

# 多步 $k$ 最近邻初值寻优的气压模拟系统遗忘迭代学习控制

杨 露, 陈春俊<sup>†</sup>, 王 欢, 王东威

(西南交通大学 机械工程学院, 四川 成都 610031; 轨道交通运维技术与装备四川省重点实验室, 四川 成都 610031)

**摘要:** 高速列车车内压力波动过大会对乘客舒适性造成影响, 而气压模拟系统是一套通过对车内模拟气压跟踪控制, 实现对乘客舒适性进行研究的装置. 为解决系统历史运行数据利用率低以及存在迭代初始误差导致系统收敛速度慢的问题, 采用 $k$ 最近邻( $k$ NN)算法, 建立一种基于历史控制信息的最优初次控制信号提取方法, 并根据迭代学习控制的基本原理, 将最优控制初值输入到带遗忘因子的迭代学习控制器中, 通过不断迭代来实现车内期望气压轨迹的跟踪控制, 并和基于大数据的迭代学习控制以及传统PID迭代学习控制进行对比分析. 仿真结果表明: 基于多步 $k$ NN的遗忘迭代学习控制收敛速度更快、系统抖动程度更小、控制精度更高以及算法鲁棒性更好.

**关键词:** 高速列车; 气压模拟系统;  $k$ 最近邻算法; 迭代学习控制; PID控制; 初值问题; 收敛速度

**引用格式:** 杨露, 陈春俊, 王欢, 等. 多步 $k$ 最近邻初值寻优的气压模拟系统遗忘迭代学习控制. 控制理论与应用, 2021, 38(3): 309–317

DOI: 10.7641/CTA.2020.00393

## Forgetting iterative learning control of air pressure simulation system based on multi-step $k$ nearest neighbor initial value optimization

YANG Lu, CHEN Chun-jun<sup>†</sup>, WANG Huan, WANG Dong-wei

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu Sichuan 610031, China;  
Technology and Equipment of Rail Transit Operation and Maintenance Key Laboratory of Sichuan Province,  
Chengdu Sichuan 610031, China)

**Abstract:** The excessive pressure fluctuation in the high-speed train has an impact on the passenger comfort, and the air pressure simulation system is a device to study the passenger comfort by tracking and controlling the simulated air pressure in the train. In order to solve the problems of low utilization rate of system historical operation data and slow convergence speed caused by iterative initial error, the  $k$  nearest neighbor ( $k$ NN) algorithm is adopted to establish an optimal initial control signal extraction method based on historical control information. According to the basic principle of iterative learning control, the initial value of the optimal control is input into the iterative learning controller with forgetting factor, and the tracking control of the desired air pressure in the train is realized through continuous iteration. And compared with the iterative learning control based on big data and the traditional PID iterative learning control. The simulation results show that the forgetting iterative learning control based on multi-step  $k$ NN has faster convergence speed, less system jitter, higher control accuracy and better robustness of the algorithm.

**Key words:** high-speed train; air pressure simulation system;  $k$  nearest neighbor algorithm; iterative learning control; PID control; initial value problems; convergence speed

**Citation:** YANG Lu, CHEN Chunjun, WANG Huan, et al. Forgetting iterative learning control of air pressure simulation system based on multi-step  $k$  nearest neighbor initial value optimization. *Control Theory & Applications*, 2021, 38(3): 309–317

## 1 引言

当列车高速通过隧道时, 车体周围的空气会被急剧压缩且受到隧道壁面的影响不能及时扩散, 从而形成剧烈的隧道压力波, 这些复杂的隧道压力波通过车体刚度变形、车体缝隙以及换气系统风道等进入车内,

引起车内压力波动<sup>[1-2]</sup>, 若车内压力变化量与变化率超过一定限值时, 乘客出现耳鸣、耳痛、恶心等现象, 进而影响其舒适性<sup>[3]</sup>. 川藏铁路具有高海拔差隧道、特长隧道以及连续隧道群的典型特征, 当列车通过这些隧道时, 车外隧道气压波动更为复杂, 对车内压力

收稿日期: 2020-06-28; 录用日期: 2020-10-08.

<sup>†</sup>通信作者. E-mail: cjchen@swjtu.edu.cn; Tel.: +86 28-87600714.

本文责任编辑: 陈增强.

国家自然科学基金项目(51975487), 轨道交通运维技术与装备四川省重点实验室开放基金课题(2019YW003)资助.

Supported by the National Natural Science Foundation of China (51975487) and the Open Fund Project of Technology and Equipment of Rail Transit Operation and Maintenance Key Laboratory of Sichuan Province (2019YW003).

舒适性提出了更大的挑战<sup>[4-5]</sup>. 在实际线路上进行车内压力波动对乘客舒适性的影响研究, 具有试验费用高, 影响列车正常运营的问题, 且对于正在建设中的川藏铁路这种特大工程, 无法进行实际线路测试试验. 因此, 日本建立了高速列车气密性试验室, 通过大量试验, 得出人体舒适度临界曲线<sup>[6-7]</sup>. 英国德比铁道研究所建造了瞬变压力试验室, 并在大量可靠数据的基础上, 制定了自己国家的气密性标准<sup>[8]</sup>. 王前选等设计了车内压力波试验模拟平台, 为制定人体舒适性指标提供了一定依据<sup>[9]</sup>. 屈国庆等设计了一套能够模拟车内压力波动情况的气压模拟系统, 为更好地研究车内压力波动与乘客舒适性的关系提供了试验平台, 具有非常重要的现实意义<sup>[10-11]</sup>.

基于气压模拟系统具有非线性、多耦合、多扰动、难以准确建模的特点, 采用迭代学习控制具有较好的适应性<sup>[12]</sup>. 目前, 国内外学者对非线性系统的迭代学习控制问题进行了相关研究. Hou等<sup>[13]</sup>针对非线性离散系统提出了一种前馈-反馈结构的离散迭代学习律. 汪首坤等<sup>[14]</sup>针对阀控非对称缸系统, 设计了一种遗忘预测迭代学习控制算法. Luo等<sup>[15]</sup>针对一类非线性多智能体系统, 设计了P型和PI $\beta$ 型迭代学习律来解决跟踪控制问题. 李新<sup>[16]</sup>针对动车组隧道压力波模拟系统, 设计了一种带遗忘因子的开闭环高阶迭代学习控制器. 综上所述, 国内外学者针对不同的控制系统分别对迭代学习律进行了相应的改进研究, 且取得了较好的控制效果, 但是以上系统对历史运行数据利用率低, 且控制给定初值常设定为零值或者与期望轨迹相对应的固定初值, 然而实际的重复作业往往会引起迭代初值相对于期望初值的偏移, 这样就会产生初始误差, 导致控制器需要经过多次迭代才能达到期望控制精度, 影响系统的收敛速度<sup>[17]</sup>, 若能从系统历史运行数据中寻找到新加载任务的最优初始控制信号, 将会提高系统跟踪性能<sup>[18]</sup>.

