时利用系统前次运行和本次运行的信息实现误差的快速收敛, 保证高精度跟踪的同时具有更好的抗扰动能力. 以日本横滨区域为对象进行了3种场景的仿真: 早高峰、晚高峰和中心区域拥堵. 仿真结果显示, 迭代学习控制方法对于各种场景下的区域路网交通情况均能达到较为理想的控制效果.

1 基于MFD的城市交通区域模型

考虑如图2所示的均匀城市区域^[8]. 其中: 小区1为中心区域, 小区2为中心区域的周围区域, 基于车辆守恒方程的交通模型为

$$\dot{n}_{11}(t) = q_{11}(t) + q_{21}(t)u_2(t) - \frac{n_{11}(t)G_1(n_1(t))}{n_1(t)}, \quad (5)$$

$$\dot{n}_{12}(t) = q_{12}(t) - \frac{n_{12}(t)G_1(n_1(t))u_1(t)}{n_1(t)}, \quad (6)$$

$$n_1(t) = n_{11}(t) + n_{12}(t). \quad (7)$$

其中: $q_{11}(t)$ (veh/s)为小区1的内部交通需求, $q_{12}(t)$ (veh/s)为小区1到小区2的交通需求, $q_{21}(t)$ (veh/s)为小区2到小区1的交通需求; $n_{11}(t)$ (veh)为 t 时刻小区1中以小区1为目的地的路网累积车辆数, $n_{12}(t)$ (veh)为 t 时刻小区1中以小区2为目的地的路网累积车辆数; $n_1(t)$ (veh)为 t 时刻小区1的路网累积车辆数; $G_1(n_1(t))$ (veh/s)根据宏观基本图定义, 是小区1内总累积车辆数为 $n_1(t)$ 时该区域的完成旅行流量. 区域完成旅行流量是指发生转移的车流量总和, 即区域内部流向区域外部的流量加上区域内部自身的流量.

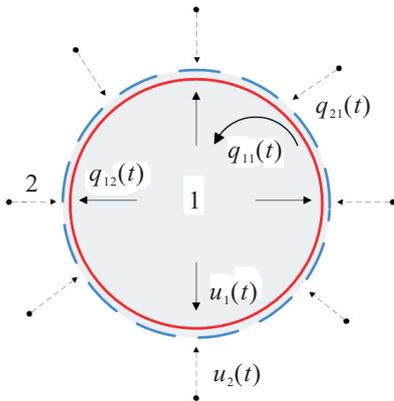


图2 城市交通区域模型

边界控制是指控制量作用于城市区域的边界上, 如图2所示, 控制输入 $u_1(t)$ 和 $u_2(t)$ 分别用来控制 t 时刻从小区1到小区2和从小区2到小区1在小区边界处的流量比.

2 迭代学习控制器设计

在城市交通区域边界控制问题中, 每天的车辆总数会在早上7点到9点和傍晚5点到7点达到高峰, 其他时间则相对较为平稳, 除一些意外因素影响外, 认为每天的交通量是近似重复的^[20-21]. 迭代学习控制利用前几次操作得到的控制输入和误差信息修正本次操作的控制输入, 可提高控制任务的完成效果^[22-23], 适用于具有不确定性和复杂非线性的城市

交通区域边界控制.

通过引入以天为迭代次数的指标 i , 城市交通模型改写为

$$\dot{n}_{11,i}(t) = q_{11}(t) + q_{21}(t)u_{2,i}(t) - \frac{n_{11,i}(t)G_1(n_{1,i}(t))}{n_{1,i}(t)}, \quad (8)$$

$$\dot{n}_{12,i}(t) = q_{12}(t) - \frac{n_{12,i}(t)G_1(n_{1,i}(t))u_{1,i}(t)}{n_{1,i}(t)}, \quad (9)$$

$$n_{1,i}(t) = n_{11,i}(t) + n_{12,i}(t), \quad (10)$$

其中交通需求量 $q_{11}(t)$ 、 $q_{12}(t)$ 、 $q_{21}(t)$ 未加入迭代指标的原因是交通区域交通需求是具有重复性的.

