

AGV 驱动电机故障预测与健康管理模型 研究与应用

黄和富^{1*}, 俞沛齐², 陈锐¹, 王志德², 时吕²

(1. 北京航空航天大学 云南创新研究院, 云南 昆明 650233;

2. 昆明船舶设备集团有限公司, 云南 昆明 650000)

Research and Application of Prognostics and Health Management Model for AGV Drive Motors

HUANG Hefu^{1*}, YU Peiqi², CHEN Rui¹, WANG Zhide², SHI Lü²

(1. Yunnan Innovation Institute, Beihang University, Kunming 650233, China;

2. Kunming Shipbuilding Equipment Co., Ltd., Kunming 650000, China)

Abstract: [Objective] A method has been proposed to preprocess, predict, and classify the load data of automated guided vehicle (AGV) drive motors, and then predict the health status and failure of AGVs. The aim is to evaluate the health status and failure probability of AGV motors, and improve the maintenance and work strategies of AGVs. [Methods] Based on the experimental collection of AGV motor channel current, vibration signal data, and temperature data, the data is sampled. The proposed method uses autoregressive model and convolutional neural network model to predict the health status and calculate the failure probability of AGV drive motor's current, vibration signal, and temperature rise data trends. The collected and predicted data are converted into symmetrized dot pattern (SDP) images using SDP algorithm for classification detection, thereby determining the health level of the working motor. After classifying the health level of the dataset into three levels based on the temperature rise data of the motor, the autoregressive model and Convolutional network model is used to detect the health status of the driving motor and estimate the probability of the driving motor health level based on the load current and vibration signals of the AGV motor. Based on the determination of the health status, the statistical model can calculate the failure probability of the AGV driving motor. [Results] The data verification through the acceleration test of the driving motor shows that the accuracy of this method in evaluating the health status diagnosis of AGV driving motors reaches an average of about 99.7%, with an accuracy of 100% in classifying the test samples as healthy and unhealthy. When predicting the probability of AGV drive

motor failure under planned workload, the root mean square error of AGV motor state data prediction reaches around 0.053. [Conclusion] By applying deep learning methods to the current, vibration, temperature rise and other data of AGV motors, the health level classification of AGV motors (healthy, sub healthy, unhealthy) is achieved. Based on the evaluation results of health status and the calculation of failure probability, reference is provided for the assessment of AGV workload intensity and maintenance plan.

Key words: automated guided vehicle drive motor; prognostics and health management; convolutional neural network; autoregressive model; symmetrized dot pattern

摘要:【目的】为评估自动引导车(AGV)驱动电机的健康状态、预测故障概率,改进 AGV 的保养维护和工作策略,本文结合 AGV 驱动电机的历史状态数据和预定义的工作负荷,提出了一种 AGV 驱动电机的故障预测与健康管理(PHM)模型。【方法】首先,采集 AGV 驱动电机的负载电流、振动信号以及温度数据,并对采集的数据进行去噪和归一化处理,以提高模型的收敛速度和泛化能力。然后,采用自回归模型和卷积神经网络模型对 AGV 驱动电机的负载电流、振动信号及温度数据的变化趋势进行预测,并将采集的数据和预测的数据转化为对称点图案(SDP)。最后,基于 YOLOv11 网络对生成的 SDP 进行分类,从而确定 AGV 驱动电机的健康等级。根据电机温升将健康等级分为不健康、亚健康和健康三类,基于电机的负载电流、振动信号采用本文所提模型检测驱动电机健康状态并估计驱动电机属于某类健康等级的概率,基于健康状态的测定可以得到 AGV 驱动电机的故障概率。【结果】对本文模型在验证集和测试集上进行验证测试以

评估模型性能。结果表明 AGV 驱动电机的 3 类健康状态的平均诊断准确率为 99.7%, 其中健康和 unhealthy 两类的诊断准确率达到了 100%。为进一步验证本文模型的优越性, 与其他两种模型进行对比, 结果表明本文模型的诊断准确度高于其他模型, 具有较高的可信度。【结论】本文提出的 PHM 模型对故障概率预测和健康状态评估的准确度较高, 将 AGV 工作负荷信息整合到 PHM 模型中, 可为 AGV 的工作任务制定和保养维护提供数据参考。

