

DOI: 10.13382/j.jemi.B2508325

基于GWO-BiLSTM的电磁继电器寿命预测*

杨蕊璟¹ 黄以锋¹ 周伟² 苗学问³ 焦晓璇¹

(1. 空军工程大学航空工程学院 西安 710038; 2. 中国人民解放军93756部队 天津 300131;

3. 中国人民解放军93184部队 北京 100070)

摘要:针对目前继电器寿命预测没有充分利用其退化过程前后状态之间联系、人工调参效率低下的问题,提出了一种基于灰狼优化算法(GWO)和双向长短期记忆(BiLSTM)网络的电磁继电器寿命预测方法。首先,构建电磁继电器加速退化实验平台,采集继电器全寿命周期数据,得到电磁继电器的平均失效寿命;然后,对数据进行采样、划分和归一化处理,并通过皮尔逊相关系数分析法筛选出线圈电阻、负载电流、接触电阻、释放时间4个关键特征参数作为预测模型的输入;最后,将电磁继电器寿命的预测值和真实值的均方根误差(RMSE)作为GWO算法的适应度函数,优化BiLSTM模型的隐含层神经元个数、dropout率和初始学习率,利用得到的最优参数组合重构预测模型。实例验证表明,相比传统的反向传播神经网络(BPNN)模型、门控循环单元(GRU)模型和长短期记忆网络(LSTM)模型,GWO-BiLSTM模型的RMSE和MAPE分别平均下降了56.7%和58.2%,表明该模型能够有效提高电磁继电器的寿命预测精度。

关键词:电磁继电器;寿命预测;双向长短期记忆网络;灰狼优化算法

中图分类号: TN0; TP206+.3 **文献标识码:** A **国家标准学科分类代码:** 510

Life prediction of electromagnetic relays based on GWO-BiLSTM

Yang Ruijing¹ Huang Yifeng¹ Zhou Wei² Miao Xuewen³ Jiao Xiaoxuan¹

(1. Aviation Engineering School, Air Force Engineering University, Xi'an 710038, China;

2. Unit 93756 of PLA, Tianjin 300131, China; 3. Unit 93184 of PLA, Beijing 100070, China)

Abstract: To address the current issues in relay life prediction where the correlation between degradation states is underutilized and manual parameter tuning is inefficient, this study proposes an electromagnetic relay life prediction method based on the grey wolf optimizer (GWO) and bidirectional long short-term memory (BiLSTM) network. First, an accelerated degradation experiment platform for electromagnetic relays is constructed to collect full service-life data, from which the mean time to failure is derived. The data is then sampled, partitioned, and normalized, with four key feature parameters—coil resistance, load current, contact resistance, and release time—selected as model inputs using Pearson correlation analysis. Subsequently, the root mean squared error (RMSE) between predicted and actual relay life is employed as the fitness function for the GWO algorithm, optimizing the number of hidden layer neurons, dropout rate, and initial learning rate of the BiLSTM model. The prediction model is reconstructed using the optimal parameter combination. Experimental validation demonstrates that the proposed GWO-BiLSTM model achieves average reductions of 56.7% in RMSE and 58.2% in MAPE compared to conventional back-propagation neural network (BPNN), gated recurrent unit (GRU), and long short-term memory (LSTM) models, effectively enhancing the prediction accuracy of electromagnetic relay service life.

Keywords: electromagnetic relay; life prediction; BiLSTM; GWO

0 引言

电磁继电器通过控制电流在线圈中形成电磁力驱动触点运动,实现对大电流电路的通断调控,具有电气隔离、电路切换与系统保护等特点,广泛应用于工业自动化^[1-2]、航空航天^[3-4]、铁路安全^[5-6]及轨道交通^[7-8]等多个领域。然而,由于电磁继电器内部结构复杂,包含机械触点、线圈、弹簧等多种功能部件,这些部件在长期使用过程中会出现机械磨损、电弧烧蚀、接触氧化、热老化等因素造成的失效,从而造成系统功能故障。此类故障不仅致使设备停机检修,徒增维护成本,尤其在航空航天等高可靠性要求的特殊场景中,严重时还会威胁系统安全。因此,精确预测电磁继电器寿命,对提升电气系统安全性和可靠性意义重大。

目前针对电磁继电器的寿命预测方法主要分为基于物理模型的预测方法和基于数据驱动的预测方法,其中,基于物理模型的预测方法需要使用微分方程等数学工具,对系统内部的物理过程和退化机制进行详细的模拟和分析,但电磁继电器内部涉及机械、电磁、热等多物理场耦合,这种复杂性使得对电磁继电器进行精确的物理建模十分困难,在实际工程中应用受到限制^[9]。基于数据驱动的预测方法则不依赖于对物理过程的深入理解,而是通过对大量历史数据的学习和分析来挖掘数据中隐藏的规律,加之传感器技术的发展为数据驱动方法提供了丰富、准确的数据支持,因而这种方法被越来越多的研究者采用。李欣等^[10]将继电器剩余寿命建模为高斯分布,利用高斯过程回归方法和多核学习技术对继电器寿命进行预测,该模型能够给出继电器在至少运行指定时间下的剩余寿命可能性分布。关欣等^[11]以灰色 GM(1, 1)模型和反向传播神经网络(back-propagation neural network, BPNN)模型为基础,通过加权组合单一预测方法构建组合预测模型,研究结果表明该模型能显著提升预测精度。

虽然基于数据驱动的预测方法在一定程度上取得了较好的预测精度,但传统的数据驱动方法往往忽略了隐藏在状态监测数据背后的时序相关性趋势,使得该方法难以有效应对预测任务中数据的长时间依赖难题。近年来,深度学习凭借突出的信息处理与特征提取优势,在处理复杂时序数据领域得到了极为广泛的应用。在众多深度学习模型中,长短期记忆(long short-term memory, LSTM)网络是一种极具效能的非线性循环神经网络,其独特的“门结构”能够深度剖析时序数据中潜藏的特征变化趋势,有效避免因时间跨度过大而引发的梯度消失或梯度爆炸问题,确保模型在长时间序列学习时的稳定性与准确性^[12]。设备运行时产生的退化监测数据本质

是时间序列数据,因此,许多研究者将 LSTM 网络模型及其拓展模型用于处理设备寿命预测问题。黄凯等^[13]提出一种自适应数据预处理结合长短期记忆神经网络的锂电池剩余寿命预测框架,降低了预测误差。Sun 等^[14]提出了一种基于改进多尺度排列熵和长短期记忆双重注意机制的交流接触器剩余寿命预测方法,相比浅层机器学习,预测精度有显著提升。梁浩鹏等^[15]通过特征融合注意力机制构建了一种基于并行双向时间卷积网络与双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)的轴承剩余寿命预测模型,可以准确预测更多类型轴承的剩余寿命。陈维兴等^[16]提出了一种基于 Wasserstein 距离与梯度惩罚措施的条件生成对抗网络与卷积长短期记忆网络相结合的预测模型,有效解决了航空发动机运行周期内故障数据难以采集而造成的数据失衡等问题。Chen 等^[17]提出一种 SDAE-LSTM 寿命预测模型,利用堆叠去噪自编码器网络对 IGBT 时域退化数据进行自适应特征提取,并采用灰狼优化算法(grey wolf optimizer, GWO)对 LSTM 模型的超参数进行优化,相比传统 BP 神经网络等,SDAE-LSTM 模型能够实现更准确、更稳定的 IGBT 寿命预测。

