

一种基于PSO_LSSVM的航空发动机磨损趋势组合预测模型研究

苗慧慧¹, 马佳丽², 曹桂松¹, 李爱³, 曹玮¹, 何超², 陈果⁴

(1. 中国航发商用航空发动机有限责任公司, 上海 200241; 2. 南京航空航天大学 民航学院, 江苏 南京 210016; 3. 南京林业大学 汽车与交通工程学院, 江苏 南京 210037; 4. 南京航空航天大学 通用航空与飞行学院, 江苏 溧阳 213300)

摘要: 通过对航空发动机的磨损趋势进行预测, 能够有效地对航空发动机磨损状态进行监测。在反映发动机磨损状态的有效观测数据中, 油液分析数据能够间接反映航空发动机整体磨损趋势。因此, 通过建立基于油样分析数据的趋势预测模型, 从而实现发动机的磨损趋势预测。但是, 目前应用于航空发动机趋势预测的模型中主要以单一预测模型为主, 组合预测模型也仅是一般的线性组合, 预测效果不佳。为此提出了一种基于支持向量机的非线性变权重组合预测模型, 通过粒子群算法实现参数优化, 油样分析数据则通过全寿命润滑油系统轴承疲劳试验, 间隔固定时间收集润滑油样品进行性能分析得到。对其中的光谱分析数据进行组合预测分析, 通过对比组合预测结果与单一预测模型的预测结果, 预测精度均超过单一预测模型的预测精度, 充分验证了所提组合预测模型的优越性和有效性。

关键词: 趋势预测; 最小二乘支持向量机; 航空发动机; 粒子群优化算法

中图分类号: TP 182 **文献标志码:** A **文章编号:** 1672-5581(2025)02-0238-06

Combinational forecast method in the aircraft engine wear trend based on PSO_LSSVM

MIAO Huihui¹, MA Jiali², CAO Guisong¹, LI Ai³, CAO Wei¹, Hechao², CHEN Guo⁴

(1. AECC Commercial Aircraft Engine Company, Shanghai 200241, China; 2. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, Jiangsu, China; 3. College of Automobile and Traffic Engineering, Nanjing Forestry University, Nanjing 210037, Jiangsu, China; 4. College of General Aviation and Flight, Nanjing University of Aeronautics and Astronautics, Liyang 213300, Jiangsu, China)

Abstract: By predicting the wear trend of aeroengine, the wear state of aeroengine can be monitored effectively. Among the effective observation data reflecting the engine wear state, the oil analysis data can indirectly reflect the overall wear trend of aeroengine. Therefore, by establishing a trend prediction model based on oil sample analysis data, so as to realize the wear trend prediction of engine. However, the current models used in aeroengine trend prediction are mainly single prediction models, and the combined prediction models are only general linear combinations, with poor prediction effect. Therefore, a nonlinear variable weight combination prediction model based on support vector machine is proposed, and realizes the parameter optimization through particle swarm optimization algorithm. The oil sample analysis data is obtained through the bearing fatigue test of the whole life oil system, and the oil samples are collected at fixed intervals for performance analysis. Through the combination prediction analysis of the spectral analysis data, by comparing the prediction results of the combination prediction and the prediction results of the single prediction model, the prediction accuracy exceeds the prediction accuracy of the single prediction model, which

fully verifies the superiority and effectiveness of the combination prediction model proposed in this paper.

Key words: trend prediction; least squares support vector machine; aircraft engine; particle swarm optimization

通过对航空发动机的磨损趋势进行预测,能够有效地对航空发动机磨损状态进行监测^[1-2]。发动机系统的磨损一般可以通过油液分析仪器如铁谱分析仪、光谱分析仪等测出的数据反映出来^[3]。因此,作为发动机摩擦学系统的输出,油液分析数据可以使航空发动机整体的磨损趋势间接的反映出来。在实际运行过程中,通常无法获取发动机摩擦学系统的输入及其传递特性,只能得到反映系统磨损状态的观测值,即系统的输出。在该情况下,只能采用同系统分析相结合的时间序列分析方法,通过“系统”的处理动态数据从而建立系统的数学分析模型,并利用建立的模型辨识系统的磨损状态预测未来的发展趋势。因此,对发动机磨损趋势的预测是通过对油样分析数据进行时序分析^[4],对发动机摩擦学系统进行辨识来实现的。