目前, 相关学者针对迭代学习控制的初值问题开展了一系列研究工作. Heinzinger等<sup>[19]</sup>针对迭代学习存在的初始误差问题, 分析得出了算法稳定条件, 但

不能保证收敛. 毛祖永等<sup>[20]</sup>针对具有迭代学习初始误差的高相对度线性离散系统, 提出了一种P型迭代学习律, 并验证了该算法的有效性, 但是该算法只能解决固定初值存在的初始误差问题, 并不能处理任意初值的情形. Hoelzle等<sup>[21]</sup>提出了一种迭代学习的基本任务方法, 通过对新任务分解出的基本任务进行迭代学习, 获取新作业任务的最优初始控制信号, 但是该文没有考虑作业任务相似性问题, 无法对基本任务的属性进行度量与描述. 屈国庆等<sup>[10-11]</sup>利用大数据的思想, 对气压模拟系统历史控制数据进行迭代学习初值寻优, 并与传统二阶PD型迭代学习控制及模糊控制进行对比, 结果表明该算法提高了系统收敛速度并取得了良好的系统稳定性, 但是该算法在寻优过程中存在初值加权计算不准确的问题, 进而影响控制效果.

针对以上问题, 本文首先建立气压模拟系统模型和历史运行数据库, 然后设计一种基于 $k$ 最近邻( $k$ -nearest neighbor,  $k$ NN)思想的初值寻优算法, 来解决气压模拟系统历史运行数据利用率低以及存在迭代初始误差导致系统收敛速度慢的问题, 再将最优初值输入到带遗忘因子的迭代学习控制器中, 最后通过数字仿真分析, 验证了该算法具有较快的收敛速度、较小的系统抖动程度、较好的控制精度以及算法鲁棒性, 为精确控制相似气压模拟系统提供了一定的参考价值.

## 2 气压模拟系统

### 2.1 气压模拟系统试验平台介绍

气压模拟系统的基本结构主要由试验车体、正负压储气罐、鼓风机、真空泵、蝶阀以及管路组成. 试验时, 控制阀门K1和K2的开度使鼓风机和真空泵分别对正压储气罐和负压储气罐进行充气和抽气动作, 使正负压储气罐相对于试验车体达到预设控制裕度, 这样不仅可以持续充气与抽气, 使试验车体内的气压更加平稳, 还可以节约能源. 当正负压储气罐满足蓄能要求时, 控制阀门T1和T2的开度来调节试验车体内的气压, 使车体内气压能够准确、快速地跟踪期望气压轨迹. 气压模拟系统结构示意图如图1所示.

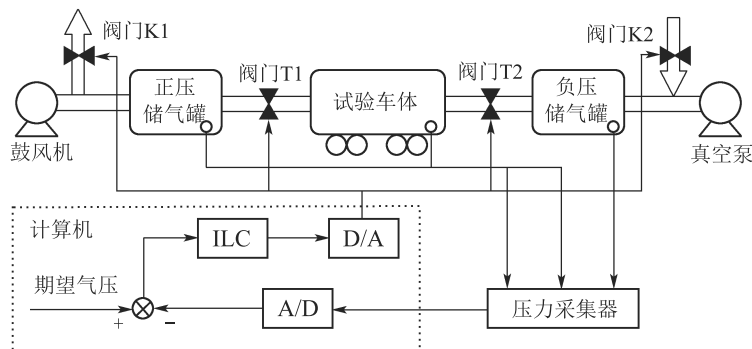


图1 气压模拟系统示意图

Fig. 1 Schematic diagram of air pressure simulation system

气压模拟系统的控制量对应4套蝶阀的开度, 被控制量对应试验车体内的气压. 气压模拟系统的主要功能是完成对车内压力环境的再现, 使车内气压沿着期望波形轨迹实现零误差的轨迹跟踪. 通过大量试验获得样本数据, 并将其进行统计特征分析, 以便更好地研究高速列车车内气压变化对人耳舒适性的影响. 根据表1可知<sup>[22]</sup>, 在动车组气压舒适度方面用气压3 s变化率作为车内压力舒适性评价指标, 因此选取如图2所示的梯形波为试验车体内的期望波形, 其周期为22 s.

表1 车内压力舒适度评价指标

Table 1 Evaluation index of interior pressure comfort

气压变化率	舒适性等级	人耳感受
$\leq 200$ Pa/s	优	非常舒适
$\leq 800$ Pa/3s	良	比较舒适
$\leq 1250$ Pa/3s	合格	一般舒适
$>1250$ Pa/3s	不合格	不舒适




图2 梯形波加载过程图

Fig. 2 Trapezoidal wave loading process diagram

由图2可知, 在车体加载梯形波的过程中, 充气与抽气过程均满足3 s内以一定斜率变化的斜坡函数曲线, 与人耳舒适性评价指标中的气压3 s变化率相对应.

## 2.2 气压模拟系统模型建立

气压模拟系统在工作过程中, 不考虑风机、正负压储气罐、试验车体、阀门以及管路的漏气现象, 则该系统符合质量守恒定律:

$$Q_C(t) = Q_{T1}(t) - Q_{T2}(t), \quad (1)$$

$$Q_Z(t) = Q_{GF}(t) - Q_{K1}(t) - Q_{T1}(t), \quad (2)$$

$$Q_F(t) = Q_{ZK}(t) - Q_{K2}(t) - Q_{T2}(t), \quad (3)$$

式中:  $Q_C(t)$ 为 $t$ 时刻流入车体的气体质量流量;  $Q_Z(t)$ 为 $t$ 时刻流入正压罐的气体质量流量;  $Q_F(t)$ 为

$t$ 时刻流入负压罐的气体质量流量;  $Q_{GF}(t)$ 为鼓风机 $t$ 时刻充进的气体质量流量;  $Q_{ZK}(t)$ 为真空泵 $t$ 时刻抽出的气体质量流量;  $Q_{K1}(t)$ ,  $Q_{K2}(t)$ ,  $Q_{T1}(t)$ ,  $Q_{T2}(t)$ 为 $t$ 时刻流经阀门K1, K2, T1, T2的气体质量流量.