通过上述文献分析,LSTM 网络及其拓展模型在寿命预测领域具有较好的性能优势,特别是 BiLSTM 模型,基本的 LSTM 模型只能处理单向的时间序列数据,而 BiLSTM 模型相比于 LSTM 有双向时序信息融合能力,能够整合前向传播与后向传播的双向时序特征,显著增强了模型对时间序列中长期依赖关系的捕获能力^[18]。在电磁继电器寿命预测中,这种双向建模机制能够解析历史累积效应与未来潜在退化模式的非线性耦合关系,更全面地捕捉继电器工作状态的动态变化规律;通过时序上下文感知提升对继电器初期微小故障特征的辨识能力。因此本文选择基于 BiLSTM 模型进行电磁继电器的寿命预测,以捕捉继电器时间序列数据中的全局依赖关系。BiLSTM 模型中隐含层的神经元个数、dropout 率以及初始学习率等超参数设置会直接影响网络模型性能,而超参数的确定往往依赖于人工经验,并需经过多次试验,耗费大量人力和时间成本。为解决 BiLSTM 模型的超参数寻优问题,引入 GWO 算法,以模型中隐含层的神经元个数、dropout 率和初始学习率的大小作为 GWO 的输入,将预测值与真实值的均方根误差(root mean squared error, RMSE)作为 GWO 寻优过程中最优个体的适应度函数,获取预测模型最优的超参数组合^[19-20]。为验证所提算法的有效性与可靠性,搭建了电磁继电器加速退化实验平台,通过模拟继电器在实际工况下的工作状态,采集继电器全寿命周期的多维度退化数据。基于该实验平台获得的数据,并结合 GWO-BiLSTM 模型与对比算法的预测结果,从预测精度和收敛速度两个维度进

行定量分析与对比验证,为电磁继电器的寿命预测提供理论支撑与数据支持。

1 GWO-BiLSTM 预测模型

1.1 LSTM 网络与 BiLSTM 网络

1) LSTM 网络

LSTM 是一种特殊的循环神经网络(recurrent neural network, RNN),克服了传统 RNN 在处理长序列数据时面临的长期依赖问题^[21],它通过引入细胞状态和门控机制来有效地保存和更新长期信息。细胞状态能够保存长期的信息,门控机制则控制信息的流动,遗忘门决定哪些信息保留,输入门选择新的信息,输出门生成最终的隐藏状态。LSTM 网络内部结构如图 1 所示。

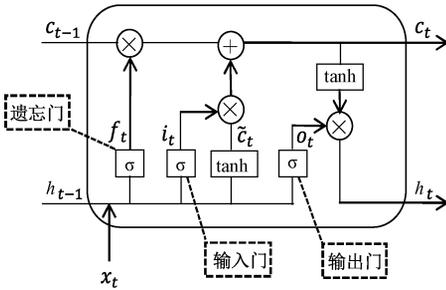


图 1 LSTM 结构

Fig. 1 Network structure of LSTM

LSTM 网络单个神经元内部信息更新过程^[22]如下:

(1) 计算遗忘门的值

$$f_t = \sigma(\mathbf{W}_{xf} \mathbf{x}_t + \mathbf{W}_{hf} \mathbf{h}_{t-1} + \mathbf{b}_f) \quad (1)$$

式中: \mathbf{W}_{xf} 与 \mathbf{W}_{hf} 均为遗忘门的权重矩阵; \mathbf{b}_f 为遗忘门的偏置项; \mathbf{x}_t 表示当前时刻输入; \mathbf{h}_{t-1} 表示上一时刻单元状态; $\sigma(\cdot)$ 为 sigmoid 函数;

(2) 计算输入门的值

$$i_t = \sigma(\mathbf{W}_{xi} \mathbf{x}_t + \mathbf{W}_{hi} \mathbf{h}_{t-1} + \mathbf{b}_i) \quad (2)$$

式中: \mathbf{W}_{xi} 为输入门与当前时刻输入 \mathbf{x}_t 之间的权重矩阵; \mathbf{W}_{hi} 为输入门与上一时刻单元状态 \mathbf{h}_{t-1} 之间的权重矩阵; \mathbf{b}_i 为输入门的偏置项。

(3) 计算当前时刻单元的候选状态值 \tilde{c}_t

$$\tilde{c}_t = \tanh(\mathbf{W}_{xc} \mathbf{x}_t + \mathbf{W}_{hc} \mathbf{c}_{t-1} + \mathbf{b}_c) \quad (3)$$

式中: \mathbf{W}_{xc} 为当前单元与当前时刻输入 \mathbf{x}_t 之间的权重矩阵; \mathbf{W}_{hc} 为当前单元与上一时刻单元状态 \mathbf{h}_{t-1} 之间的权重矩阵; \mathbf{b}_c 为当前单元的偏置项; \mathbf{c}_{t-1} 表示上一时刻的单元状态值; $\tanh(\cdot)$ 为双曲正切函数。

(4) 计算当前时刻的单元状态值 \mathbf{c}_t

$$\mathbf{c}_t = f_t \otimes \mathbf{c}_{t-1} + i_t \otimes \tilde{c}_t \quad (4)$$

式中: 符号 \otimes 表示矩阵按元素相乘。

(5) 计算输出门的值 \mathbf{o}_t

$$\mathbf{o}_t = \sigma(\mathbf{W}_{xo} \mathbf{x}_t + \mathbf{W}_{ho} \mathbf{h}_{t-1} + \mathbf{b}_o) \quad (5)$$

式中: \mathbf{W}_{xo} 为输出门与当前时刻输入 \mathbf{x}_t 之间的权重矩阵; \mathbf{W}_{ho} 为输出门与上一时刻单元状态 \mathbf{h}_{t-1} 之间的权重矩阵; \mathbf{b}_o 为输出门的偏置项。

(6) 计算当前单元的最终输出值 \mathbf{h}_t

$$\mathbf{h}_t = \mathbf{o}_t \otimes \tanh(\mathbf{c}_t) \quad (6)$$

2) BiLSTM 网络

BiLSTM 网络由两个传播方向相反的 LSTM 网络组成,其网络结构如图 2 所示。网络 t 时刻的最终输出结果 y_t 的计算过程如下^[23]:

$$\mathbf{h}_t^R = f(\mathbf{w}_1 \mathbf{x}_t + \mathbf{w}_2 \mathbf{h}_{t-1}^R) \quad (7)$$

$$\mathbf{h}_t^L = f(\mathbf{w}_3 \mathbf{x}_t + \mathbf{w}_4 \mathbf{h}_{t+1}^L) \quad (8)$$

$$\mathbf{y}_t = g(\mathbf{w}_5 \mathbf{h}_t^R + \mathbf{w}_6 \mathbf{h}_t^L) \quad (9)$$

式中: \mathbf{h}_t^R 和 \mathbf{h}_t^L 分别为 t 时刻前向层和后向层的输出结果; \mathbf{w}_1 、 \mathbf{w}_3 分别为输入层与前向层、后向层之间的权重矩阵; \mathbf{w}_2 为上一时刻前向传播单元与当前单元之间的权重矩阵; \mathbf{w}_4 为下一时刻后向传播单元与当前单元之间的权重矩阵; \mathbf{w}_5 、 \mathbf{w}_6 分别为前向层、后向层与输出层之间的权重矩阵; $f(\cdot)$ 表示神经元内部的计算过程; $g(\cdot)$ 表示神经元内部前后向传播结果进行拼接的计算过程。