关键词: 自动引导车驱动电机; 故障预测与健康管理; 卷积神经网络; 自回归模型; 对称点图案

0 引言

驱动电机是电气化工厂中传动系统和生产设备的主要核心动力来源, 根据驱动电机的故障与健康状况诊断和预测数据, 对设备进行保养维修或替换, 及时调整生产计划, 对于保障生产系统的质量、安全性和生产率至关重要^[1-3]。随着电子商务迅速发展, 快递包裹业务量不断扩大, 兼备柔性、效率和成本优势的自动引导车 (Automated Guided Vehicle, AGV) 快递分拣系统应运而生。AGV 分拣相比人工优势明显, 自动化快递分拨中心可以实现 24 小时作业, 不仅大幅降低人工成本, 还能提高作业效率^[4-5]。同时随着机械装备不断朝高速化、大型化及智能化方向发展, 为了保障 AGV 高效、安全和可靠运行, AGV 驱动电机系统的故障预测与健康管理 (Prognostics and Health Management, PHM) 成为工业领域研究的重要方向^[6]。此外通过对驱动系统健康状况数据进行分析, 可以有效识别系统的薄弱点, 进行针对性改进设计, 提高产品的可靠性。

在 PHM 的发展过程中, 出现过各种维护逻辑。其中基于设备工作时间的逻辑维护是定期计划的预防性维护, 该方法可以减缓组件的退化过程^[7]。随着基于设备工作状态的维护逻辑的出现, 采用深度学习的方法可以实现对电机故障的实时诊断^[8-10]。

陈滇斐等人^[11]提出一种参数优化的变分模态分解算法对电流信号进行处理。通过计算电流和电磁转矩的多尺度模糊熵对短路故障进行诊断。王少萍等人^[12]提出了一种永磁同步电机双闭环 PHM 方法, 通过监测电机的线电压、线电流、机械转速和输出扭矩等参数进行 PHM, 但该方法

不能全面反映电机的运行健康状态。唐鸣等人^[13]提出了变分模态分解能量熵与卷积神经网络相结合的电机轴承故障诊断方法。文献^[14-15]通过对振动信号进行分析提高了故障的诊断精度。

现有的 PHM 算法和模型中, 只有较少方法通过集成历史状态数据和当前健康状态数据来估计 AGV 驱动系统成功完成预定义工作量的概率。虽然关于 PHM 的算法近年来显著增加, 但其中大多数只适用于单一状态因素和恒定负荷条件下运行的设备。由于 AGV 驱动系统长时间工作, 若发生老化而意外中断将耽误 AGV 分拣系统运行的安全性和效率, 因此, 基于 AGV 驱动电机的历史状态数据和预定义的工作负荷来评估 AGV 驱动系统的健康状况, 预估 AGV 成功完成预定义工作负荷的概率, 对于智能化分拣工厂系统中的活动调度至关重要^[16-18]。

本文旨在通过 AGV 驱动电机的历史状态数据结合预定义的工作负荷对 AGV 进行 PHM。主要的工作如下:

(1) 采用对称点图案 (Symmetrized Dot Pattern, SDP) 和自回归 (Autoregressive, AR) 模型对 AGV 驱动系统的多个状态参数进行特征提取和特征状态数据预测;

(2) 对 AGV 驱动电机的负载电流、振动信号和温升参数进行标准化特征处理后生成 SDP, 并使用 YOLOv11 分类模型进行健康状态分类, 同时使用标准化特征参数进行逻辑回归预测对比分析;

(3) 将 AGV 工作负荷信息整合到 AGV 驱动电机的 PHM 模型中, 为 AGV 的任务制定和维护提供数据参考。

1 数据 AR 和 SDP 转化

1.1 预处理

AGV 驱动电机的状态通过数据采集器采集的数据得到, 由于采集的电流、振动和温度数据带有噪声且量纲不统一, 因此本文采用滑动平均滤波算法^[19]对采集的电流、振动信号进行去噪处理。在采样数据长度为 N 的数组中取长度为 m ($m < N$) 的数列, 每进行一次新的采样, 把采样数据放入队尾, 扔掉原来队首的一个数据, 这

样队列中始终有 m 个最新数据。对这 m 个最新数据取平均值,作为此次采样的有效值,再进行滤波处理。振动信号进行滤波处理前后的对比如图 1 所示。




图 1 AGV 驱动电机的振动信号滤波对比

Fig. 1 Comparison of vibration signal filtering for AGV drive motor

为了统一 AGV 驱动电机的各状态数据为无量纲数据,进行归一化处理。设 $v_{i,j}$ 为原始采集的数据, $nor_{i,j}$ 为归一化处理后的数据,其中 i 为数据类别, j 为 i 类数据中的第 j 个数据。通过式(1)对数据进行归一化处理:

$$nor_{i,j} = \frac{v_{i,j} - \min}{\max - \min}, \quad i = 0, 1, 2, j = 0, 1, 2, \dots, N \quad (1)$$