理想气体状态方程的具体形式如下所示:

$$PV = nRT, \quad (4)$$

式中:  $P$ ,  $V$ 为理想气体压强与体积;  $n$ 为气体物质的量;  $R$ 为理想气体常数;  $T$ 为理想气体热力学温度.

分别对车体以及正负压储气罐中的气体质量流量进行积分, 得到气体质量. 假设气压模拟系统中的空气是理想气体, 通过上述理想气体状态方程, 得到3个容器中的气压.

$$m_C(t) = m_{C0} + \int_0^t Q_C(\sigma) d\sigma, \quad (5)$$

$$m_Z(t) = m_{Z0} + \int_0^t Q_Z(\sigma) d\sigma, \quad (6)$$

$$m_F(t) = m_{F0} - \int_0^t Q_F(\sigma) d\sigma, \quad (7)$$

式中:  $m_C(t)$ 为 $t$ 时刻车体内的气体总质量;  $m_{C0}$ 为车体内的气体总质量的初始值;  $m_Z(t)$ 为 $t$ 时刻正压罐的气体总质量;  $m_{Z0}$ 为正压罐的气体总质量的初始值;  $m_F(t)$ 为 $t$ 时刻负压罐的气体总质量;  $m_{F0}$ 为负压罐的气体总质量的初始值.

本系统控制的关键是对4个蝶阀的开度进行精确调节, 因此准确建立阀门模型尤为重要. 首先计算阀门的流量系数, 然后建立阀门开度与流量系数的关系, 再找到阀门控制电流与阀门开度的关系, 最终得到空气流经阀门的质量流量. 由于篇幅有限, 此处只列出阀门的质量流量公式, 如下所示:

$$Q_{FM} = \frac{P_k T_1}{P_1 T_k} Q_V \rho_S, \quad (8)$$

式中:  $Q_{FM}$ 为流经阀门的气体质量流量;  $P_k$ ,  $T_k$ 为气体标准状况的气压以及热力学温度;  $P_1$ ,  $T_1$ 为阀门入口的气体绝压以及热力学温度;  $Q_V$ 为气体的标准体积流量;  $\rho_S$ 为阀门入口的气体密度.

以上述理论为基础, 本文使用仿真软件搭建气压模拟系统仿真模型, 且在搭建仿真模型时充分考虑高速列车实际运行状态. 因此, 试验车体为进行一定内部改造的实际高速列车的中间车体. 气压模拟系统模型的主要参数如表2所示.

## 3 气压模拟系统控制算法设计

### 3.1 kNN算法

$k$ 最近邻算法( $k$ NN)是机器学习中一种基本的分类与回归方法, 所谓 $k$ 最近邻, 就是 $k$ 个最近邻居的意思, 即每个样本都可以用它最接近的 $k$ 个邻居来

代表. 该算法的思路是在训练数据集中, 找到与输入样本最邻近的 $k$ 个样本, 若 $k$ 个样本多数属于某个已知类, 则该输入样本也被分到这个类别<sup>[23-24]</sup>. 本文利用 $k$ NN算法的分类思想, 将其应用于遗忘迭代学习控制初值寻优问题中.

表2 气压模拟系统模型主要参数

Table 2 Main parameters of air pressure simulation system model

名称	单位	数值
试验车体容积	m <sup>3</sup>	200
正负压储气罐容积	m <sup>3</sup>	50
鼓风机最大流量	m <sup>3</sup> /min	260
真空泵最大流量	m <sup>3</sup> /min	260
阀门流量系数	us gal/min	8000
阀门控制电流	mA	4~20
管路内径	mm	400

已知测试样本 $q$ 和查询参数 $k$ ,  $k$ NN算法会返回最小数据集, 其中包含来自数据库的距离样本 $q$ 最近的 $k$ 个数据, 且符合以下条件:

$$\begin{cases} \forall p \in NN_q(k), \forall p' \in DB - NN_q(k), \\ d(p, q) < d(p', q), \end{cases} \quad (9)$$

式中:  $p$ 为数据库中的距离样本 $q$ 最近的训练样本;  $NN_q(k)$ 为数据库中距离样本 $q$ 最近的 $k$ 个样本组成的样本集;  $p'$ 为数据库中除距离样本 $q$ 最近的 $k$ 个样本之外的训练样本;  $DB$ 为数据库中的样本集;  $d(p, q)$ 为样本 $p$ 和样本 $q$ 之间的距离;  $d(p', q)$ 为样本 $p'$ 和样本 $q$ 之间的距离.

假设数据库是 $n$ 维实数向量空间, 训练样本特征向量为 $\mathbf{x}_p = (x_{p1} \ x_{p2} \ \cdots \ x_{pn})^T$ , 测试样本特征向量为 $\mathbf{x}_q = (x_{q1} \ x_{q2} \ \cdots \ x_{qn})^T$ , 本文采用欧氏距离来计算测试样本与数据库中训练样本之间的距离, 计算公式如下所示:

$$d = \sqrt{\sum_{i=1}^n (x_{pi} - x_{qi})^2}, \quad (10)$$

式中:  $d$ 为两个样本之间的欧式距离;  $x_{pi}$ 为 $\mathbf{x}_p$ 的第 $i$ 个属性的样本值;  $x_{qi}$ 为 $\mathbf{x}_q$ 的第 $i$ 个属性的样本值.