针对城市交通区域的迭代学习边界控制问题是: 在给定状态方程、实时交通需求 $q_{11}(t)$ 、 $q_{12}(t)$ 、 $q_{21}(t)$ 、初始累积车辆数 $n_1(0)$ 和最终累积车辆数 $n_{1,ss}$ 的条件下, 以根据初始累积车辆数 $n_1(0)$ 和最终累积车辆数 $n_{1,ss}$ 规划出的期望累积车辆数变化曲线 $n_{1,d}(t)$ 为控制目标, 设计边界控制输入 $u_1(t)$ 和 $u_2(t)$, 使得小区1内的累计车辆数尽量接近 $n_{1,d}(t)$.

系统输出跟踪误差定义为

$$e_i(t) = n_{1,d}(t) - n_{1,i}(t). \quad (11)$$

基于ILC的城市区域边界控制策略包括开环的迭代学习控制环路和反馈控制环路, 表达式如下:

$$\mathbf{u}_{i+1}(t) = \mathbf{u}_i(t) + \mathbf{\Gamma} \dot{e}_i(t) + \mathbf{L} e_{i+1}(t). \quad (12)$$

其中: $\mathbf{u}_i(t) = [u_{1,i}(t), u_{2,i}(t)]^T$ 为控制输入矩阵, $\mathbf{\Gamma}$ 为前馈迭代学习增益矩阵, \mathbf{L} 为反馈控制增益矩阵.

由于迭代学习边界控制算法(12)同时利用了系统前一次运行的控制信息 $\mathbf{u}_i(t)$ 和误差信息 $e_i(t)$ 以及当前迭代的误差信息 $e_{i+1}(t)$, 可保证较快的系统学习收敛速度, 提高跟踪精度, 同时增强抗干扰能力.

3 收敛性分析

令

$$\mathbf{n}_i(t) = [n_{11,i}(t), n_{12,i}(t)]^T,$$

$$\mathbf{q}(t) = [q_{11}(t), q_{12}(t)]^T,$$

式(3)可以改写成向量形式

$$\begin{cases} \dot{\mathbf{n}}_i(t) = \mathbf{A}(\mathbf{n}_i(t)) + \mathbf{q}(t) + \mathbf{B}(\mathbf{n}_i(t))\mathbf{u}_i(t), \\ \mathbf{n}_{1,i}(t) = \mathbf{C}\mathbf{n}_i(t). \end{cases} \quad (13)$$

其中

$$\mathbf{A}(\mathbf{n}_i(t)) = \left[\frac{G_1(n_{1,i}(t))}{n_{1,i}(t)}, 0 \right]^T, \quad \mathbf{C} = [1, 1],$$

$$\mathbf{B}(\mathbf{n}_i(t)) = \begin{bmatrix} 0, & q_{21}(t) \\ -\frac{G_1(n_{12,i}(t))}{n_{1,i}(t)} & 0 \end{bmatrix}.$$

假设1 $A(\mathbf{n})$ 、 $B(\mathbf{n})$ 关于 \mathbf{n} 满足全局一致 Lipschitz 条件,即对于 $\mathbf{n}_1, \mathbf{n}_2 \in R^n$, 有

$$\begin{aligned} \|A(\mathbf{n}_1) - A(\mathbf{n}_2)\| &\leq k_A \|\mathbf{n}_1 - \mathbf{n}_2\|, \\ \|B(\mathbf{n}_1) - B(\mathbf{n}_2)\| &\leq k_B \|\mathbf{n}_1 - \mathbf{n}_2\|, \\ \|B(\mathbf{n}_i)\| &\leq M_1, \end{aligned}$$

其中 k_A, k_B 为 Lipschitz 常数.