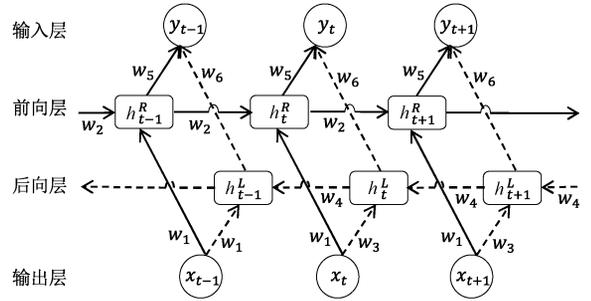


图 2 BiLSTM 网络结构

Fig. 2 Network structure of BiLSTM

1.2 GWO 算法

GWO 算法由 Mirjalili 等^[24]于 2014 年提出,是一种基于生物群体智能的元启发式优化算法。该算法模仿灰狼群在自然环境中的捕猎行为,结构简单,调节参数少,通过自适应调整的收敛因子以及信息反馈机制,用于解决全局优化问题。

自然界中灰狼群体有着严格的社会等级制度,狼群中存在 4 种角色。 α 狼,是种群中的领导者,在狩猎过程中可以敏锐地发现猎物的位置; β 狼,是 α 狼的智囊团队,更能知道猎物的位置; δ 狼,负责协助 α 狼与 β 狼; ω 狼,负责跟踪猎物。GWO 模拟了灰狼的领导 and 狩猎层级,该算法将前 3 个最优解分别定义为 α 、 β 和 δ ,指导其

他狼向最优目标搜索,其余解被定义为 ω , 跟随 α 、 β 或者 δ 更新位置。捕食过程在头狼的带领下完成,主要包括跟踪、追逐和接近猎物,再追捕、包围和骚扰猎物,直到它停止移动,最后攻击猎物^[25-26]。

GWO 寻优的具体过程如下^[27]:

1) 包围猎物

个体与猎物间的距离和灰狼的位置更新公式分别为:

$$D = |C \cdot gbest - X(t)| \quad (10)$$

$$X(t+1) = gbest - A \cdot D \quad (11)$$

式中: $X(t+1)$ 是灰狼下一次迭代位置; t 表示当前迭代次数; A 和 D 是系数向量; $gbest$ 是猎物的位置向量; $X(t)$ 表示灰狼的位置向量。向量 A 和 C 的计算公式如下:

$$A = 2 \cdot a \cdot r_1 - a \quad (12)$$

$$C = 2r_2 \quad (13)$$

其中,收敛因子 a 的取值在迭代过程中随着迭代次数增大从 2 线性减少到 0, r_1 、 r_2 是 $[0-1]$ 中的随机向量。位于 $X(t)$ 位置的灰狼可以根据猎物的位置 $X^*(t)$ 更新其位置。通过调整向量 A 和 C 的值,可以相对于当前位置到达最优代理周围的不同位置。

2) 狩猎攻击

追捕猎物环节的数学模型如下:

$$\begin{cases} D_\alpha = |C_1 \cdot X_\alpha - X| \\ D_\beta = |C_2 \cdot X_\beta - X| \\ D_\delta = |C_3 \cdot X_\delta - X| \end{cases} \quad (14)$$

$$\begin{cases} X_1(t) = X_\alpha - A_1 \cdot D_\alpha \\ X_2(t) = X_\beta - A_2 \cdot D_\beta \\ X_3(t) = X_\delta - A_3 \cdot D_\delta \end{cases} \quad (15)$$

$$X(t+1) = \frac{(X_1 + X_2 + X_3)}{3} \quad (16)$$

式中: D_α 、 D_β 、 D_δ 分别表示 ω 狼个体与 α 狼、 β 狼、 δ 狼的距离; C_1 、 C_2 、 C_3 分别表示 α 狼、 β 狼、 δ 狼对灰狼个体距离感知的随机扰动系数; $X_1(t)$ 、 $X_2(t)$ 、 $X_3(t)$ 分别表示当前迭代中 ω 狼个体需受 α 狼、 β 狼、 δ 狼的影响需要调整的位置; $X_\alpha(t)$ 、 $X_\beta(t)$ 、 $X_\delta(t)$ 分别表示当前迭代中 α 狼、 β 狼、 δ 狼位置; A_1 、 A_2 、 A_3 分别表示 α 狼、 β 狼、 δ 狼的方向调节系数。个体的最终位置取 ω 狼个体需要调整的位置的平均值,如式(16)所示。

本文采用 GWO 对 BiLSTM 网络模型的隐含层神经元个数、dropout 率以及初始学习率进行优化,以获得最优的超参数组合,提高预测模型的精度。

1.3 GWO-BiLSTM 预测模型

本文所提 GWO-BiLSTM 预测模型整体流程如图 3 所示,预测流程为:

步骤 1) 为去除噪声、提高数据质量,对电磁继电器全寿命周期的状态信息进行数据预处理操作,包括数据采样、数据集划分和归一化处理,以及特征参数筛选。

步骤 2) 设置 GWO 算法的初始化参数,确定灰狼种群数量,每个灰狼的位置表示一组超参数组合,包括即 BiLSTM 模型的隐含层神经元个数、dropout 率以及初始学习率,并确定待优化超参数的上下边界,设置灰狼算法的最大迭代次数。

步骤 3) 生成方向调节系数向量 A 、随机扰动因子 C 和收敛因子 a ,以 BiLSTM 模型的 RMSE 作为灰狼算法的种群适应度值。

步骤 4) 对狼群中的每只狼(即每组超参数组合),按以下流程计算适应度值:(1)从当前狼的位置向量 $X(t)$ 中解码出 BiLSTM 的超参数;(2)使用解码后的超参数初始化 BiLSTM,采用固定训练轮次的策略进行模型的训练;(3)使用训练好的模型对验证集输入数据进行预测,得到预测值,并计算出 RMSE 的值,将计算得到的 RMSE 作为当前狼的适应度值。

步骤 5) 将狼群按照适应度值(RMSE)进行升序排列, α 狼是排序后的第 1 只狼,它的适应度值最优(最小), β 狼是适应度值第 2 优的狼, δ 狼是适应度值第 3 优的狼,根据 α 、 β 、 δ 狼的位置,并按 GWO 追捕猎物环节的式(14)~(16)计算得到更新后的灰狼个体的最终位置。

步骤 6) 重复步骤 3)~5),直到满足迭代的条件(达到设置的 GWO 最大迭代次数)。

步骤 7) 选取训练数据输入至 BiLSTM 网络模型,并使用得到的最优超参数组合来训练 BiLSTM 模型,直至达到 BiLSTM 网络设置的最大迭代次数,输出电磁继电器寿命的预测结果。

GWO-BiLSTM 在电磁继电器的寿命预测中的优势在于,BiLSTM 通过前向和后向 LSTM 层同时学习继电器退化数据中过去和未来信息,其深层结构能够拟合复杂的非线性关系,更适合继电器复杂的退化过程;GWO 通过模拟灰狼群体的狩猎行为,自动优化 BiLSTM 的超参数,能克服传统神经网络依赖经验调参的问题,提升模型效率,且 GWO 的群体智能算法特性使其更可能找到全局最优解,避免陷入局部最优,从而提高模型泛化能力。