欧式距离测量的是各样本在特征空间上的绝对距离, 距离越远表明两个样本的差距越大, 且测试样本 $q$ 与 $k$ 个最近的训练样本 $p$ 的最大距离 $h$ 为

$$h = \max\{d(p, q) | p \in NN_q(k)\}. \quad (11)$$

为使得距离近的样本可以获得更大的权重, 本文采用径向基函数(radial basis function, RBF)计算测试样本与数据库中 $k$ 个最近的训练样本的距离权

重, 记为 $w$ . 权重计算公式如下所示:

$$w = e^{-\frac{\|x_{pi} - x_{qi}\|^2}{2\sigma^2}}, \quad (12)$$

其中:  $\|x_{pi} - x_{qi}\|^2$ 可以看做两个特征向量第 $i$ 个样本属性值之间的欧几里得距离的平方,  $\sigma$ 为函数的

宽度参数, 令 $\sigma = \frac{h}{\sqrt{2}}$ , 则式(12)变为

$$w = e^{-(\frac{d}{h})^2}. \quad (13)$$

最后利用 $k$ NN算法返回的与测试样本最接近的 $k$ 个样本及相对应的权重, 可以求得测试样本属性

$$\mathbf{y} = \frac{\sum_{i=1}^k w_i \mathbf{y}_{pi}}{\sum_{i=1}^k w_i}, \quad (14)$$

式中:  $\mathbf{y}$ 为样本属性;  $\mathbf{y}_{pi}$ 为数据库中距离测试样本最近的第 $i$ 个训练样本属性;  $w_i$ 为测试样本与数据库中最近的训练样本的第 $i$ 个距离权重.

针对气压模拟系统, 将加载期望气压的波形类别、波形周期以及波形幅值作为当前操作工况信息, 车体期望误差为零向量, 数据库中有操作工况信息、试验车体控制误差以及阀门开度控制电流信息. 本文设计的多步 $k$ NN算法初值寻优流程分为两个阶段.

第1阶段: 将当前操作工况信息作为测试样本的特征向量, 数据库中的操作工况信息作为训练样本的特征向量, 车体控制误差信息作为训练样本的属性. 本文利用 $k$ NN算法将当前操作工况 $q_1$ 与数据库中的操作工况信息进行对比分析, 计算得到 $k_1$ 个初始候选工况信息, 并在数据库中调出 $k_1$ 个初始候选工况信息所对应的试验车体控制误差信息.

第2阶段: 将试验车体期望误差信息作为测试样本的特征向量, 第1阶段的试验车体控制误差数据作为训练样本的特征向量, 阀门开度控制电流作为训练样本的属性. 本文再次利用 $k$ NN算法将试验车体期望误差 $q_2$ 与第1阶段计算得到的车体控制误差信息进行对比分析, 选取出 $k_2$ 个车内控制误差较小的候选样本数据, 最后通过局部加权计算得到最终阀门开度控制电流信息.

多步 $k$ NN算法初值寻优的计算流程如图3所示.

### 3.2 遗忘迭代学习控制算法

迭代学习控制算法可以对过去周期性重复数据加以利用来提高当前周期的控制性能, 且无需建立系统精确模型. 其基本原理是利用系统先前的控制历史信息与输出误差不断修正当前控制输入, 使系统实际输出在有限控制时间内沿着给定轨迹实现零

误差的轨迹跟踪<sup>[17,25]</sup>. 因此针对气压模拟系统对试验车体反复加载试验波形的重复性质且难以准确建模的特点, 采用迭代学习算法非常适用<sup>[12,25]</sup>.

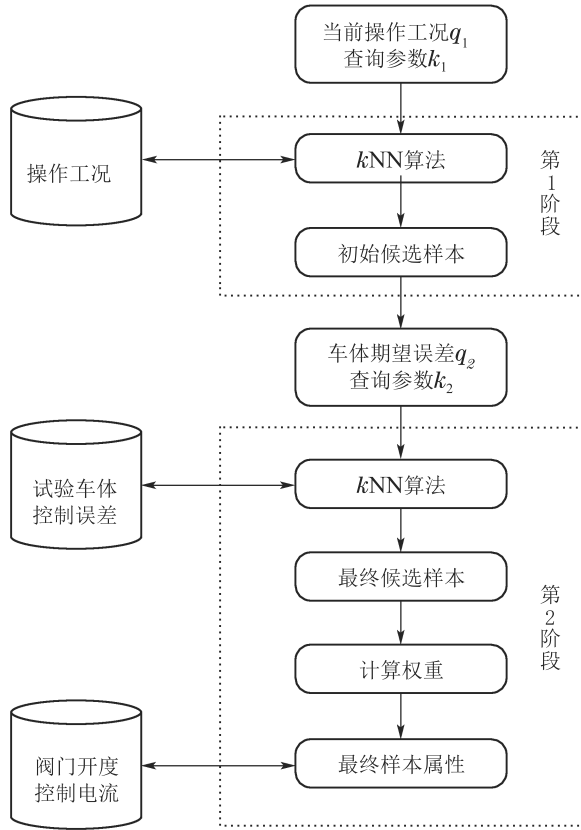


图 3 多步  $k$  NN 算法计算流程图

Fig. 3 Calculation flow chart of multi-step  $k$  NN algorithm

该系统控制流程分为正负压储气罐蓄能阶段与试验车体气压控制阶段. 正负压储气罐蓄能阶段可以保证储气罐内的气压始终高于车内气压, 能够实现对车内的持续充气 and 抽气动作. 试验车体气压控制阶段则是控制车内实际气压不断跟踪车内期望波形轨迹.

定义系统的输出误差:

$$e_k(t) = y_d(t) - y_k(t), \quad (15)$$

式中:  $y_d(t)$  为系统的期望输出;  $y_k(t)$  为系统的实际输出;  $k$  为迭代次数.

试验车体内气压是变幅值控制, 且易受正负压储气罐气压扰动以及初始误差的影响, 因此采取带遗忘因子的开闭环比例-积分-微分 (proportion integration differentiation, PID) 型迭代学习律:

$$u_{k+1}(t) = \lambda u_0^*(t) + (1 - \lambda) u_k(t) + K_{p1} e_k(t) + K_{i1} \int_0^t e_k(\tau) d\tau + K_{d1} e'_k(t) + K_{p2} e_{k+1}(t) +$$

$$K_{i2} \int_0^t e_{k+1}(\tau) d\tau + K_{d2} e'_{k+1}(t), \quad (16)$$

式中:  $u_{k+1}(t)$  为第  $k + 1$  次控制输入;  $\lambda$  为遗忘因子, 满足  $\lambda \in [0, 1)$  且  $k \rightarrow \infty, \lambda \rightarrow 0$ ;  $u_0^*(t)$  为  $k$  NN 算法计算的最优控制输入初值;  $u_k(t)$  为第  $k$  次控制输入;  $K_{p1}, K_{p2}$  为开闭环比例增益系数;  $K_{i1}, K_{i2}$  为开闭环积分增益系数;  $K_{d1}, K_{d2}$  为开闭环微分增益系数.