假设2 系统满足相同初始条件,即 $\mathbf{n}_i(0) = \mathbf{n}_d(0)$, 其中 $\mathbf{n}_d(0)$ 为期望的初始状态值.

假设3 存在控制输入 $\mathbf{u}_d(t)$ 使系统在有限迭代时间 $[0, T]$ 内完全跟踪上期望曲线 $\mathbf{n}_{1,d}(t)$, 且 $b_1 = \sup_{0 \leq t \leq T} \|\mathbf{u}_d(t)\|$.

假设1 成立的原因是交通模型在整个区间内都是连续可微的, 所以其满足全局一致 Lipschitz 条件; 另一方面, 实际交通系统的状态、流量、累积车辆数在实际中都不可能是无限的, 并且时间区间也是有限的. 假设2 要求系统初始状态值与期望值保持一致. 在实际中, 如果这种情况未发生, 则总是可以在跟踪的开始阶段重新修正目标曲线.

定理1 满足假设1~假设3的条件下, 选取一个合适学习增益矩阵 Γ , 满足 $\|I - \Gamma CB(\mathbf{n}_i(t))\| \leq \rho < 1$, 则系统输出收敛于期望输出, 即

$$\lim_{i \rightarrow \infty} n_{1,i}(t) = n_{1,d}(t), \quad t \in [0, T].$$

注1 限于篇幅, 本文不再给出证明, 可参考文献 [13,24] 进行证明.

4 仿真分析

为验证城市交通区域的迭代学习边界控制方法的有效性, 利用 Matlab 对小区 1 的路网累积车辆数变化曲线进行跟踪仿真实验. 本文采用迭代学习边界控制方法对日本横滨区域路网进行边界控制, 主要包括以下场景 (采样时间为 30s): 早高峰、晚高峰和中心区域拥堵. 鉴于实际交通系统中参数每次迭代运行都是变化的, 仿真考虑两种交通参数迭代变化情况: MFD 形状的变化和交通流量需求的变化. 用于仿真的 MFD 模型取自文献 [8], 与其不同的是, MFD 模型参数是随着迭代运行发生变化的, 具体设置如下:

$$\begin{aligned} G_1(n_1(i, t)) = & \frac{10^{-7}(1.4877 + v(i, t))n_1^3(i, t)}{3600} - \\ & \frac{10^{-3}(2.9815 + w(i, t))n_1^2(i, t)}{3600} + \\ & \frac{(15.0912 + r(i, t))n_1(i, t)}{3600}. \end{aligned} \quad (14)$$

其中

$$\begin{aligned} v(i, t) &= 0.1 \sin\left(\frac{2\pi t}{N} + \frac{\pi(i-1)}{10}\right), \\ w(i, t) &= 0.2 \sin\left(\frac{2\pi t}{N} + \frac{\pi(i-1)}{10}\right), \\ r(i, t) &= \sin\left(\frac{2\pi t}{t} + \frac{\pi(i-1)}{10}\right), \\ t &= 1, 2, \dots, N, \quad i = 1, 2, \dots. \end{aligned}$$

早高峰交通流量需求迭代变化设置如下:

$$\begin{aligned} q_{11}(i, t) &= 0.75 + q(i, t), \\ q_{12}(i, t) &= 1.5 + q(i, t), \\ q_{21}(i, t) &= 5 + q(i, t). \end{aligned}$$

晚高峰交通流量需求迭代变化设置如下:

$$\begin{aligned} q_{11}(i, t) &= 0.75 + q(i, t), \\ q_{12}(i, t) &= 5 + q(i, t), \\ q_{21}(i, t) &= 1.5 + q(i, t). \end{aligned}$$

其中

$$\begin{aligned} q(i, t) &= 0.1 \sin\left(\frac{2\pi t}{N} + \frac{\pi(i-1)}{10}\right), \\ t &= 1, 2, \dots, N, \quad i = 1, 2, \dots, \end{aligned}$$

N 为总采样点数.