目前大多数预测模型为单一预测模型,然而该模型存在信息源不敏感、模型设置敏感等缺陷,导致预测效果不佳。因此,从20世纪60年代末,众多专家学者开始系统研究组合预测方法^[6]。目前,在国内外关于组合预测方法的实际应用与理论研究中,计算组合预测方法的权重系数向量更多地采用以某种绝对误差最小为优化准则。文献[7-8]研究了权重非负约束情况下,利用误差平方和如何获取最优组合预测模型的简捷方法。文献[9]研究的组合预测模型则是以预测有效度作为模型的优化精度指标。文献[10]研究的组合预测模型则采用经验模态分解方法,利用航空发动机性能参数建立组合预测模型。以上研究的组合预测模型主要通过一种最优化方法来寻求固定权重,组合预测模型的权重随着预测步数的不同而改变。同时,由于航空发动机的特殊工况,使得获取油样分析数据困难,导致数据样本量较小,采用现行的预测方法并不能得到较好的预测效果。而支持向量机在处理小样本信息领域有着无可比拟的优越性,并且拟合效果好、外推能力更强。为此,本文将考虑通过选择多种不同的预测模型同时对油液分析数据进行预测,并综合各类预测结果,最后使用支持向量机实现二次估计,从而得到的组合预测模型较单一预测模型更为全面,增强了预测的精确度与时效性。同时,本文中引入的最小二乘支持向量机(least squares

support vector machine, LSSVM)^[11]将标准支持向量机中的不等式约束转换为等式约束,把经验损失从误差的一范数转为二范数,将解决二次优化过程的难题转变为解决一个线性方程组难题,计算的收敛速率明显提高。

1 基于LSSVM的组合预测方法

1.1 基于PSO的LSSVM回归预测模型优化

LSSVM的回归模型为

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (1)$$

当核函数选择高斯径向基核函数时,

$$K(x_i, x_j) = \exp\left(-g \|x_i - x_j\|^2\right) \quad (2)$$

核函数参数 g 与正则化参数 C 是影响预测模型准确性的两个参数,为了优化这2个参数,本文采用粒子群优化算法(particle swarm optimization, PSO)^[12],分别以 g 和 C 作为粒子的 x 轴坐标以及 y 轴坐标,将种群大小设为 M ,最大迭代次数设为 h_{\max} ,并按照以下步骤进行优化:

(1) 首先进行粒子群初始化,对粒子的速度 v 和初始位置 x 随机设置。

(2) 对每个粒子计算其适应度值 fitness。运用训练样本数据在每个粒子位置训练得到LSSVM回归模型,然后用训练好的模型计算测试样本的预测值,粒子的适应度值则由测试样本的预测值与真实值的平均绝对误差表示。

(3) 对所有的 $i \in \{1, 2, \dots, M\}$,假如 $f_{\text{fitness}_i} > P_{\text{best}_i}$ (P_{best_i} 为第 i 个粒子达到的最大适应度值),那么令 $P_{\text{best}_i} = f_{\text{fitness}_i}$, $x_i^{\text{pbest}} = x_i$ (x_i^{pbest} 为粒子达到的最大适应度值相对应的位置),假如 $f_{\text{fitness}_i} > g_{\text{best}}$ (g_{best} 为粒子群中所有粒子所经历的最佳位置),则重置 g_{best} 的索引号 a 。

(4) 根据式(3)、式(4)调整每个粒子的位置 x_i 和速度 v_i ,

$$v_i = wv_i + c_1 r_1 (x_i^{\text{pbest}} - x_i) + c_2 r_2 (x_i^{\text{gbest}} - x_i) \quad (3)$$

$$x_i = x_i + v_i \quad (4)$$

式中: r_1, r_2 为 $[0, 1]$ 之间的随机数; c_1, c_2 为加速度

系数,通常为 $c_1 + c_2 \geq 4$,本文采用 $c_1 = c_2 = 2$; w 为惯性权值,能够使粒子保持其运动惯性,较小的 w 值对算法的收敛有利,而较大的 w 值则对跳出局部最小点有利。

在本文中,选择使用文献[13]中的自适应惯性权值: $w = w_{\min} - hw_n + sw_s$,其不仅可以保持粒子的多种类型,而且可以快速得到最优解。