正负压储气罐内气压是恒值控制, 控制相对简单, 且储气罐内气压易受初始误差的影响, 因此采用带遗忘因子的闭环 PID 型迭代学习律:

$$u_{k+1}(t) = \lambda u_0^*(t) + (1 - \lambda) u_k(t) + K_{p2} e_{k+1}(t) + K_{i2} \int_0^t e_{k+1}(\tau) d\tau + K_{d2} e'_{k+1}(t). \quad (17)$$

随着迭代次数的不断增加, 由于遗忘因子的存在, 先前的控制误差累积越来越小, 这样可以解决传统迭代学习律对初始误差的敏感问题<sup>[26-27]</sup>. 文献<sup>[28]</sup>通过递推法证明了遗忘因子可以使系统达到渐进遗忘的效果.

### 3.3 控制算法实现

一个控制系统的参数、学习律和算法确定好后, 系统收敛速度只与控制初值的选取有关, 若选取合适, 则会大幅提高收敛速度<sup>[10,17]</sup>. 气压模拟系统实际运行下的控制初值常设定为预估常值, 且在系统实际运行下, 预设初值相对于期望初值往往会发生偏移, 这样就会存在初始误差, 导致控制器需要经过多次迭代才能达到期望控制精度, 系统收敛速度慢. 因此, 为解决系统存在初始误差而导致系统收敛速度慢的问题, 本文将  $k$  NN 算法应用于遗忘迭代学习控制来进行控制输入初值寻优. 控制算法实现的具体步骤如下所示:

**步骤 1** 利用  $k$  NN 算法将当前操作工况与数据库中的操作工况进行类比分析, 计算得到车体控制误差数据;

**步骤 2** 利用  $k$  NN 算法将试验车体期望误差与候选样本的控制误差信息进行类比分析, 计算得到最终阀门开度控制电流数据;

**步骤 3** 将最优阀门开度控制电流作为第 1 个周期的初始控制信号输入到遗忘迭代学习控制中, 通过不断学习训练, 对车内气压进行完全跟踪控制.

基于  $k$  NN 算法的气压模拟系统遗忘迭代学习控制框图如图 4 所示. 其中, 期望气压为控制输入, 控制器包括  $k$  NN 初值寻优算法以及遗忘迭代学习控制器, 执行机构阀门、控制对象试验车体以及正负压储气罐共同构成气压模拟系统, 实际气压为控制输出, 气压传感器和数据采集器构成检测变送环节.

当期望气压输入到控制器中, 控制器根据两次  $kNN$  初值寻优算法在系统历史运行数据库中找到最优阀门控制电流数据, 并将其作为最优初值输入到遗忘迭代学习控制器中, 产生控制信号分别控制阀

门开度, 最终控制气压模拟系统中试验车体内的气压变化, 输出的实际气压被气压传感器采集到, 作为反馈信号与期望气压信号进行比较, 再次输入到控制器中, 最终形成一个闭环控制系统.

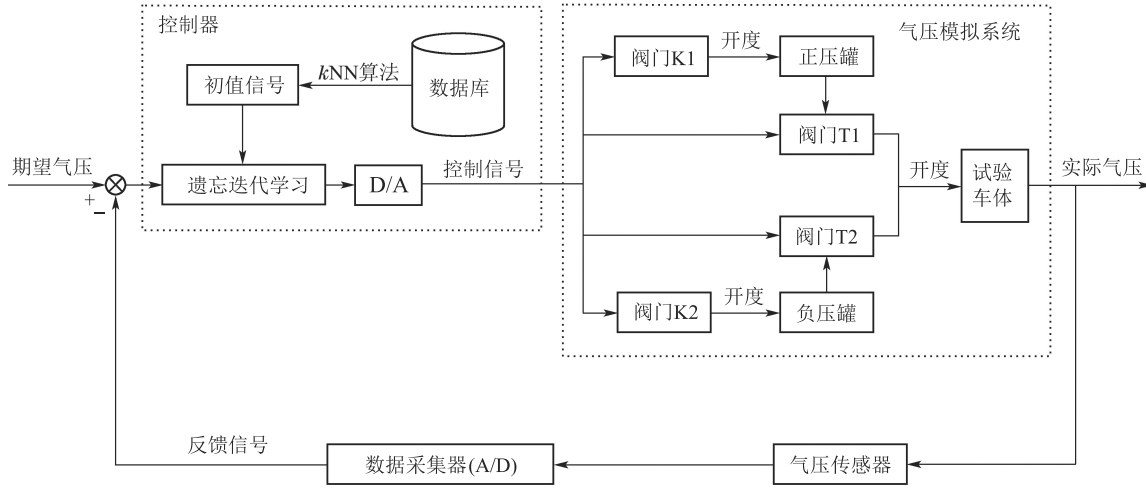


图4 气压模拟系统控制框图

Fig. 4 Control block diagram of air pressure simulation system

另外, 在每次控制系统仿真结束后, 期望气压的波形参数信息, 即当前操作工况信息(包括波形类别、波形周期以及波形幅值)和每次工况下的历史控制数据(包括试验车体、正负压储气罐控制误差以及阀门开度控制电流)均会储存到系统历史运行数据库中, 以供  $kNN$  初值寻优算法读取使用.

#### 4 仿真分析

文献[10-11]基于气压模拟系统历史运行数据库, 利用工况匹配算法和误差范数加权平均寻优算法对控制初值进行寻优, 并将最优初值输入到迭代学习控制器中, 获得了较好的控制效果. 但是文中没有列出系统历史运行数据库的具体参数信息, 故其仿真结果具有不可复现性. 因此, 在仿真之前, 首先利用系统历史控制信息建立数据库. 数据库具体组成结构如图5所示.




图5 数据库组成结构示意图

Fig. 5 Schematic diagram of database composition structure

根据数据库组成结构可知, 在波形类别以及波形周期确定的前提下, 本文所建立的数据库操作工

况中只有波形幅值是变化的, 且波形幅值在0.2 kPa ~ 2 kPa之间随机波动.