$q_{12}(i, t)$ 和 $q_{21}(i, t)$ 在早晚高峰的设定值是相反的, 这符合人们早晚高峰的实际出行情况. 此外, 中心区域 (小区 1) 拥堵仿真场景中需求量的设置参照早高峰^[8] 设置如下:

$$n_{1,d}(t) = \begin{cases} n_1(0) + \alpha t, & t < \frac{n_{1,ss} - n_1(0)}{\alpha}; \\ n_{1,ss}, & t \geq \frac{n_{1,ss} - n_1(0)}{\alpha}. \end{cases} \quad (15)$$

其中 α 为常数, 根据实际情况设计.

4.1 早高峰

早高峰初始累积车辆数 $n_1(0) = 2400$ veh, 最终累积车辆数 $n_{1,ss} = 3060$ veh, 曲线斜率 $\alpha = 20$, 迭代学习增益 $\Gamma = [0.02, -0.02]^T$, 反馈控制增益 $L = [1, -1]^T$, 采样点个数 $N = 100$, 迭代次数为 10. 应用迭代学习控制器 (12) 的仿真结果如图 3 所示.

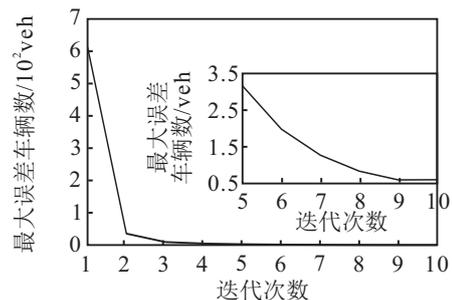


图3 每次迭代最大误差 (早高峰)

4.2 晚高峰

早高峰初始累积车辆数 $n_1(0) = 2400(\text{veh})$, 最终累积车辆数 $n_{1,ss} = 3060(\text{veh})$, 曲线斜率 $\alpha = 20$, 迭代学习增益 $\Gamma = [0.02, -0.02]^T$, 反馈控制增益 $L = [1, -1]^T$, 采样点个数 $N = 100$, 迭代次数为10次. 应用迭代学习控制器(12)的仿真结果如图4所示.

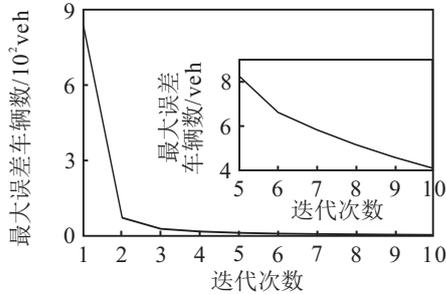


图4 每次迭代最大误差(晚高峰)

4.3 中心区域拥堵

早高峰初始累积车辆数 $n_1(0) = 7000 \text{ veh}$, 最终累积车辆数 $n_{1,ss} = 3600 \text{ veh}$, 曲线斜率 $\alpha = 20$, 迭代学习增益 $\Gamma = [0.02, -0.02]^T$, 反馈控制增益 $L = [1, -1]^T$, 采样点个数 $N = 100$, 迭代次数为10. 应用迭代学习控制器(12)的仿真结果如图5所示.

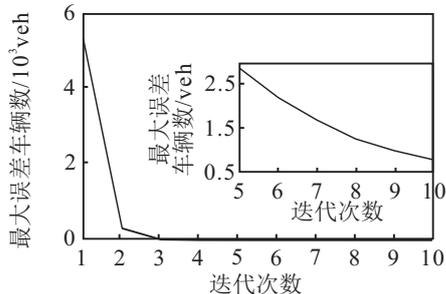


图5 每次迭代最大误差(中心区域拥堵)

由图5可见, 迭代学习控制器针对不同的路网情况都能达到较高的控制精度和较快的收敛速度, 并且可以较好地跟踪期望曲线, 当迭代次数大于10次以后, 每次迭代的车辆数最大误差均小于3辆.