(5) 对停止条件进行检查,如果达到了最大的迭代次数,那么终止迭代,否则返回步骤2。

(6) 最后得到了最优参数 g 和 C ,同时建立了相应的LS_SVM回归预测模型。

1.2 单一预测模型的选取

由于灰色GM(1,1)预测方法对短时间序列、不完全信息和较少的统计数据建模具有独特的功能,同时在反映系统确定性的趋势方面又具有很大的优势,因此,将该方法作为组合预测中的基础模型之一。自回归AR模型在预测随机序列信息时具有较强的优点,因此将AR模型作为组合预测的又一个基础模型。而BP神经网络由于可以进行输入、输出之间的高度非线性映射,同时又擅长处理非线性数据,故将BP神经网络作为组合预测的第3个基础模型。

1.3 误差指标

本文用于评估模型预测准确性的指标为平均绝对百分比误差:

$$\begin{aligned} E_{Tr} &= \frac{1}{n_{Tr}} \sum_{i=1}^{n_{Tr}} \frac{|\hat{y}_{Tri} - y_{Tri}|}{y_{Tri}} \times 100\% \\ E_{Te} &= \frac{1}{n_{Te}} \sum_{i=1}^{n_{Te}} \frac{|\hat{y}_{Tei} - y_{Tei}|}{y_{Tei}} \times 100\% \\ E_s &= E_{Tr} + E_{Te} \end{aligned} \quad (5)$$

式中: \hat{y}_{Tri} 、 y_{Tri} 和 n_{Tr} 分别为训练集的拟合值、实际值以及样本量; E_{Tr} 为拟合误差; i 为某个时间点; \hat{y}_{Tei} 、 y_{Tei} 和 n_{Te} 分别为测试数据的拟合值、实际值和样本量; E_{Te} 为外推误差。

本文将拟合误差与外推误差的和 E_s 作为评价模型正确性的综合指标。

1.4 获取训练样本

使用选取的3种单一预测模型对原始训练样本进行预测,得到的初步预测结果即为LSSVM组合预测的训练样本 $(x_{1t}, x_{2t}, x_{3t}, y_t)$, $t = 1, 2, \dots, n$ 。其中, y_t 为第 t 时刻的真实数值, x_{1t} 为利用AR预测模型^[14]进行预测得到的预测值, x_{2t} 为利用BP神经网络预测模型进行预测得到的预测值, x_{3t} 为GM(1,1)预测模型预测得到的预测值, t 表示第 t 时刻。由此得到的训练样本的输入为

$$X = \begin{bmatrix} x_{11} & x_{21} & x_{31} \\ \vdots & \vdots & \vdots \\ x_{1t} & x_{2t} & x_{3t} \end{bmatrix} \quad (6)$$

输出值为

$$Y = [y_1, y_2, \dots, y_t]^T \quad (7)$$

通过非线性映射 $\phi(x)$,将原始空间的样本 x 映射到高维特征空间中进行线性回归。假设回归模型如下:

$$H(X) = \omega^T \phi(X) + b \quad (8)$$

通过约束条件建立拉格朗日函数,得到LS_SVM组合预测模型,通过求解得到LS_SVM预测模型。

1.5 组合预测步骤

(1) 确定训练集和测试集。

将油样中某元素给定的时间序列实测值分为训练集 T_r 和测试集 T_e 。 y_{Tri} 为训练集 T_r 的实际值, n_{Tr} 为其样本量。 y_{Tei} 为测试集的实际值, n_{Te} 为测试集的样本数。

(2) 数据预处理。

为了提高训练模型的收敛速度,对训练集 T_r 和测试集 T_e 的实测值进行了极差标准化和标准化计算,求得标准化后在 $[0, 1]$ 区间内的值。

(3) 利用训练集 T_r 进行建模。

本文以训练集 T_r 中的 y_{Tri} 作为样本,采用AR预测模型、BP神经网络预测模型和GM(1,1)预测模型分别进行建模,并得到各模型最佳参数。针对AR模型的阶数,采用赤池信息量准则(akaike information criterion, AIC)与最终预报误差准则(final prediction error criterion, FPE)计算不同模型阶数 p 的AIC值与FPE值,进而求平均值,并以平均值最小时对应的 p 作为适用模型的阶数,该阶数对应的模型就是最佳适用模型。同时将该值作为BP神经网络模型的嵌入维数,而BP神经网络模型的隐层神经元数目则由经验公式给出^[15]:

$$n_H = \sqrt{n_I + n_O} + l \quad (9)$$

式中: n_H 为隐含层神经元数目; n_I 为输入层神经元数目; n_O 为输出层神经元数目; l 取1~10之间的整数。

将得到的模型参数分别输入到3种单一模型中,通过单一模型预测得到数据 y_{Tri} 的拟合值 \hat{y}_{Tri} ,形成训练样本,将得到的训练样本输入到LSSVM模型建模。在模型训练中采用PSO得到最佳的核函数参数 g 和正则化参数 C ,求解模型得到参数 a 和 b 。将训练集的 y_{Tri} 输入到训练好的LSSVM模型