式中: $\max$ 、 $\min$ 分别为数组中的最大值和最小值。

由图 1 可见,经去噪处理,信号更加平滑,噪声明显减少。经归一化处理,可以有效提高模型的收敛速度,避免特征间的权重不平衡,提高模型的泛化能力。

1.2 数据 AR

AGV 驱动电机的 AR 模型是一种时间序列模型,对 AGV 驱动电机的负载电流、振动和温度数据进行处理后发现,结合历史状态数据,使用 AR 模型可以实现对工作负荷不变情况下 AGV 驱动电机的工作状态数据的预测。设置采集器采样频率为每分钟/次,以采集的 AGV 驱动电机的电流、振动信号为例,对 AGV 驱动电机的状态信号进行预测,如式(2)所示:

$$g_{t+1} = f(g_{t-p}, g_{t-p+1}, g_{t-p+2}, \dots, g_{t-1}) \quad (2)$$

式中: g_{t+1} 为待预测数据; $g_{t-p}, g_{t-p+1}, g_{t-p+2}, \dots, g_{t-1}$ 为历史数据序列。

对式(2)进行 AR 处理,得到 AGV 驱动电机

的 p 阶 AR 模型如式(3)所示:

$$g_{t+1} = b_0 + b_1 g_t + b_2 g_{t-1} + \dots + b_p g_{t-p+1} + \varepsilon_t \quad (3)$$

式中: $b = (b_0, b_1, \dots, b_p)$ 为 AR 系数; ε_t 为白噪声参数。

根据式(3)对 AGV 驱动电机的电流信号和温升进行 AR 预测,结果如图 2 所示。




图 2 AGV 驱动电机的电流信号和温升 AR 预测

Fig. 2 AR prediction of current signals and temperature rise for AGV drive motor

电流信号 AR 预测的均方根误差为 0.066, 温升 AR 预测的均方根误差为 0.041 5, 两者均方根误差平均值为 0.053 75, 表明预测较为准确, 根据 AR 模型可以有效预测 AGV 驱动电机在不同工况下的状态参数数据, 将该数据输入到健康状态分类模型, 可作为 AGV 驱动电机的故障预测的参考值。

1.3 SDP 生成

将归一化后的时域波形映射到极坐标上可以生成 SDP。SDP 分析可以通过图像来反映不同的 AGV 驱动电机的电流、振动和温度等时序信号幅值和频率的状态变化^[22]。令 $A =$

$$\begin{bmatrix} a_{11}, a_{12}, \dots, a_{1n} \\ a_{21}, a_{22}, \dots, a_{2n} \\ a_{31}, a_{32}, \dots, a_{3n} \end{bmatrix}$$

为 AGV 驱动电机的负载电流、

振动信号、温度信号序列,其中温度数据主要作为健康状态分类的依据,取 A 中间隔为 inv 的数列

$\begin{bmatrix} a_{1,j}, \dots, a_{1,j+inv} \\ a_{2,j}, \dots, a_{2,j+inv} \end{bmatrix}$ 绘制 SDP, 其中 j 的取值范围为 $(0 \leq j \leq n - inv)$, 将下标 j 的数据进行极坐标转换为 $U(r_{i,j}, \theta_{i,j}, \varphi_{i,j})$, 以 inv 为间隔绘制一张 SDP。其中, $r_{i,j}$ 为极半径; $\theta_{i,j}$ 为坐标点沿极轴逆时针旋转角度; $\varphi_{i,j}$ 为坐标点沿极轴顺时针旋转角度。信号进行极坐标转换后的关系如式(4)所示:

$$\begin{cases} r_{i,j} = \frac{a_{i,j} - a_{i,\min}}{a_{i,\max} - a_{i,\min}} \\ \theta_{i,j} = \vartheta + \frac{a_{i,j+inv} - a_{i,\min}}{a_{i,\max} - a_{i,\min}} \varepsilon \\ \varphi_{i,j} = \vartheta + \frac{a_{i,j+inv} - a_{i,\min}}{a_{i,\max} - a_{i,\min}} \varepsilon \end{cases} \quad (4)$$

式中: $a_{i,\max}$ 、 $a_{i,\min}$ 分别为第 i 行中的最大、最小值; $\vartheta = 360 m/n$ 为镜像平面旋转角度, n 为镜像平面的个数, $m = 1, 2, \dots, n$; ε 为放大因子, $\varepsilon \leq \vartheta$ 。

将不同健康状态下 AGV 驱动电机的电流、振动信号数据生成 SDP, 如图 3 所示。




图 3 不同健康状态下 AGV 驱动电机的电流和振动信号 SDP

Fig. 3 SDP of current and vibration signals for AGV drive motor under different health states