5 结论

迭代学习控制是一种无模型控制方法, 经过足够次数的迭代学习后可以保证较高的控制精度, 因此适用于如城市交通区域边界控制这类控制目标重复的复杂非线性系统. 宏观基本图作为路网所固有的属性, 具有很大的实际运用价值, 特别是从宏观层面对路网进行交通管理与控制方面具有深远意义^[3]. 本文基于迭代学习控制策略和路网的宏观基本图属性, 从宏观层面对不同路网情况进行了仿真. 仿真结果表明, 通过在城市中心区域边界上使用迭代学习控制器可以很好地控制中心区域总的累积车辆数, 从而使路

网通行能力达到最大化.

参考文献(References)

- [1] Godfrey J W. The mechanism of a road network[J]. Traffic Engineering and Control, 1969, 11(7): 323-327.
- [2] Daganzo C F. Urban gridlock: Macroscopic modeling and mitigation approaches[J]. Transportation Research Part B, 2007, 41: 49-62.
- [3] 林晓辉. 基于MFD的路网周边交通控制策略与仿真[J]. 中外公路, 2014, 34(4): 353-356.
(Liu X H. Road network traffic control strategy and simulation based on MFD[J]. J of China and Foreign Highway, 2014, 34(4): 353-356.)
- [4] Geroliminis N, Daganzo C F. Existence of urban-scale macroscopic fundamental diagrams: Some experimental finding[J]. Transportation Research Part B, 2008, 42: 759-770.
- [5] Keyvan-Ekbatani M, Kouvelas A, Papamichail I, et al. Exploiting the fundamental diagram of urban networks for feedback-based gating[J]. Transportation Research Part B, 2012, 46: 1393-1403.
- [6] Aboudolas K, Geroliminis N. Perimeter and boundary flow control in multi-reservoir heterogeneous networks[J]. Transportation Research Part B, 2013, 55: 265-281.
- [7] Geroliminis N, Haddad J, Ramezani M. Optimal perimeter control for two urban regions with macroscopic fundamental diagrams: A model predictive approach[J]. IEEE Trans on Intelligent Transportation Systems, 2013, 14(1): 348-359.
- [8] Haddad J, Shraiber A. Robust perimeter control design for an urban region[J]. Transportation Research Part B, 2014, 68: 315-332.
- [9] 杜怡曼, 吴建平. 基于宏观基本图的区域交通总量动态调控技术[J]. 交通运输系统工程与信息, 2014, 14(3): 162-167.
(Du Y M, Wu J P. MFD-Based regional traffic volume dynamic control[J]. J of Transportation Systems Engineering and Information Technology, 2014, 14(3): 162-167.)
- [10] Arimoto S, Kawamura S, Miyazaki S. Bettering operation of robots by learning[J]. J of Robotics Systems, 1984, 1(2): 123-140.
- [11] Ahn H S, Chen Y Q, Moore K L. Iterative learning control: Brief survey and categorization[J]. IEEE Trans on Systems, Man, and Cybernetics, Part C, 2007, 37(6): 1099-1121.
- [12] Xu J X. A survey on iterative learning control for nonlinear systems[J]. Int J of Control, 2011, 84(7): 1275-1294.
- [13] Hou Z S, Xu J X, Yan J W. An iterative learning approach for density control of freeway traffic flow via ramp metering[J]. Transportation Research Part C, 2008, 16: 71-97.
- [14] Hou Z S, Xu X, Yan J W, et al. A complementary

modularized ramp metering designing approach based on iterative learning control and ALINEA[J]. IEEE Trans on Intelligent Transportation Systems, 2011, 12(4): 1305-1318.

[15] Hou Z S, Yan J W, Xu J X, et al. Modified iterative-learning-control-based ramp metering strategies for freeway traffic control with iteration-dependent factors[J]. IEEE Trans on Intelligent Transportation Systems, 2012, 13(2): 608-618.