1.4 模型评价指标

为了定量评估所提模型的性能,选用 RMSE、平均百分比误差(mean absolute percentage error, MAPE)作为 BiLSTM 网络的损失函数,其值越小,说明模型的预测性能越好,计算公式如下^[28]:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y - y)^2} \quad (17)$$

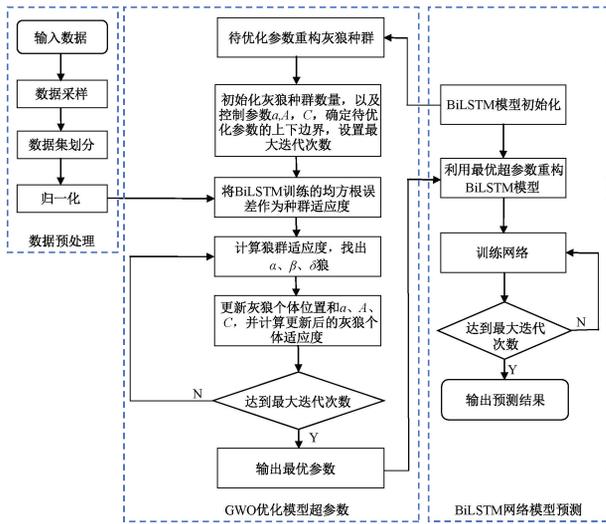


图 3 GWO-BiLSTM 模型的预测流程

Fig. 3 Prediction flowchart of GWO-BiLSTM model

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y - y}{Y} \right| \quad (18)$$

式中: Y 表示 BiLSTM 对每个样本的预测寿命值; y 表示每个样本的真实寿命值; N 表示验证集样本量。在本文中,验证集样本来源与实验平台所测的电磁继电器全寿命周期退化数据集,每个样本的寿命用电磁继电器的闭合次数表示。损失函数确定之后,BiLSTM 模型的学习问题转换为最小化损失函数的优化问题,本文选用 BiLSTM 预测模型的 RMSE 作为 GWO 寻优过程中最优个体的适应度函数。

2 实验验证与结果分析

2.1 实验平台设计及数据获取

在实际应用中,由于生产材料存在批次性差异以及生产工艺的一致性难以做到绝对统一等问题,即便是同样型号的电磁继电器,每个继电器的失效寿命也并不完全相同。为了探索某种特定型号电磁继电器的失效寿命情况,同时满足不同预测模型的数据需求,本文自主搭建了一套电磁继电器加速退化实验平台,采用 G5V-1-24VDC 型电磁继电器作为实验对象,以工作应力作为主要加速因子,将电磁继电器接入负载电路,通过合理加大负载电流,驱动电磁继电器进行高频次通断动作,模拟其在实际应用场景中的工作状态,从而加速继电器的退化过程。基于该平台完成了 15 个继电器样本的加速退化实验,通过实验获取这批继电器的平均失效寿命和各个继电器的全寿命周期状态信息两方面的关键数据。

实验平台硬件原理如图 4 所示,其主要组成部分有:继电器板、负载电阻、负载电源、控制检测装置电源、加速

退化试验控制检测装置、无线路由器和加速退化试验数据监测终端。实验平台以 UTP1306 直流稳压电源对继电器板和控制检测装置进行供电,该稳压电源可提供稳定的 24 V 电压。微控制器模块采用 STM32F103CB 微控制器,驱使电磁继电器按照指定频率动作,同时在不影响其正常工作的情况下,检测电磁继电器和吸合和释放时间,并控制数据采集模块检测线圈电流、线圈电阻、负载电流和接触电阻。数据采集模块采用 ADS1256 芯片,采集 4 路电压信号,在电磁继电器线圈回路和负载回路中分别串入线圈采样电阻和触点采样电阻,通过分压原理和欧姆定律计算得到线圈电阻和接触电阻。存储模块采用 W25Q128 存储芯片,根据其存储容量设计了数据的存储格式,以满足全寿命周期的数据存储功能。采集到的各个继电器全寿命周期状态参数通过 RS232 总线传输至 WiFi 通信模块,再经无线路由器汇总至监测终端处理与展示。实验平台实物如图 5 所示。

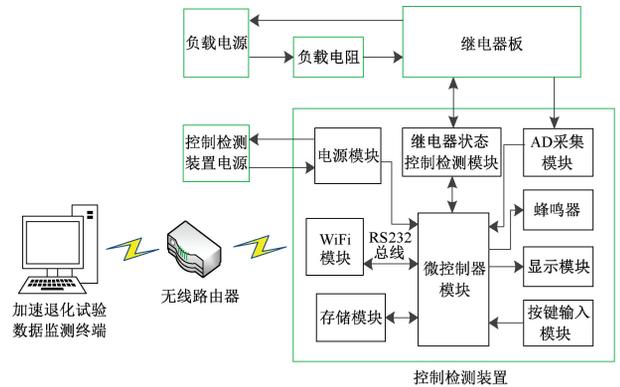


图 4 实验平台硬件原理

Fig. 4 Schematic diagram of the experimental platform hardware

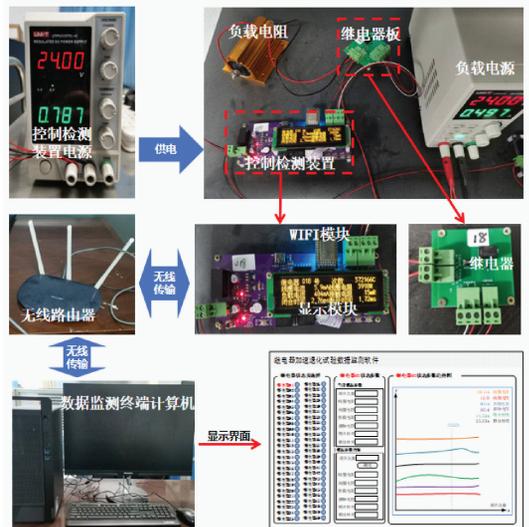


图 5 实验平台实物

Fig. 5 Physical experimental platform

实验在室温 ($23^{\circ}\text{C} \pm 5^{\circ}\text{C}$)、相对湿度 $50\% \pm 10\%$ 的环境下进行,实验环境洁净无腐蚀性气体。实验使用 15 个同批次生产的 G5V-1-24VDC 型继电器,规格为线圈电压 24 VDC,额定电流 6.25 mA,线圈电阻 $3\ 840\ \Omega$ 。继电器的工作模式为循环通断,通断频率为 1 s 闭合、1 s 断开,负载类型为纯电阻负载 ($15\ \Omega$)。根据实验现象和实验获取的数据,当监测到释放时间骤降至 0 时,继电器不再动作,此时认为继电器达到其寿命终点,该时刻即可认定为继电器的失效寿命。基于上述判定标准,实验测得了 15 个继电器的失效寿命(通断次数),数据如图 6 所示。计算结果表明,这一批次继电器的平均失效寿命为 3 558 751 次(约 3.56×10^6 次),失效寿命范围为 2 945 190~4 550 900 次,标准差为 347 380 次。