生成 SDP 后,使用图像处理算法进行数据的扩充,包含旋转、平移、裁剪、翻转、调整亮度和增加噪声 6 种方式,随意组合,将每张图片扩充至 5 张。AGV 驱动电机电流和振动信号的 SDP 如图 4 所示。

2 YOLOv11 和逻辑回归模型

2.1 YOLOv11 模型

使用 YOLOv11 对 AGV 驱动电机的电流、振动信号的 SDP 进行健康状态分类, YOLOv11 将分类划为回归问题,可以实现对整张图片的类识别




图 4 AGV 驱动电机电流和振动信号的 SDP

Fig. 4 SDP of current and vibration signals for AGV drive motor

别和分类^[23-25]。YOLOv11 的网络结构分为 Backbone、Neck 和 Head 三个部分。Backbone 模块负责特征提取,通过卷积层、批归一化层和激活函数提取特征,并不断缩小特征图。Neck 模块负责多尺度特征融合,采用特征金字塔网络和路径聚合网络结构,对不同尺度的特征图进行融合,从而增强模型对各种大小物体的检测能力。Head 模块负责进行最终的回归预测,包括目标的位置和类别预测。在预测阶段,使用非极大值抑制技术去除多余的预测框,进行最终的分类计算。

YOLOv11 网络引入 C3K2, 同时在快速空间金字塔池化 (Space Pyramid Pool-Fast, SPPF) 模块后面添加了一个 C2PSA 模块,使用深度可分离的方法,减少冗余计算,提高效率。C2PSA 是对 C2F 模块的扩展,在标准 C2F 模块中引入金字塔切片注意力 (Pointwise Spatial Attention, PSA) 模块,用于增强特征提取和注意力机制。具体网路模型结构如图 5 所示。

2.2 逻辑回归模型与健康状态预测

剩余使用寿命 (Remaining Useful Life, RUL) 是设备预测中重要的参考参数。然而由于参数的不确定性,所以估计故障概率值更为有效。RUL 与 AGV 驱动电机的健康状态密切相关,能有效平衡生产和维护活动。当 AGV 驱动电机寿命退化时,相同额定工作条件下,驱动电机线圈老化,阻抗变大,相比新的电机工作温升变高,老化电机产生的振动信号中会出现抖动或噪声^[26-27]。




图5 YOLOv11 模型的网络结构

Fig. 5 Network structure of YOLOv11 model

文献[28]使用自回归滑动平均(AR Moving Average, ARMA)模型预测电梯门电机的 RUL,对电梯门电机运动退化进行了应用逻辑回归评估。逻辑回归模型是一种经典常用的预测模型,使用逻辑回归模型预测 AGV 驱动电机状态概率的计算式如式(5)所示:

$$Prob(sta) = Prob(A) = \frac{\exp(\alpha + \beta_1 A[i, 1] + \beta_2 A[i, 2] + \dots + \beta_n A[i, n])}{1 + \exp(\alpha + \beta_1 A[i, 1] + \beta_2 A[i, 2] + \dots + \beta_n A[i, n])} \quad (5)$$

式中: $\alpha + \beta_1 A[i, 1] + \beta_2 A[i, 2] + \dots + \beta_n A[i, n]$ 为 ARMA 模型对状态趋势的一种预测; A 为 AGV 驱动电机的状态数据矩阵; α, β 为模型的系数,通过历史状态数据求解得出。

式(5)是基于数据是线性可分得到的,而 AGV 状态数据是非线性的,因此逻辑回归无法准

确分类。其次 AGV 驱动电机的状态特征之间存在相关性,逻辑回归模型可能会受到干扰,导致模型的性能下降。

由于逻辑回归模型的极限性,本文将 AGV 驱动电机的健康状态等级分为健康、亚健康和不健康三类。为了方便代入模型计算,使用数字标签代表各状态,其对应关系如表 1 所示。

表 1 AGV 驱动电机健康状态与标签对应表

Tab. 1 AGV drive motor health status and label corresponding table

健康状态	标签符号
健康	1
亚健康	2
不健康	3

通过式(6)对 AGV 驱动电机的健康状态与故障进行预测:

$$Prob(sta) = Prob(A) = YOLOv11[SDP(A)] = YOLOv11\left\{SDP\left\{\alpha + \beta_1 \begin{bmatrix} a_{11} \\ a_{21} \end{bmatrix} + \cdots + \beta_n \begin{bmatrix} a_{1n} \\ a_{2n} \end{bmatrix} + \varepsilon\right\}\right\} \quad (6)$$