中进行拟合,求解得到时间序列 T 的二次拟合值,并通过方程式(4)得到各模型的拟合误差 E_{Tr} 。

(4) 利用测试集 T_e 数据进行数据预测。

利用已建立的3个单一预测模型进行外推预测,对应得到每一个元素在预测点的3个预测值 $[Y_{Ai}, Y_{Bi}, Y_{Gi}]$,将该预测值输入到 LSSVM 模型中,求解得到元素在预测点的最终预测值。最后通过式(5)求出3个单一模型以及 LSSVM 组合预测的外推误差 E_{Te} 、拟合误差以及外推误差之和 E_s 。

2 航空发动机油液分析数据组合预测实例分析

为了验证本文方法的有效性,对实际航空发动机附件轴承进行加速疲劳试验,间隔固定时间收集滑油样品进行性能分析,选择光谱分析数据对所建模型进行验证。

2.1 滚动轴承疲劳寿命加速试验

为该实验定制加工了一台 ABLT-1A 型滚动轴承加速度疲劳试验器,如图 1 所示。该试验器主要由试验头、试验头座、传动系统、加载系统、润滑系统、计算机监控系统等部分组成。定制加工 M50 材料的圆柱滚子轴承,与某在研发发动机轴承型号参数一致。


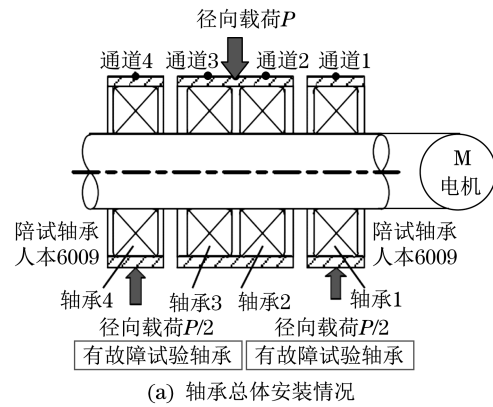


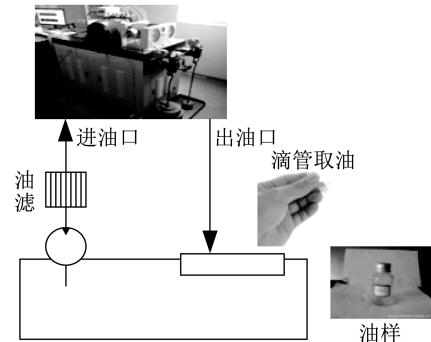
图1 疲劳试验机

Fig 1 Material testing machine

本次试验的轴承总体安装情况如图 2(a) 所示,使用被试件 M50 轴承 2 件,安装在第 2、3 工位。其中第 2 工位带 1.5 mm(宽)×0.2 mm×16 mm 缺陷,第 3 工位带 0.5 mm(宽)×0.2 mm×16 mm 缺陷,缺陷采用线切割加工。在第 1、4 工位上均安装陪试轴承 6009。本次试验采用人工滴管从油箱进油口位置取油的方式,如图 2(b) 所示。本次实验共进行了 192 h,轴承发生严重磨损导致振动超过界限停机。采集的油液从 6 h 到 192 h,对采集得到的油液进行光谱分析、颗粒计数分析以及理化分析。



(a) 轴承总体安装情况



(b) 取油方式

图2 试验轴承工况

Fig 2 Test bearing condition

2.2 预测模型验证

经过试验,从 32 个光谱油样分析数据中,选取 Fe 元素的质量浓度 ($10^{-6} \mu\text{g}\cdot\text{mL}^{-1}$) 作为样本,对所建预测模型进行验证。并将测试样本与训练样本比例分别设为 70%、80%、90% 这 3 种情况,根据预测结果验证本文方法的有效性。