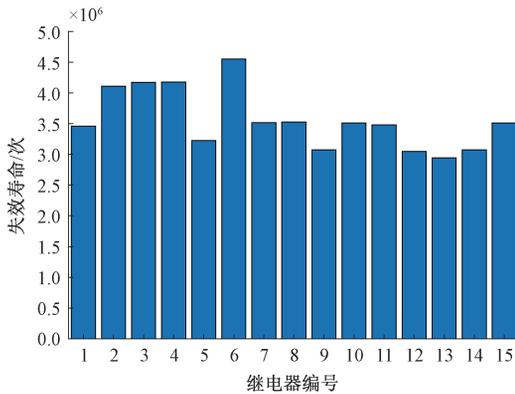


图 6 电磁继电器失效寿命

Fig. 6 Electromagnetic relay failure lifetime

2.2 数据预处理及特征筛选

经实验得到这批电磁继电器的平均寿命约为 3.5×10^6 次,存储模块每 10 次存储一组状态参数的平均值,最终生成约 3.5×10^5 组状态参数数据。由于继电器的退化过程是一个缓慢的变化过程,其状态参数在短时间内通常不会发生剧烈变化。因此,本文对这 3.5×10^5 组左右的数据进行均匀下采样,每 100 组取一个样本点(即每 1 000 次取一个预测点)。这一采样方法在保证预测精度的同时,显著减少了数据量,并有效去除了重复性信息。

为防止模型过拟合并提升模型的泛化能力,合理的数据集划分和归一化是数据预处理的关键步骤。在本文中,数据集按照时间顺序划分为训练集和测试集,将数据集的前 80% 作为训练集,后 20% 作为测试集,用于评估模型的泛化能力,测试集包含 700 组左右的继电器线圈电流、线圈电阻、负载电流、接触电阻、吸合时间、释放时间 6 个特征参数值。

实验测得的电磁继电器各特征参数的度量单位和数量级分别是线圈电流为 10^{-2} A,线圈电阻为 $10^3\ \Omega$,负载

电流为 10^{-1} A,接触电阻为 $10^{-1}\ \Omega$,闭合时间为 10^{-2} s,吸合时间为 10^{-2} s。由于实验测得的继电器各特征参量的度量单位不同,且数值量级不一致,在开展 BiLSTM 模型训练前,有必要对特征参量进行归一化处理。本文选用最大最小值归一化方法,归一化将不同量纲的数据转换到同一尺度,以此获取无量纲数据,能帮助模型更快收敛并提高性能。归一化公式如下:

$$x'_t = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} \quad (19)$$

式中: x'_t 为归一化处理后的 t 时刻对应的值; x_t 为原序列中 t 时刻对应的值; x_{\max} 与 x_{\min} 分别为数据序列中的最大值与最小值。通过归一化,可避免数值大的特征参数主导分析结果,继电器各特征参数可转换为无单位、可比的标准数值,在训练中 BiLSTM 模型能公平学习各特征参数的影响。

对于实验中每个继电器的数据均依照前述的采样、划分及归一化方法进行处理,进而获得对应编号的数据集,在后续特征提取和模型训练阶段选择 12 号数据集作为实例验证。

数据采集能够显著降低样本数量,剔除因长时间稳态运行造成的冗余信息,但无法剔除因参数之间的相关性而造成的冗余,这部分冗余不仅会增加模型的复杂程度,还可能引入噪声干扰,从而降低继电器寿命预测的精准度。为解决这一问题,本文采用皮尔逊相关系数法对原始特征参数中的关键信息进行筛选^[29]。首先计算各特征参量之间的相关系数,皮尔逊相关系数的取值在 $-1 \sim 1$ 之间,其关联度标准如表 1 所示。其次,对于相关性强的两个特征参数剔除其中一个,以得到能表征继电器寿命的关键特征参数。继电器各参数之间的皮尔逊相关系数计算结果如图 7 所示,其中颜色越深代表特征之间的相关系数越大。

表 1 皮尔逊相关系数关联度标准

Table 1 Pearson correlation degree standard

相关性水平	相关系数绝对值
无相关性	0~0.2
弱相关性	0.2~0.5
较强相关性	0.5~0.8
强相关性	0.8~1.0

结合表 1 和图 7 可知,线圈电流与线圈电阻的相关系数和吸合时间与释放时间的相关系数均 > 0.8 ,呈强相关性。在实验条件下,继电器的工作环境较为稳定,线圈电流的变化范围较小,而且根据欧姆定律,线圈电流和线圈电阻在物理上存在依赖关系,因此剔除线圈电流;吸合时间和释放时间在物理上是继电器动作的两个阶段,通常会受到相似因素的影响,根据实验获得的继电器数据,吸合时间的数值变化范围相比释放时间的小,因此剔除



图 7 皮尔逊相关系数热力图

Fig. 7 Pearson correlation coefficient heat map

吸合时间。综上所述,最终选择线圈电阻、负载电流、接触电阻、释放时间 4 个特征变量作为关键特征退化量继续进行后续研究。

2.3 模型训练与预测结果分析

模型基于 MATLAB2024 语言编写,硬件环境为 Windows 11 专业版操作系统,12th Gen Intel (R) Core (TM) i9-12900H 2.50 GHz 处理器,NVIDIA GeForce RTX 3080 Laptop GPU 显卡。

为验证通过 GWO 来确定模型最优超参数的可行性,模型的隐藏层数量、初始学习率和 dropout 率的搜索范围分别设置为 [32, 512]、[0.000 1, 0.01] 和 [0, 0.5],模型的迭代次数设置为 300,GWO 最大迭代次数设置为 30,每次更新灰狼位置后计算狼群适应度值,随迭代次数增加得到的最佳适应度变化曲线如图 8 所示。由图 8 可知,灰狼优化算法在第 25 次迭代时适应度值达到最低,在之后的 5 次迭代中,适应度值与最优参数组合均未再发生变化,此时所搜寻到的优化参数组合为最优参数组合。表 2 为隐藏层数量、初始学习率以及 dropout 率在寻优过程中的上下边界以及最优值。隐藏层数量最优值为 32,表明模型在避免复杂度的同时,能够捕捉继电器寿命的关键时序特征;初始学习率最优值为 0.005,有助于模型在复杂时序数据中稳定收敛,避免梯度震荡;dropout 率最优值为 0.443 9,表明模型在训练过程中通过随机屏蔽 44% 的神经元,能够有效抑制参数间的共适应性。

表 2 优化参数寻优范围及最优值

Table 2 Parameter Optimization Ranges and Optimal Values

优化参数	寻优范围	最优值
隐藏层数量	[32, 512]	32
初始学习率	[0.000 1, 0.01]	0.000 5
dropout 率	[0, 0.5]	0.443 9

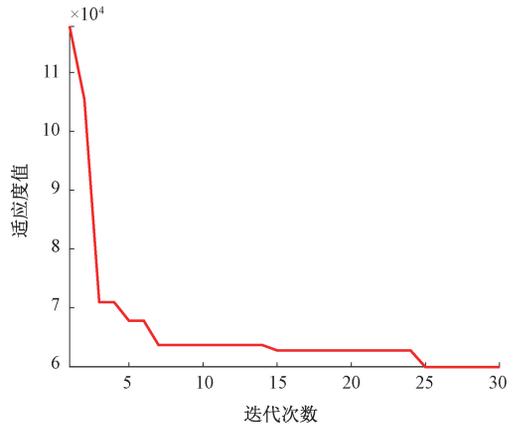
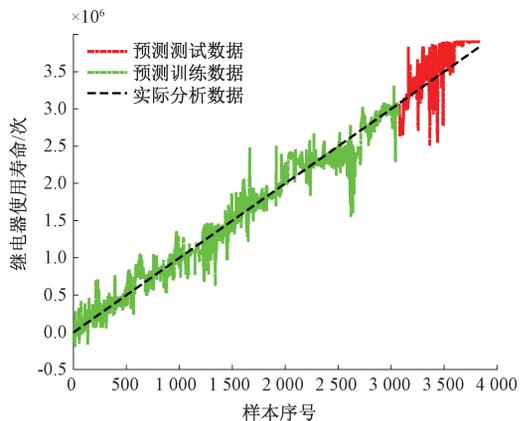