式中: $YOLOv11(\cdot)$ 为 YOLOv11 深度学习网络模型; $SDP(\cdot)$ 为 SDP 处理算法; $\alpha + \beta_1 \begin{bmatrix} a_{11} \\ a_{21} \end{bmatrix} + \cdots + \beta_n \begin{bmatrix} a_{1n} \\ a_{2n} \end{bmatrix} + \varepsilon$ 为 AR 模型预测的 AGV 驱动电机的状态数据。

YOLOv11 网络中分类损失通常使用交叉熵损失来计算, 交叉熵损失衡量的是模型预测的概率分布与真实标签之间的差异。模型分类损失值 c_Loss 的计算式为

$$c_Loss = \sum_{i=0}^s 1_i^{obj} \sum_{c \in [1,2,3]} [p_i([1,2,3]) - r_i([1,2,3])]^2 \quad (7)$$

式中: s 为网格的大小; 1_i^{obj} 表示第 i 个网格单元是否包含目标类, 包含目标类时值为 1, 否则为 0; c 为分类类别; $p_i([1,2,3])$ 为模型预测的概率, 表示第 i 个网格单元中目标属于 $[1,2,3]$ 的概率; $r_i([1,2,3])$ 为真实标签, 表示第 i 个网格单元中目标是否属于 $[1,2,3]$ 的概率。

通过最小化 c_Loss , 模型可以处理多个类别的

目标检测任务, 同时提高模型的分类准确性。

数据采集实物连接图如图 6 所示。AGV 驱动电机的 PHM 流程如图 7 所示, 主要包括以下步骤。

(1) 利用数据 SA1816A2 动态信号采集器从 AGV 驱动电机的传感器中获取振动信号、电流信号。通过红外测量仪器测得温度, 红外测量仪的型号为 H16, 测温范围 $-20\text{ }^{\circ}\text{C} \sim 400\text{ }^{\circ}\text{C}$, 测温精度 $<1\text{ }^{\circ}\text{C}$ 。

(2) 对采集的原始信号进行预处理, 包括平滑去噪和归一化处理、SDP 生成以及图像数据集扩充等。

(3) 将任务分为健康状态诊断和故障概率预测, 故障概率预测要结合历史状态数据对未来的状态数据进行预测然后生成 SDP。

(4) 使用 YOLOv11 网络建立 PHM 模型。使用历史数据集对 PHM 模型进行训练, 再将训练好的 PHM 模型用于 AGV 驱动电机的 PHM。



图 6 数据采集实物连接图

Fig. 6 Diagram of physical connection for data collection




图 7 PHM 流程图

Fig. 7 Flowchart of PHM

3 试验验证

3.1 数据采集

数据采集器的采集频率设置为 100 Hz。试

验中电机的退化趋势很微弱, 通过后期数据处理对比发现 1 分钟内数据的差值很小, 以 1 分钟为间隔进行抽样不会导致主要数据丢失, 可以避免数据的重复处理。采集 6 个月左右的加速试验环

境下 AGV 驱动电机的 $3 \times 241\ 080$ 条时序数据,对采集数据进行预处理后,以间隔为 20,区间为 $[200, 600]$ 的数据段生成 SDP。对生成的 SDP 根据温升的趋势进行分类,以额定温度 $80\ ^\circ\text{C}$ 为参考,根据电机温升将健康等级分为健康 ($70\ ^\circ\text{C} \sim 73.5\ ^\circ\text{C}$)、亚健康 ($73.5\ ^\circ\text{C} \sim 77\ ^\circ\text{C}$) 以及不健康 ($77\ ^\circ\text{C} \sim 80\ ^\circ\text{C}$) 三类。对 AGV 驱动系统电机健康状态的 SDP 进行分类,如表 2 所示。

表 2 AGV 驱动电机健康状态的 SDP 类型划分表

Tab. 2 SDP image type classification for AGV drive motor health states

健康状态	数据类型	数量
健康	训练集	9 975
	验证集	244
	测试集	245
亚健康	训练集	1 845
	验证集	46
	测试集	47
不健康	训练集	2 885
	验证集	72
	测试集	73

3.2 试验步骤

AGV 驱动电机的 PHM 试验步骤包括环境配置、数据集准备、模型训练和模型验证等。其中模型训练中优化器选择 Adam,训练的详细参数如表 3 所示。

表 3 AGV 驱动电机训练参数配置表

Tab. 3 Training parameter configuration for AGV drive motor

参数名称	数值	参数名称	数值
epochs	110	NBS	64
batch	116	layers	151
IOU	0.7	lr0	0.000 7
momentum	0.9	imgSize	224×224
weight decay	0.000 5	parameters	1 534 947