为验证本文设计的基于多步  $kNN$  的遗忘迭代学习控制算法对试验车体气压跟踪控制的有效性, 依据气压模拟系统仿真模型与数据库, 对控制算法进行仿真研究. 基于多步  $kNN$  的遗忘迭代学习控制算法在第24个迭代周期时达到收敛, 选取第3个周期、第7个周期以及第24个周期的控制过程进行具体分析, 如图6所示.




图6 基于多步  $kNN$  遗忘迭代学习的不同周期车体内控制误差图

Fig. 6 Vehicle body control error diagram with different cycles based on multi-step  $kNN$  forgetting iterative learning

在基于多步  $kNN$  的遗忘迭代学习律下, 3种迭代周期下的试验车体内控制误差参数如表3所示.

表3 试验车体内控制误差参数

Table 3 Internal control error parameters of test vehicle

迭代周期	试验车体内气压	
	误差峰值/kPa	平均误差/kPa
第3次迭代	0.2145	0.0564
第7次迭代	0.1677	0.0644
第24次迭代	0.1122	0.0366
改善率/%	47.6923	35.1064

由表3可知, 第24次迭代相较于第3次迭代, 车内气压误差峰值从0.2145 kPa降至0.1122 kPa, 改善了47.6923%, 平均误差从0.0564 kPa降至0.0366 kPa, 改善了35.1064%。因此, 基于多步kNN的遗忘迭代学习控制算法对试验车体内的气压跟踪控制是有效的。

此外, 本文还将基于多步kNN的遗忘迭代学习控制(iterative learning control, ILC)(以下简称kNN寻优ILC)与目前学者们针对气压模拟系统使用较多的基于大数据思想的迭代学习控制<sup>[10-11]</sup>(以下简称大数据寻优ILC)、传统PID迭代学习控制(以下简称传统ILC)进行对比, 并在控制精度、收敛速度以及算法鲁棒性方面分别分析3种控制算法的控制性能。

#### 4.1 系统控制精度及收敛速度分析

本文使用控制气压曲线与期望气压轨迹的误差范数衡量控制精度, 误差范数定义如下:

$$\|e_k(t)\|_\infty = \max(|e_k(t)|), t \in [0, T]. \quad (18)$$

图7中纵坐标为对数坐标, 且迭代学习的收敛条件为 $\|e_k(t)\|_\infty \leq 0.1473$ 。将图7中的参数点坐标提取出来, 汇总于表4。

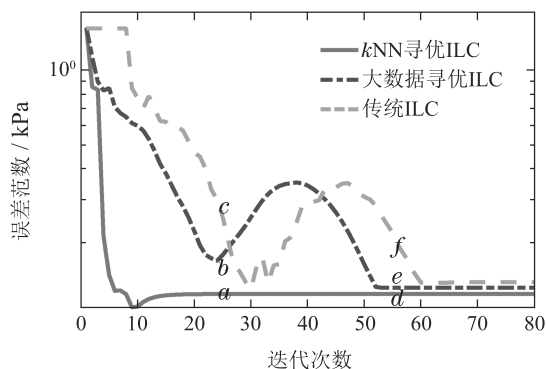


图7 波形幅值为1.473 kPa的3种控制算法控制误差范数图  
Fig. 7 Control error norm diagram of three control algorithms with waveform amplitude 1.473 kPa

对比3种控制算法的仿真结果发现, 3种控制算法的误差范数均随着迭代周期次数的增加而逐渐减

小, 且逐渐收敛到一定范围. 其中, kNN寻优ILC算法以及大数据寻优ILC算法在第55个迭代周期时均达到迭代收敛条件, 其满足迭代收敛条件的误差范数分别为0.1245 kPa和0.1321 kPa, 且分别为加载气压波形幅值(1.473 kPa)的8.4521%和8.9681%, 改善了5.7532%, 而此时传统ILC算法的误差范数没有收敛, 这表明kNN寻优ILC算法的控制精度要优于另外两种算法。

表4 参数点坐标

Table 4 Coordinates of parameter points

参数点	坐标
a	(24, 0.1245)
b	(24, 0.1696)
c	(24, 0.2994)
d	(55, 0.1245)
e	(55, 0.1321)
f	(55, 0.2194)

文献[14]中使用正弦畸变率指标来衡量系统的抖动程度, 保证了控制精度, 获得了不错的控制效果. 因此, 为进一步分析3种控制算法的控制精度, 本文对反馈的试验车体气压信号进行快速傅里叶变换(fast fourier transform, FFT)得到其频谱波形, 从频谱波形中可以求得各次谐波分量以及基波分量的有效幅值, 然后计算其畸变率来衡量系统抖动程度, 畸变率定义如下:

$$THD = \frac{\sqrt{\sum_{i=2}^k U_i^2}}{U_1} \times 100\%, \quad (19)$$

式中:  $U_i$ 为各次谐波分量的有效幅值;  $U_1$ 为基波分量的有效幅值。

图8中 $g = (55, 14.8598)$ ,  $h = (55, 14.9637)$ 。由此可知kNN寻优ILC算法的畸变率很快达到收敛, 而大数据寻优ILC算法以及传统ILC算法的畸变率变化剧烈, 系统抖动程度大, 图7中误差范数的波动情况也可以验证这一点. kNN寻优ILC算法以及大数据寻优ILC算法在第55个迭代周期时的畸变率分别为14.8598%和14.9637%, 改善了0.6943%, 而此时传统ILC算法的系统畸变率没有收敛. 从仿真结果可知, 相比较另外两种算法, kNN寻优ILC算法的畸变率更快达到收敛, 算法时效性较好, 且系统抖动程度更小, 控制精度更高。

在收敛速度方面, 图7中kNN寻优ILC算法在第24个迭代周期时已经收敛, 其误差范数为0.1245 kPa, 而此时另外两种算法还没有达到收敛条件. 从结果可知, kNN寻优ILC算法的收敛速度要快于另外两

种算法.




图8 波形幅值为1.473 kPa的3种控制算法畸变率效果图

Fig. 8 Distortion rate effect diagram of three control algorithms with waveform amplitude of 1.473 kPa

## 4.2 鲁棒性分析

为更加准确全面地对算法进行鲁棒性分析以及保证选取工况更贴合实际和人耳舒适性指标, 本文在舒适性指标4个范围内随机选取的期望波形幅值分别为1.473 kPa, 1.066 kPa, 0.792 kPa及0.485 kPa (相对于标准大气压101.325 kPa). 由于篇幅限制, 另外3种气压期望波形幅值工况的控制效果图从略, 将4种气压期望波形幅值工况的仿真结果汇总于表5, 且表中参数均为控制算法在第55个迭代周期时所得, 传统ILC算法在第55个迭代周期时没有达到收敛, 故表中未对其进行对比分析. 具体参数如表5所示.