光谱分析 Fe 元素质量浓度具体数据见表 1。首先利用 BP 神经网络预测模型、AR 预测模型以及 GM(1,1) 预测模型对训练样本进行预测,得到样本值并计算样本误差,各单一模型参数见表 2。然后将上一步通过单一预测模型得到的训练样本预测值输入到 PSO_LSSVM 组合预测中进行训练。最后用测试数据来验证训练模型的准确度。粒子群规模 M 设为 30,最大进化代数 $h_{\max}=100$, $C \in [1, 10\ 000]$, $g \in [0, 1]$,求得的基于 LSSVM 的组合预测模型的正则化参数 C 和核函数参数 g 见表 1,得到的预测误差见表 3。

通过表 3 可以发现,在不同的样本比例下,基于 LSSVM 的组合预测模型获得的预测结果误差显著低于其他 3 种单一预测模型的预测误差,从而证明了本文方法的有效性和优越性。尤其在样本比例为 90% 时,预测效果最好。单一预测模型得到的结果如图 3~图 5 所示,本文中采用 PSO_LSSVM 组合预测模型预测得到的结果如图 6 所示。从图中

表1 发动机油样光谱分析Fe元素质量浓度(10⁻⁶ μg·mL⁻¹)

Tab.1 Fe element content of engine oil sample by spectral analysis (10⁻⁶ μg·mL⁻¹)

编号	1	2	3	4	5	6	7	8	9	10	11
质量浓度	1.054	1.019	0.91	0.826	0.835	0.817	0.799	0.782	1.028	0.91	1.096
编号	12	13	14	15	16	17	18	19	20	21	22
质量浓度	1.004	0.996	0.996	1	0.949	0.935	1.119	0.951	0.981	0.959	0.97
编号	23	24	25	26	24	28	29	30	31	32	
质量浓度	1.033	1.008	0.985	1.104	1.096	1.069	1.033	1.144	1.162	1.561	

表2 各样本比例下PSO_LSSVM组合预测模型参数
Tab.2 Under each sample proportion PSO_LSSVM combined prediction model

样本比例/%	阶数p (AR模型)	隐层神经元数目 (BP模型)	g	C
70	5	13	0.492 6	58.326 0
80	5	13	0.216 0	43.774 9
90	2	12	0.426 0	33.669 5

表3 各种预测方法对Fe的预测误差比较

Tab.3 Comparison of prediction errors of various prediction methods for Fe

样本比例/%	误差	BP模型	GM(1,1)模型	AR模型	LS_SVM组合模型
70	E _{Tr}	0.161 1	0.404 5	0.040 1	0.000 0
	E _{Te}	0.165 5	0.162 2	0.122 2	0.092 4
	E _s	0.326 6	0.566 7	0.162 2	0.092 4
80	E _{Tr}	0.280 5	0.354 1	0.064 5	0.000 0
	E _{Te}	0.451 6	0.237 1	0.145 0	0.055 3
	E _s	0.732 2	0.591 2	0.209 4	0.055 3
90	E _{Tr}	0.119 9	0.318 7	0.063 7	0.000 0
	E _{Te}	0.229 8	0.400 9	0.215 7	0.053 5
	E _s	0.349 7	0.719 6	0.279 4	0.053 5

能够很明显地看出,采用PSO_LSSVM的组合预测方法具有良好的预期效果。




图3 BP模型预测结果

Fig.3 Predicting results of BP model




图4 AR模型预测结果

Fig.4 Predicting results of AR model




图5 GM模型预测结果

Fig.5 Predicting results of GM model




图6 PSO_LSSVM组合模型预测结果

Fig.6 Predicting results of PSO_LSSVM combinational model

3 结论

(1) 提出了一种带粒子群优化的LSSVM组合预测模型,基于油液分析数据实现了航空发动机摩擦磨损趋势的预测。根据其数据特征,本文选取了AR预测模型、GM(1,1)预测模型以及BP神经网络预测模型构成预测模型群,利用预测模型群得到预测结果进行基于LSSVM的组合预测,同时采用PSO对模型参数进行优化,最终建立了基于PSO_LSSVM的组合预测模型。

(2) 以某航空发动机附件轴承加速疲劳试验得到的实测光谱数据为例,利用本文所建立的PSO_LSSVM组合预测模型得到的预测值,比单一预测方法精度更高,充分验证了该方法的有效性和优越性。

(3) 通过实际试验表明该预测模型能较好地适应实际工程需求,可作为航空发动机光谱数据预测的有效工具,对合理进行发动机状态监测和视情维护工作具有重大意义。

参考文献:

- [1] 张全德,陈果,郑宏光,等.一种基于油液分析数据挖掘的航空发动机磨损故障诊断知识获取方法[J]. 润滑与密封, 2019,44(3):128-134.
- [2] 皮骏,马圣,贺嘉诚,等.遗传算法优化的SVM在航空发动机

磨损故障诊断中的应用[J]. 润滑与密封,2018,43(10):89-97.