按表 3 的参数完成模型训练后,可以得到模型训练损失、模型验证损失和模型识别精度。模型训练的后期,模型的损失值和识别精度收敛趋于稳定,说明训练模型已经稳定且得出模型的最优解。

使用训练好的模型在验证集和测试集上进行验证测试,来评估模型性能。模型验证结果的混淆矩阵如图 8 所示。

由图 8 可知,AGV 驱动电机的 3 类健康状态




图 8 模型验证结果的混淆矩阵

Fig. 8 Confusion matrix of model validation results

的平均识别准确率为 99.7%,其中健康状态为类别 1、类别 3 的试验样本检测准确率均达到了 100%,健康状态为类别 2 的一个数据被识别为类别 1。可见,AGV 驱动电机的 PHM 模型能准确识别预定工作负荷下的 3 类健康状态。

3.3 试验验证

为了验证模型的精确性,将本文所提分类模型与 AR 模型、对数据集进行标准化处理后代入 AR 模型(STD_AR)和支持向量机(Support Vector Machine, SVM)^[29-30]模型进行对比试验,计算精度对比结果如表 4 所示。

表 4 AGV 驱动系统健康状态分类模型计算精度对比

Tab. 4 Comparison of calculation accuracy of health state classification model for AGV drive system

模型名称	AR	STD_AR	SVM	本文模型
计算精度	0.704	0.957	0.965	0.997

由表 4 可知,本文模型的诊断准确度高于其他模型,具有较高的可信度。AGV 驱动电机在 $71\ ^\circ\text{C}$ 、预定负荷下连续工作 132 天的状态数据的 SDP 如图 9 所示。其标签为 2,输入到本文模型中,输出结果为类别 2 的概率为 0.91,为类别 3 的概率 0.09,可见 AGV 驱动电机状态数据表明的健康状态为亚健康,故障概率较低。

4 结语

本文提出了一种预定工作负荷下 AGV 驱动电机 PHM 模型,来估计 AGV 驱动电机在预定工作负荷下的故障概率。本文基于温度加速试验获取电机的状态数据,并在验证集和测试集上进行验证测试以评估所提模型的性能。结果表明 AGV 驱动电机的 3 类健康状态的平均诊断准确率为 99.7%,其中健康和亚健康两类的诊断准确




图 9 AGV 驱动电机为亚健康状态的 SDP
Fig. 9 SDP diagram of AGV drive motor in sub-healthy state

率达到了 100%。与其他模型的对比试验结果表明本文模型的诊断准确度高于其他模型,具有较高的可信度和优越性。将 AGV 工作负荷信息整合到 PHM 模型中,可为 AGV 的工作任务制定和保养维护提供数据参考。未来将进一步进行加速模型与实际工作的退化模型的量化工作。

利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

作者贡献

黄和富进行了模型设计和算法代码的编写,陈锐、时吕进行内容总结与论文撰写,俞沛齐、王志德进行了试验研究,时吕参与了论文的审核与修改。所有作者均阅读并同意了最终稿件的提交。

The model design and algorithm code writing were carried out by Huang Hefu. The content summary and paper writing were carried out by Chen Rui and Shi Lü. The experiment research was conducted by Yu Peiqi and Wang Zhide. The manuscript research was revised by Shi Lü. All authors have read the last version of paper and consented for submission.

参考文献

[1] JAMWAL A, AGRAWAL R, SHARMA M, et al. Industry 4.0 technologies for manufacturing sustainability: A systematic review and future research directions [J]. Applied Sciences, 2021, 11

(12): 5725.

[2] 梁超,唐敬,王吉,等. 工业机器人健康管理数字孪生模型研究及应用[J]. 电子产品可靠性与环境试验, 2022, 40(增刊 2): 5-10.

LIANG C, TANG J, WANG J, et al. Research and application of digital twin model for industrial robot health management [J]. Electronic Products Reliability and Environmental Testing, 2022, 40 (S2): 5-10.

[3] 赵威,王锴,徐皓冬,等. 面向智能制造的工业机器人健康评估方法[J]. 机器人, 2020, 42(4): 9-10.

ZHAO W, WANG K, XU A D, et al. An Industrial robot health assessment method for intelligent manufacturing [J]. Robot, 2020, 42(4): 9-10.

[4] 田帅辉,樊略. 动态优先级策略下快递分拨中心多 AGV 路径规划[J]. 计算机工程与应用, 2023, 59(14): 275-284.

TIAN S H, FAN L. Multi-AGV path planning for express distribution center under dynamic priority strategy [J]. Computer Engineering and Application, 2023, 59(14): 275-284.