表5 试验车体内气压参数

Table 5 Air pressure parameters of test vehicle

波形幅值/kPa	控制算法	试验车体内气压	
		误差范数/kPa	畸变率/%
1.473	kNN寻优ILC	0.1245	14.8598
	大数据寻优ILC	0.1321	14.9637
	改善率/%	5.7532	0.6943
1.066	kNN寻优ILC	0.0848	14.6804
	大数据寻优ILC	0.1345	14.8431
	改善率/%	36.9517	1.0961
0.792	kNN寻优ILC	0.0848	14.6804
	大数据寻优ILC	0.102	14.8281
	改善率/%	16.8627	0.9961
0.485	kNN寻优ILC	0.0396	14.929
	大数据寻优ILC	0.0556	15.1175
	改善率/%	28.777	1.2469

由表5可知, 在4种期望波形下, kNN寻优ILC算法在误差范数以及畸变率方面均优于大数据寻优ILC算法, 这表明kNN寻优ILC算法具有较好的鲁棒性以及寻优特性.

进一步分析kNN寻优ILC算法在减小系统抖动程度、提高系统控制精度以及算法鲁棒性等方面优于大数据寻优ILC算法的原因. 发现文献[10-11]设计的大数据寻优算法在系统历史运行数据库中寻找的是与当前操作工况相同的数据, 若在数据库中没有发现与期望气压波形参数信息相同的工况, 则会对数据库中所有工况下的阀门开度控制电流数据进行加权计算. 而本文设计的kNN寻优算法在第1阶段寻找的是与当前操作工况信息最接近的数据, 然后在第1阶段的基础上, 再次利用kNN寻优算法计算得到试验车体控制误差较小的数据, 最终对经过两次kNN寻优计算得到的阀门开度控制电流数据进行权重计算. 通过上述分析可知, kNN寻优算法相比于大数据寻优算法, 在系统历史运行数据库中搜索到的阀门开度控制电流数据与期望阀门开度控制电流数据更加接近, 初始误差更小, 对其进行加权计算后得到的控制初值准确度更高. 因此, kNN寻优算法可以保证寻优精度, 获得最优初值.

因此, 本文设计的基于多步kNN的遗忘迭代学习控制算法, 与大数据寻优ILC算法、传统ILC算法相比, 不仅提高了学习速度与控制精度, 还抑制了系统抖动. 总之, 将该算法用于气压模拟系统获得了较好的控制效果, 且验证了算法具有较好的鲁棒性.

## 5 结论

本文利用理论计算与仿真分析相结合的手段模拟气压模拟系统试验车体内气压跟踪控制问题, 并建立气压模拟系统仿真模型和系统历史运行数据库, 基于多步kNN算法的思想, 设计基于历史控制信息的最优初值计算方法, 将最优初值应用到遗忘迭代学习控制中, 通过与大数据寻优ILC算法和传统ILC算法仿真对比分析可知, kNN寻优ILC算法收敛速度更快、系统抖动程度更小、控制精度更高、鲁棒性更好. 本篇文章主要创新点如下:

1) 通过利用多步kNN初值寻优算法计算得到的控制初值, 相比于气压模拟系统实际运行下的固定初值, 初始误差较小. 且将最优初值输入到遗忘迭代学习控制器中, 系统收敛速度更快;

2) kNN寻优ILC算法在大数据寻优ILC算法的基础上, 引进kNN算法用于遗忘迭代学习初值寻优, 改进了初值寻优以及局部加权计算方式, 从而提高了寻优精度, 并获得最优初值;

3) 由于kNN寻优ILC算法建立在历史控制经验上, 解决了采用传统ILC算法时系统历史运行数据利用率低的问题, 且所提方法取得了较好的控制效果, 因此将该方法应用于相似重复作业的气压模拟系统等工程应用中, 具有一定的参考价值.