图 8 GWO 寻优过程中适应度变化情况

Fig. 8 Fitness changes in GWO optimization process

为验证所提出的 GWO-BiLSTM 预测模型的有效性,本文选用 BPNN 模型、LSTM 网络模型、门控循环单元(gated recurrent unit,GRU)模型作为对比模型,其中,BP 神经网络是传统机器学习的代表,无法捕捉继电器的时序退化特征,用来验证时序建模的必要性^[30];LSTM 是单向结构的经典时序模型,用来验证双向结构对继电器寿命预测的提升^[31];GRU 是 LSTM 的轻量化变体,其简化门控机制在继电器小样本数据中易受超参数影响,用来验证 GWO 优化的必要性^[32]。各预测模型均采用经过相同处理的同一个数据集,并通过多次实验确定了各模型的最优超参数组合:BP 神经网络隐藏层神经元数量为 10,学习率为 0.01,训练轮数为 1 000;LSTM 的隐含层神经元个数为 64,初始学习率设置为 0.001,迭代次数为 200;GRU 模型隐藏单元数为 50,初始学习率为 0.001,训练轮数为 200。各模型的预测结果和相对误差如图 9、10 所示。

图 9(a)~(d)分别是 BP 神经网络模型、GRU 模型、LSTM 模型和 GWO-BiLSTM 模型的预测结果,横坐标为预测样本点,纵坐标为继电器的寿命。图 9 中黑色虚



(a) BP神经网络预测结果

(a) BP neural network prediction results

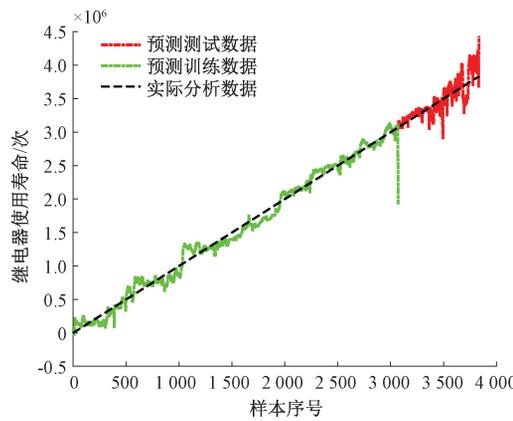
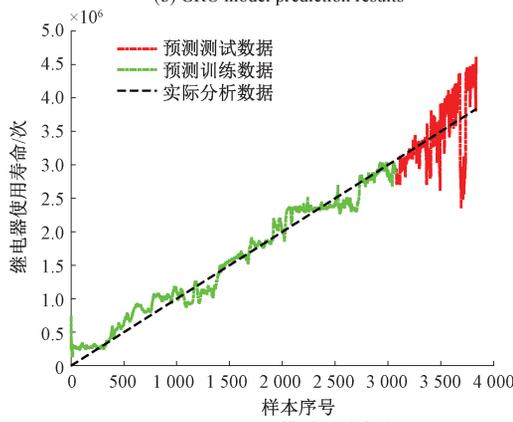
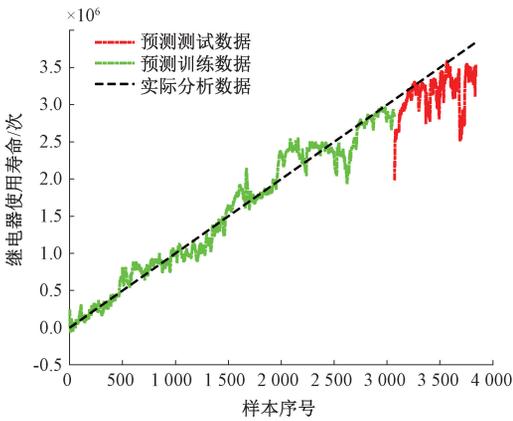


图 9 不同模型预测结果对比

Fig. 9 Comparison of prediction results of different models

线为电磁继电器实际寿命;绿色曲线表示的前 80% 部分为训练集结果;红色曲线表示的后 20% 部分为测试集结果。从预测曲线的拟合程度可以对比分析出, GWO-BiLSTM 模型的训练效果相比于其他模型更好, 整体较为平稳, 波动较小, 且测试集的预测值与真实值的吻合程度更高。

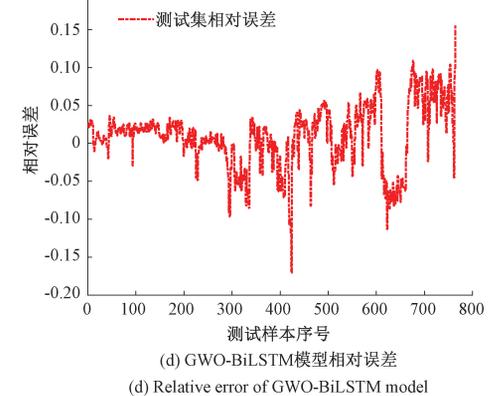
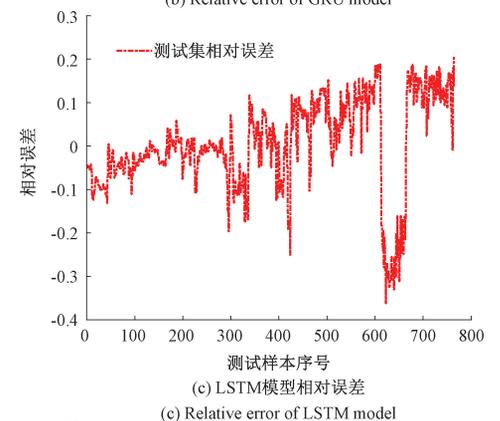
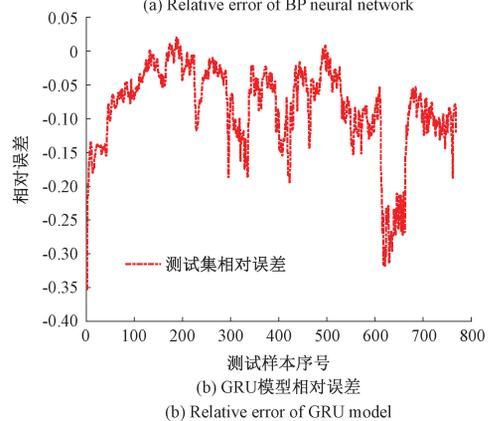
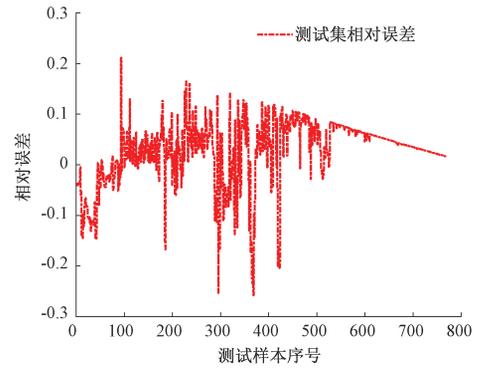