[5] 姚金生. 基于 CANopen 的八轮 AGV 运动控制及里程计算法在智能制造中的应用[J]. 电机与控制应用, 2020, 47(4): 92-96.

YAO J S. Application of eight-wheel AGV motion control and odometer algorithm based on CANopen in intelligent manufacturing [J]. Electric Machines & Control Application, 2020, 47(4): 92-96.

[6] VESPOLI S, GUIZZI G, CONVERSO G, et al. An electrical DC motor equivalent circuit test bed for the battery Prognostic health and management [C]// 2019 II Workshop on Metrology for Industry 4.0 and IoT, Naples, 2019.

[7] ALAM M A, AZARIAN M H, OSTERMAN M, et al. Prognostics of failures in embedded planar capacitors using model-based and data driven approaches [J]. Journal of Intelligent Material Systems and Structures, 2011, 22(12): 1293-1304.

[8] BYINGTON C S, WATSON M, EDWARDS D. Data-driven neural network methodology to remaining life predictions for aircraft actuator components [C]// 2004 IEEE Aerospace Conference Proceedings, Big Sky, MT, 2004.

[9] 曹美禾,宋琳,孙军,等. 深度学习及其在电机控制中的研究现状与展望[J]. 电机与控制应用,

- 2023, 50(5): 1-9.
- CAO M H, SONG L, SUN J, et al. Research and prospect on deep learning and its application in motor control [J]. *Electric Machines & Control Application*, 2023, 50(5): 1-9.
- [10] 金晓航, 王宇, ZHANG Bin. 工业大数据驱动的故障预测与健康管理[J]. *计算机集成制造系统*, 2022, 5(28): 1314-1336.
- JIN X H, WANG Y, ZHANG B. Industrial big data-driven fault prognostics and health management [J]. *Computer Integrated Manufacturing Systems*, 2022, 5(28): 1314-1336.
- [11] 陈滨斐, 凌志豪, 李志新, 等. 基于参数优化 VMD 和多尺度模糊熵的星-三角接法 FS-PMM 匝间短路故障诊断方法[J]. *电机与控制应用*, 2024, 51(6): 31-43.
- CHEN Z F, LING Z H, LI Z X, et al. Fault diagnosis of inter-turn short circuit fault in star-delta connection FS-PMM based on parameter optimization VMD and multi-scale fuzzy entropy [J]. *Electric Machines & Control Application*, 2024, 51(6): 31-43.
- [12] 王少萍, 郭浩宇, 石健, 等. 一种永磁同步电机双闭环故障预测与健康管理方法及装置: CN202310085346.5[P]. 2023-04-21.
- [13] 唐鸣, 王爱元, 朱振田. 多维度能量熵提取的不同负载下电机轴承故障诊断[J]. *电机与控制应用*, 2023, 50(9): 63-69.
- TANG M, WANG A Y, ZHU Z T. Fault diagnosis of motor bearings with different loads based on multi-dimensional energy entropy extraction [J]. *Electric Machines & Control Application*, 2023, 50(9): 63-69.
- [14] 刘昕宇, 姜长泓, 王其铭, 等. 基于 SDP 图像和 MobilenetV2 的滚动轴承故障诊断[J]. *组合机床与自动化加工技术*, 2023, (2): 178-182.
- LIU X Y, JIANG C H, WANG Q M, et al. Fault diagnosis of rolling bearing based on SDP image and MobilenetV2 [J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2023, (2): 178-182.
- [15] 张天缘, 孙虎儿, 朱继扬, 等. 基于 SDP 和改进 SAM-MobileNetv2 的滚动轴承故障诊断方法研究[J]. *机械强度*, 2024, 46(4): 787-794.
- ZHANG T Y, SUN H E, ZHU J Y, et al. Fault diagnosis of rolling bearing based on SDP and improved SAM-MobileNetv2 [J]. *Journal of Mechanical Strength*, 2024, 46(4): 787-794.
- [16] 郑一珍, 牛蒯楷, 熊晓燕, 等. 基于 EMD-SDP 特征融合的 CNN 轴承保持架故障诊断研究[J]. *机电工程*, 2021, 38(1): 81-87.
- ZHENG Y Z, NIU L K, XIONG X Y, et al. Fault diagnosis of CNN bearing cage based on EMD-SDP feature fusion [J]. *Journal of Mechanical & Electrical Engineering*, 2021, 38(1): 81-87.
- [17] CONVERSO G, GALLO M, MURINO T, et al. Predicting failure probability in industry 4.0 production systems: A workload-based prognostic model for maintenance planning [J]. *Applied Sciences*, 2023, 13(3): 1938.
- [18] ZHANG Y Y, LI S, GUO H L. A type of biased consensus based distributed neural network for path planning [J]. *Nonlinear Dynamics*, 2017, 89: 1803-1815.
- [19] 唐焱辉, 胡洁, 王晓蒙, 等. 基于电流差的电动车窗防夹算法研究[J]. *汽车电器*, 2024, (7): 51-53+56.
- TANG Y H, HU J, WANG X M, et al. Research on anti-clip algorithm of electric window based on current difference [J]. *Auto Electric Parts*, 2024, (7): 51-53+56.
- [20] 郑立楷, 吴玉香, 王孝洪, 等. 伺服系统弹性负载的闭环辨识方法[J]. *控制理论与应用*, 2023, 40(3): 468-476.
- ZHENG L K, WU Y X, WANG X H, et al. Closed-loop identification method for servo elastic load [J]. *Control Theory & Applications*, 2023, 40(3): 468-476.
- [21] 王瑞山, 李娜, 秦转丽. 牵引电机 PHM 系统分时调度技术应用[J]. *微型电脑应用*, 2024, 40(2): 204-207.
- WANG R S, LI N, QIN Z L. Application of time-sharing scheduling technology in traction motor PHM system [J]. *Microcomputer Applications*, 2024, 40(2): 204-207.
- [22] 张前图, 房立清. 基于图像处理的滚动轴承故障特征提取研究[J]. *机械传动*, 2015, 39(5): 42-45.
- ZHANG Q T, FANG L Q. Research of the fault feature extraction of rolling bearing based on image processing [J]. *Journal of Mechanical Transmission*, 2015, 39(5): 42-45.