[16] 戴喜生, 杨峰, 郭亚君, 等. 快速路交通流常微分模型的PD型迭代学习控制[J]. 广西科技大学学报, 2014, 25(3): 21-25.
(Dai X S, Yang F, Guo Y J, et al. A PD iterative learning control of an ordinary differential freeway traffic flow model[J]. J of Guangxi University of Science and Technology, 2014, 25(3): 21-25.)

[17] 闫飞, 田福礼, 史忠科. 城市区域交通信号迭代学习控制策略[J]. 控制与决策, 2015, 30(8): 1411-1416.
(Yan F, Tian F L, Shi Z K. Iterative learning control strategy for traffic signal of urban area[J]. Control and Decision, 2015, 30(8): 1411-1416.)

[18] 闫飞, 田福礼, 史忠科. 城市交通信号的迭代学习控制及其对路网宏观基本图的影响[J]. 控制理论与应用, 2016, 33(5): 645-652.
(Yan F, Tian F L, Shi Z K. Iterative learning control for urban traffic signals and the impacts on macroscopic fundamental diagram of road networks[J]. Control Theory & Applications, 2016, 33(5): 645-652.)

[19] Wang Y, Wang D W, Jin S T, et al. Iterative tuning strategy for setting phase splits with anticipation of traffic demand in urban traffic network[J]. IET Control Theory and Applications, 2016, 10(12): 1469-1479.

[20] Hou Z S, Xu J X, Zhong H W. Freeway traffic control using iterative learning control-based ramp metering and speed signaling[J]. IEEE Trans on Vehicular Technology, 2007, 56(2): 466-477.

[21] Hou Z S, Li X Y. Repeatability and similarity of traffic flow and long term prediction[J]. IEEE Trans on Intelligent Transportation Systems, 2016, 17(6): 1786-1796.

[22] 许建新, 侯忠生. 学习控制的现状与展望[J]. 自动化学报, 2005, 31(6): 943-955.
(Xu J X, Hou Z S. On learning control: the state of the art and perspective[J]. Acta Automatica Sinica, 2005, 31(6): 943-955.)

[23] 李仁俊, 韩正之. 迭代学习控制综述[J]. 控制与决策, 2005, 20(9): 961-966.
(Li R J, Han Z Z. Survey of iterative learning control[J]. Control and Decision, 2005, 20(9): 961-966.)

[24] 孙明轩, 黄宝健. 迭代学习控制[M]. 北京: 国防工业出版社, 1999: 18-20.
(Sun M X, Huang B J. Iterative learning control[M]. Beijing: Defence Industry Press, 1999: 18-20.)

(责任编辑: 郑晓蕾)

下 期 要 目

基于区间观测器的动态系统故障诊断技术综述 杨光红, 等

一种统一的鲁棒自适应控制方法及近期自适应控制结果综述 温长云, 等

网络稳定性与控制的小增益原理: 回顾与近期进展 姜钟平, 等

饱和约束控制系统的吸引域估计 林宗利, 等

因果关系与因体控制初探 郭 雷, 等

高速列车牵引系统故障诊断与预测技术综述 姜 斌, 等

有色冶金过程不确定优化方法探讨 阳春华, 等

滤波器组框架理论及其在图信号处理中的应用 柴 利, 等

进化高维多目标优化算法研究综述 刘建昌, 等

鲁棒与最优控制在伺服系统中的应用 苏为洲, 等

基于声纳图像的水下目标检测、识别与跟踪研究综述 郭 戈, 等

脉冲神经网络: 模型、学习算法与应用 程 龙, 等

智慧能源——人工智能技术在电力系统中的应用与展望 孙秋野, 等

混杂奇异摄动系统的研究综述 王燕舞, 等

受限布尔网络发展现状 冯俊斌, 等