图 10 不同模型预测相对误差对比

Fig. 10 Comparison of relative prediction errors of different models

图 10(a)~(d) 分别是 BP 神经网络模型、GRU 模型、LSTM 模型和 GWO-BiLSTM 模型的相对误差,横坐标是测试集样本点,纵坐标是预测的相对误差。通过图 10 可以看出,BP 神经网络模型、GRU 模型和 LSTM 模型的最大预测相对误差绝对值分别在 0.2、0.35、0.3 左右,意味着预测值有 70%~80% 与真实值一致;而 GWO-BiLSTM 模型的相对误差在 ± 0.1 内,且集中在 ± 0.05 附近,意味着预测值有 95% 左右与真实值一致,表明本文提出的 GWO-BiLSTM 模型具有较好的预测效果。

为进一步验证模型的泛化能力,在相同的实验条件

下,随机选取 3 个继电器数据集分别用 BP 神经网络模型、GRU 模型和 LSTM 模型和训练好的 GWO-BiLSTM 模型进行预测,含 12 号数据集结果在内的各模型性能评价指标数值如表 3 所示。由表 3 可看得出,本文提出的 GWO-BiLSTM 模型的 RMSE 和 MAPE 值均小于其他模型,相比其他预测模型,GWO-BiLSTM 模型的 RMSE 和 MAPE 分别平均下降了 56.7% 和 58.2%,表明该模型能够进一步提高电磁继电器的寿命预测精度,且具有较好的适用性。

表 3 性能评价指标对比

Table 3 Performance evaluation index comparison

模型	12 号继电器		5 号继电器		9 号继电器		14 号继电器	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
BP	206 280	0.051 4	482 330	0.098 6	475 210	0.087 0	218 970	0.041 2
GRU	147 820	0.033 8	314 580	0.089 7	372 000	0.075 6	429 110	0.071 5
LSTM	217 570	0.048 3	173 160	0.043 1	169 510	0.044 4	183 540	0.046 5
GWO-BiLSTM	65 525	0.016 6	137 430	0.028 2	95 972	0.019 9	122 010	0.026 4

3 结 论

针对电磁继电器寿命预测中非线性退化特征捕捉困难、人工调参效率低下等问题,本文将智能优化算法与深度学习模型相结合,提出了一种基于 GWO 算法优化的 BiLSTM 模型,利用实验平台获得的数据集进行验证,并与传统的 BPNN 网络、GRU 和 LSTM 模型相比,所提出的 GWO-BiLSTM 模型在以下 3 个方面取得了实质性进展。1) 利用 BiLSTM 双向时序建模能力解决了传统 BP 神经网络等对时序依赖关系表征不足的问题;2) 通过 GWO 的群体智能搜索机制替代人工调参,大大提升了超参数优化效率;3) 构建的 GWO-BiLSTM 模型在特征提取与参数优化层面形成互补。实验结果表明 GWO-BiLSTM 模型的 RMSE 和 MAPE 较传统方法分别平均下降了 56.7% 和 58.2%,表现出其在电磁继电器寿命预测上的有效性和适用性,为电磁继电器寿命的预测问题提供了新思路。

进一步的研究可沿以下 3 个方向拓展。1) 聚焦多源数据融合与退化机理,深入电磁继电器退化参数的耦合关系,建立更完善的物理-数据融合模型;2) 优化小样本学习策略,强化模型对有限数据的特征挖掘能力,提升模型在复杂工况与小样本条件下的自适应能力与泛化性能;3) 增强预测模型的可解释性,发展不确定性量化与误差修正技术,提高模型置信度。

参考文献

[1] 郑卫红. 继电器在电气工程及自动化低压电器中的

应用[J]. 机电元件, 2022, 42(4): 36-38.

ZHENG W H. Application of relays in electrical engineering and automation low-voltage apparatus [J]. Electromechanical Components, 2022, 42(4): 36-38.

[2] ELGAMAL M, ELADL A A, SEDHOM E B, et al. A deep learning-based cyberattack detection method for transmission line differential relays [J]. Internet of Things, 2025, 31: 101574.

[3] 陈昊, 叶雪荣, 梁慧敏, 等. 磁保持型航天电磁继电器性能提升与质量一致性设计[J]. 电工技术学报, 2023, 38(4): 1076-1087.

CHEN H, YE X R, LIANG H M, et al. Performance improvement and quality consistency design of magnetic latching aerospace electromagnetic relays [J]. Transactions of China Electrotechnical Society, 2023, 38(4): 1076-1087.

[4] 李文华, 桑海爽, 项石虎, 等. 基于可恢复冲击效应的继电器可靠性评估方法[J]. 仪器仪表学报, 2022, 43(11): 200-209.

LI W H, SANG H SH, XIANG SH H, et al. Reliability evaluation method of relay based on recoverable shock effect [J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 200-209.

[5] SUN Y, CAO Y, ZHANG Y, et al. A novel life prediction method for railway safety relays using