- [3] 曹桂松,马佳丽,苗慧慧,等.一种航空发动机磨损故障模糊融合诊断方法[J]. 润滑与密封,2022,47(3):150-156.
- [4] 李爱.航空发动机磨损故障智能诊断若干关键技术研究[D].南京:南京航空航天大学,2013.
- [5] 冯伟,贺石中.摩擦学系统特征信息关系的试验研究[J]. 工程设计学报,2011,18(4):288-292.
- [6] BATES J M, GRANGER C W J. The combination of forecasts [J]. Journal of Operational Research Quarterly, 1969,20:451-468.
- [7] 唐小我.组合预测误差信息矩阵研究[J]. 电子科技大学学报,1992(4):448-454.
- [8] 马永开,唐小我,杨桂元.非负权重最优组合预测方法的基本理论研究[J]. 运筹与管理,1997(2):1-8.
- [9] 陈华友,侯定丕.基于预测有效度的优性组合预测模型研究[J]. 中国科学技术大学学报,2002(2):49-57.
- [10] 王雄威.基于性能参数预测的航空发动机维修决策支持系统研究[D].哈尔滨:哈尔滨工业大学,2013.
- [11] 崔建国,高波,蒋丽英,等.LSSVM与HMM在航空发动机状态预测中的应用研究[J]. 计算机工程,2017,43(10):310-315.
- [12] 郑波.基于粒子群优化算法的航空发动机故障诊断与性能参数预测研究[D].成都:电子科技大学,2018.
- [13] 张选平,杜玉平,秦国强,等.一种动态改变惯性权的自适应粒子群算法[J]. 西安交通大学学报,2005(10):1039-1042.
- [14] AI Y, SUN X, CHENG Z, et al. Research on sensor data validation in aeroengine vibration tests [C]// International Conference on Measuring Technology & Mechatronics Automation. IEEE Computer Society, 2010:162-166.
- [15] ZHANG J, YANG Y, ZHANG J M. A MEC-BP-Adaboost neural network-based color correction algorithm for color image acquisition equipments [J]. International Journal for Light and Electron Optics, 2016, 127(2):776-780.

(上接第237页)

箱涵专用多功能作业车,并实现其高精度控制包括:

(1) 行走轮采用伺服驱动系统能够在不同工作状态下快速、慢速行走,单人操作机器即可完成升降、前进、后退、转向等动作,实现25°爬坡,减少操作人员数量,降低施工人员劳动强度,提高工作效率。

(2) 电机无级变速有效延长了蓄电池和电机的使用寿命,电机仅消耗工作时的能量。行走轮配备双伺服驱动系统可实现360°大角度回转,使得作业车具有优良的灵活性。

(3) 基于双电机实时速度及速度差,采用交叉耦合控制算法进行作业车同步控制,在较长纵向位移下作业车横向位移和实时偏移角度均控制在较满意的范围内。

参考文献:

- [1] 李永鑫.南水北调天津干线箱涵变形缝监测分析[J]. 中国水利,2021,14(5):28-30.
- [2] 关炜.南水北调工程关键技术研究进展[J]. 人民长江, 2022,53(1):167-181.
- [3] 窦明,左其亭,胡彩虹.南水北调工程的生态环境影响评价研究[J]. 郑州大学学报,2005,26(2):63-66.
- [4] 郑光辉.一种隧道施工多功能辅助作业车[J]. 中国工程机械学报,2021,19(5):59-64.
- [5] 王创.多电机网络控制系统速度同步控制研究[D].济南:济南大学,2018:15-20.
- [6] 唐姣姣.基于交叉耦合算法的双直线电机协同控制系统研究[D].合肥:安徽大学,2016:5-25.
- [7] 孙传有.履带车双电机同步伺服控制技术研究[D].武汉:湖北工业大学,2020:1-5.
- [8] 葛浩然.爬壁机器人机电耦合动力学与轨迹跟踪控制研究[D].长春:吉林大学,2021:19-40.