- [23] 徐彦威, 李军, 董元方, 等. YOLO 系列目标检测算法综述[J]. 计算机科学与探索, 2024, 18(9): 2221-2238.
XU Y W, LI J, DONG Y F, et al. Survey of development of YOLO object detection algorithms [J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(9): 2221-2238.
- [24] 王晓红, 胡豫. 复杂背景下的无人机图像小目标检测[J]. 计算机工程与应用, 2023, 59(15): 107-114.
WANG X H, HU Y. UAV image small object detection on complex background [J]. Computer Engineering and Applications, 2023, 59(15): 107-114.
- [25] 白宇, 周艳媛, 安胜彪. 改进 YOLOv5 的无人机小目标检测方法研究[J]. 计算机工程与应用, 2024, 60(10): 276-284.
BAI Y, ZHOU Y Y, AN S B. Research on UAV small object detection method improved by YOLOv5 [J]. Computer Engineering and Applications, 2024, 60(10): 276-284.
- [26] 宋志环. 车用驱动电机电磁振动噪声源诊断技术[J]. 电机与控制应用, 2018, 45(7): 97-104.
SONG Z H. Diagnostic techniques for electromagnetic vibration and noise of traction motor for vehicle [J]. Electric Machines & Control Application, 2018, 45(7): 97-104.
- [27] 杨建川. 车用驱动电机系统振动测试标准分析[J]. 电机与控制应用, 2021, 48(3): 94-99.
YANG J C. Analysis of vibration test standards for vehicle drive motor system [J]. Electric Machines & Control Application, 2021, 48(3): 94-99.
- [28] YAN J H, VAN J, KOC M, LEE J. A prognostic algorithm for machine performance assessment and its application [J]. Production Planning & Control, 2004, 15(8): 796-801.
- [29] 薛健侗, 马宏忠. 基于 ST-SVD 与 WOA-SVM 模型的变压器绕组松动故障诊断方法[J]. 电机与控制应用, 2023, 50(9): 57-62.
XUE J T, MA H Z. Fault diagnosis method of transformer winding looseness based on ST-SVD and WOA-SVM model [J]. Electric Machines & Control Application, 2023, 50(9): 57-62.
- [30] 刘可真, 姚岳, 赵现平, 等. 基于样本集成学习和 SO-SVM 的变压器故障诊断[J]. 电机与控制应用, 2023, 50(12): 21-31.
LIU K Z, YAO Y, ZHAO X P, et al. Transformer fault diagnosis based on sample integration learning and SO-SVM [J]. Electric Machines & Control Application, 2023, 50(12): 21-31.

收稿日期:2024-11-12

收到修改稿日期:2025-01-12

作者简介:

黄和富(1995-),男,硕士,副研究员,研究方向为系统可靠性、故障预测与健康管,1966423770@qq.com;

*通信作者:黄和富(1995-),男,硕士,副研究员,研究方向为系统可靠性、故障预测与健康管,1966423770@qq.com。