## 参考文献:

- [1] TIAN Hongqi. Development of research on aerodynamics of high-speed rails in China. *Engineering Science*, 2015, 17(4): 30 – 41.  
(田红旗. 中国高速轨道交通空气动力学研究进展及发展思考. 中国工程科学, 2015, 17(4): 30 – 41.)
- [2] RICCO P, BARON A, MOLteni P. Nature of pressure waves induced by a high-speed train travelling through a tunnel. *Journal of Wind Engineering & Industrial Aerodynamics*, 2007, 95(8): 781 – 808.
- [3] LIU T H, CHEN X D, LI W H, et al. Field study on the interior pressure variations in high-speed trains passing through tunnels of different lengths. *Journal of Wind Engineering & Industrial Aerodynamics*, 2017, 169: 54 – 66.
- [4] LU C F, CAI C X. Challenges and countermeasures for construction safety during the sichuan-tibet railway project. *Engineering*, 2019, 5(5): 49 – 61.
- [5] ZHENG Zongxi, SUN Qiqing. Sichuan-tibet railway tunnel project. *Tunnel Construction*, 2017, 37(8): 1049 – 1054.  
(郑宗溪, 孙其清. 川藏铁路隧道工程. 隧道建设, 2017, 37(8): 1049 – 1054.)
- [6] SUZUKI M. Unsteady aerodynamic force acting on high speed trains in tunnel. *Quarterly Report of RTRI*, 2001, 42(2): 89 – 93.
- [7] SUZUKI H. A review of research trends on passengers' aural discomfort caused by rail tunnel pressure change. *Foreign Railway Vehicle*, 1999, 36(5): 15 – 18.  
(铃木浩明. 车内压力波动引起耳鸣的研究. 国外铁道车辆, 1999, 36(5): 15 – 18.)
- [8] WANG Yueming. Problem about the railway coach airproof. *Railway Locomotive & Car*, 2000, (4): 4 – 7.  
(王悦明. 铁路客车空气压力密封性问题. 铁道机车车辆, 2000, (4): 4 – 7.)
- [9] WANG Qianxuan, LIANG Xifeng, REN Xin. Experimental research on simulation of interior pressure of train passing through tunnel at high speed. *Journal of Central South University: Science and Technology*, 2014, 45(5): 1699 – 1704.  
(王前选, 梁习锋, 任鑫. 列车高速通过隧道时车内压力波模拟试验研究. 中南大学学报: 自然科学版, 2014, 45(5): 1699 – 1704.)
- [10] QU Guoqing. *Design and algorithm research of the pressure control system of the simulation test rig for comprehensive comfort*. Chengdu: Southwest Jiaotong University, 2016.  
(屈国庆. 综合舒适度模拟试验台气压控制系统设计与算法研究. 成都: 西南交通大学, 2016.)
- [11] QU Guoqing, CHEN Chunjun, YAN Zhongkui. Research of big data iterative learning control algorithm for air pressure simulation system. *Journal of Railway Science and Engineering*, 2016, 13(10): 1886 – 1890.  
(屈国庆, 陈春俊, 闫中奎. 气压模拟系统大数据迭代学习控制算法研究. 铁道科学与工程学报, 2016, 13(10): 1886 – 1890.)
- [12] WANG Zhiyuan. *Research on the whole network control strategy of FAST based on iterative learning*. Shenyang: Northeastern University, 2015.  
(王志远. 基于迭代学习理论的FAST整网控制策略的研究. 沈阳: 东北大学, 2015.)
- [13] HOU Z S, XU J X. A new feedback-feedforward configuration for the iterative learning control of a class of discrete-time systems. *Acta Automatica Sinica*, 2007, 33(3): 323 – 326.
- [14] WANG Shoukun, PENG Jianmin. Forecast iterative learning control with forgetting factor and its application in valve-controlled asymmetric cylinder. *Journal of Mechanical Engineering*, 2014, 50(10): 191 – 198.  
(汪首坤, 彭建敏. 带遗忘因子的预测迭代学习控制在阀控非对称缸系统中的应用研究. 机械工程学报, 2014, 50(10): 191 – 198.)
- [15] LUO D H, WANG J R, SHEN D. Iterative learning control for locally lipschitz nonlinear fractional-order multi-agent systems. *Journal of the Franklin Institute*, 2020, 357(11): 6671 – 6693.
- [16] LI Xin. *Design of simulation system for EMU tunnel pressure wave and research on control algorithms*. Chengdu: Southwest Jiaotong University, 2019.  
(李新. 动车组隧道压力波模拟系统设计与控制算法研究. 成都: 西南交通大学, 2019.)
- [17] LIN Hui, WANG Lin. *Iterative Learning Control Theory*. Xi'an: Northwestern Polytechnical University Press, 1998.  
(林辉, 王林. 迭代学习控制理论. 西安: 西北工业大学出版社, 1998.)
- [18] XU Jianming, WANG Yaodong, SUN Mingxuan. Iterative learning control based on extracting initial iterative control signals. *Acta Automatica Sinica*, 2020, 46(2): 294 – 306.  
(徐建明, 王耀东, 孙明轩. 基于初次控制信号提取的迭代学习控制方法. 自动化学报, 2020, 46(2): 294 – 306.)
- [19] HEINZINGER G, FENWICK D, PADEN B, et al. Stability of learning control with disturbances and uncertain initial conditions. *IEEE Transactions on Automatic Control*, 1992, 37(1): 110 – 114.
- [20] MAO Zuyong, LI Xiaodong. Iterative learning control for linear discrete systems with high relative degree and iterative initial error. *Control Theory & Applications*, 2012, 29(8): 1078 – 1081.  
(毛祖永, 李晓东. 具有迭代初始误差的高相对度线性离散系统的迭代学习控制. 控制理论与应用, 2012, 29(8): 1078 – 1081.)
- [21] HOELZLE D J, ALLEYNE A G, JOHNSON A J W. Basis task approach to iterative learning control with applications to micro-robotic deposition. *IEEE Transactions on Control Systems Technology*, 2011, 19(5): 1138 – 1148.
- [22] HE Dehua. The study of pressure comfort criterion for high-speed train. *Railway Locomotive & Car*, 2016, 36(3): 1 – 6, 10.  
(何德华. 高速列车车内空气压力舒适度标准的研究. 铁道机车车辆, 2016, 36(3): 1 – 6, 10.)
- [23] SEIDL T, KRIEDEL H P. Optimal multi-step  $k$ -nearest neighbor search. *Acm Sigmod Record*, 1998, 27(2): 154 – 165.
- [24] ARIF M, ISHIHARA T, INOOKA H. Incorporation of experience in iterative learning controllers using locally weighted learning. *Automatica*, 2001, 37(6): 881 – 888.
- [25] ZHANG Y J, LI Y H, CHEN M J. Iterative learning control for linear generalized distributed parameter system. *Neural Computing & Applications*, 2018, 31(9): 4503 – 4512.
- [26] YANG H, LI S M. PD-type ILC algorithm research with forgetting factor for a class of linear systems with multiple time delays. *Applied Mechanics and Materials*, 2012, 2025: 1125 – 1130.
- [27] LIN N, LIANG H, LV Y K, et al. A forgetting-factor based data-driven optimal terminal iterative learning control with applications to product concentration control of ethanol fermentation processes. *Transactions of the Institute of Measurement and Control*, 2019, 41(14): 3936 – 3942.
- [28] FANG Chao, CHEN Chunjun, XIONG Wenwei. Iterative learning control of the high-speed train tunnel pressure wave simulation system with forgetting factor. *Control Engineering of China*, 2015, 22(3): 486 – 489.  
(方超, 陈春俊, 熊文伟. 高速列车隧道压力波模拟迭代遗忘因子控制. 控制工程, 2015, 22(3): 486 – 489.)

## 作者简介:

杨露 硕士研究生, 目前研究方向为高速列车车内压力波动迭代学习控制, E-mail: luyang@my.swjtu.edu.cn;

陈春俊 教授, 博士, 博士生导师, 目前研究方向为轨道交通设备性能测试、诊断与控制, E-mail: cjchen@swjtu.edu.cn;

王欢 硕士研究生, 目前研究方向为高速列车车内压力波动迭代学习控制, E-mail: 2250684505@qq.com;

王东威 博士研究生, 目前研究方向为高速列车空气动力学仿真及流动控制, E-mail: dongweiwang@my.swjtu.edu.cn.