- degradation parameters [J]. IEEE Intelligent Transportation Systems Magazine, 2018, 10 (3): 48-56.
- [6] 刘树鑫, 柴宇凡, 李哲, 等. 基于 KNN-ERT 算法的铁路继电器不良数据处理方法[J/OL]. 铁道科学与工程学报, 1-12 [2025-09-18]. <https://doi.org/10.19713/j.cnki.43-1423/u.T20250032>.
- LIU SH X, CHAI Y F, LI ZH, et al. Faulty data processing method for railway relays based on the KNN-ERT algorithm[J/OL]. Journal of Railway Science and Engineering, 1-12 [2025-09-18]. <https://doi.org/10.19713/j.cnki.43-1423/u.T20250032>.
- [7] 聂靖杰, 刘树鑫, 邢朝健, 等. 基于 TPE-Informer 模型的铁路继电器寿命预测[J]. 电气工程学报, 2024, 19(3): 98-106.
- NIE J J, LIU SH X, XING CH J, et al. Life prediction of railway relays based on TPE-Informer mode [J]. Journal of Electrical Engineering, 2024, 19 (3): 98-106.
- [8] GUO G, ZHAO X, LI Q, et al. Analysis and prediction of vibration characteristics of electromagnetic relays[J]. Journal of Physics: Conference Series, 2024, 2849(1): 012013-012013.
- [9] 马东坤, 王召斌, 何天洋. 电磁继电器的剩余使用寿命预测方法综述[J]. 电器与能效管理技术, 2024 (7): 1-8, 49.
- MA D K, WANG ZH B, HE T Y. A comprehensive review of electromagnetic relay remaining useful life prediction method [J]. Electrical & Energy Management Technology, 2024 (7): 1-8, 49.
- [10] 李欣, 刘志强, 魏秀琨. 基于多核高斯过程回归的地铁车辆继电器寿命预测[J]. 中国铁路, 2024 (10): 114-121.
- LI X, LIU ZH Q, WEI X K. Metro vehicle relay life prediction based on multi-kernel Gaussian process regression[J]. China Railway, 2024(10): 114-121.
- [11] 关欣, 吕治国, 岳宝强, 等. 基于权重优化组合模型的电磁继电器寿命预测研究[J]. 电器与能效管理技术, 2022 (6): 45-50.
- GUAN X, LYU ZH G, YUE B Q, et al. Research on life prediction of electromagnetic relay based on weighted optimization combination model[J]. Electrical & Energy Management Technology, 2022(6): 45-50.
- [12] 刘文彪, 段礼祥, 耿帆, 等. 基于 CNN-BLSTM 网络的轴承性能退化预测[J]. 电子测量与仪器学报, 2021, 35(2): 80-86.
- LIU W B, DUAN L X, GENG F, et al. Bearing performance degradation prognosis based on CNN-BLSTM network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 80-86.
- [13] 黄凯, 丁恒, 郭永芳, 等. 基于数据预处理和长短期记忆神经网络的锂离子电池寿命预测[J]. 电工技术学报, 2022, 37(15): 3753-3766.
- HUANG K, DING H, GUO Y F, et al. Prediction of remaining useful life of lithium-ion battery based on adaptive data preprocessing and long short-term memory network [J]. Transactions of China Electrotechnical Society, 2022, 37(15): 3753-3766.
- [14] SUN S, LIU J, WANG J, et al. Remaining useful life prediction for AC contactor based on MMPE and LSTM with dual attention mechanism[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-13.
- [15] 梁浩鹏, 曹洁, 赵小强. 基于并行双向时间卷积网络和双向长短期记忆网络的轴承剩余使用寿命预测方法[J]. 控制与决策, 2024, 39(4): 1288-1296.
- LIANG H P, CAO J, ZHAO X Q. Remaining useful life prediction method for bearings based on parallel bidirectional temporal convolutional network and bidirectional long and short-term memory network [J]. Control and Decision, 2024, 39(4): 1288-1296.
- [16] 陈维兴, 常东润, 李宗帅. 基于改进生成对抗网络与 ConvLSTM 的航空发动机剩余寿命预测方法[J]. 电子测量与仪器学报, 2023, 37(3): 211-221.
- CHEN W X, CHANG D R, LI Z SH. Aeroengine residual life prediction method based on improved generative adversarial network and ConvLSTM [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 211-221.
- [17] CHEN Z, DAI M, LIU J, et al. Life prediction of IGBT module for nuclear power plant rod position indicating and rod control system based on SDAE-LSTM [J]. Nuclear Engineering and Technology, 2024, 56(9): 3740-3749.
- [18] SONG F, WANG Z, LIU X, et al. Remaining life prediction of rolling bearings with secondary feature selection and BSBiLSTM[J]. Measurement Science and Technology, 2024, DOI:10.1088/1361-6501/AD3EA6.
- [19] 李敬一, 苏翔. GWO 优化 CNN-BiLSTM-Attention 的轴承剩余寿命预测方法 [J]. 振动与冲击, 2025, 44(2): 321-332.

- LI J Y, SU X. Residual life prediction method of bearings based on CNN-BiLSTM-Attention optimized by the grey wolf optimizer [J]. *Journal of Vibration and Shock*, 2025, 44(2): 321-332.
- [20] LIU Z S, YANG J F. Research on short-term load forecasting based on GWO-BiLSTM [C]. 3rd International Conference on Electrical, Electronic Information and Communication Engineering, 2022.
- [21] 焦佳明, 毕俊喜, 葛新宇, 等. 基于优化 LSTM 模型的风力机叶片剩余使用寿命预测[J]. *太阳能学报*, 2024, 45(6): 495-502.
- JIAO J M, BI J X, GE X Y, et al. Remaining useful life prediction of wind turbine blades based on optimized LSTM model[J]. *Acta Energetica Solaris Sinica*, 2024, 45(6): 495-502.
- [22] 张加劲. 基于注意力机制和 CNN-BiLSTM 模型的航空发动机剩余寿命预测[J]. *电子测量与仪器学报*, 2022, 36(8): 231-237.
- ZHANG J J. Remaining useful life estimation of aero-engine based on CNN-BiLSTM and attention mechanism [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(8): 231-237.
- [23] 李家豪, 王青于, 范玥霖, 等. 鲸鱼优化算法-双向长短期记忆神经网络用于断路器机械剩余寿命的预测研究[J]. *高电压技术*, 2024, 50(1): 250-262.
- LI J H, WANG Q Y, FAN Y L, et al. Research on whale optimization algorithm-bidirectional long-short-term memory neural network for prediction of machinery remaining useful life of circuit breaker [J]. *High Voltage Engineering*, 2024, 50(1): 250-262.
- [24] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [25] 张晓凤, 王秀英. 灰狼优化算法研究综述[J]. *计算机科学*, 2019, 46(3): 30-38.
- ZHANG X F, WANG X Y. Comprehensive review of grey wolf optimizer algorithm [J]. *Computer Science*, 2019, 46(3): 30-38.
- [26] 焦晓璇, 景博, 李娟, 等. 基于 ADEGWO-SVM 的机载燃油泵寿命预测研究[J]. *仪器仪表学报*, 2018, 39(8): 43-52.
- JIAO X X, JING B, LI J, et al. Research on remaining useful life prediction of fuel pump based on adaptive differential evaluation grey wolf optimizer-support vector machine[J]. *Chinese Journal of Scientific Instrument*, 2018, 39(8): 43-52.
- [27] 薛阳, 燕宇铖, 贾巍, 等. 基于改进灰狼算法优化长短期记忆网络的光伏功率预测[J]. *太阳能学报*, 2023, 44(7): 207-213.
- XUE Y, YAN Y CH, JIA W, et al. Photovoltaic power prediction based on improved grey wolf algorithm optimized long short-term memory network [J]. *Acta Energetica Solaris Sinica*, 2023, 44(7): 207-213.
- [28] 张蕊, 张泰瑀, 贾民平, 等. 多传感器融合和 MHA-LSTM 的电机轴承剩余寿命预测[J]. *仪器仪表学报*, 2024, 45(3): 84-93.
- ZHANG W, ZHANG T Y, JIA M P, et al. Prediction of remaining life of motor bearings using multi-sensor fusion and MHA-LSTM [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(3): 84-93.
- [29] 黄宇, 冯坤, 高俊峰, 等. 结合 LSTM 和 Self-Attention 的滚动轴承剩余使用寿命预测方法[J]. *振动工程学报*, 2023, 36(6): 1744-1753.
- HUANG Y, FENG K, GAO J F, et al. Remaining useful life prediction method for rolling bearings combining LSTM and Self-Attention [J]. *Journal of Vibration Engineering*, 2023, 36(6): 1744-1753.
- [30] 李奎, 李晓倍, 郑淑梅, 等. 基于 BP 神经网络的交流接触器剩余电寿命预测[J]. *电工技术学报*, 2017, 32(15): 120-127.
- LI K, LI X B, ZHENG SH M, et al. Residual electrical life prediction for AC contactors based on BP neural network [J]. *Transactions of China Electrotechnical Society*, 2017, 32(15): 120-127.
- [31] 刘树鑫, 高士珍, 刘洋, 等. 基于 LSTM 的交流接触器剩余寿命预测[J]. *高电压技术*, 2022, 48(8): 3210-3220.
- LIU SH X, GAO SH ZH, LIU Y, et al. Residual life prediction of AC contactor based on long short-term memory [J]. *High Voltage Engineering*, 2022, 48(8): 3210-3220.
- [32] 刘雨生, 汤新民, 任宣铭. 基于注意力机制的 GRU-IKF 场面滑行轨迹预测模型[J]. *北京航空航天大学学报*, 2025, 51(3): 1028-1036.
- LIU Y SH, TANG X M, REN X M. Taxiing trajectory prediction model based on attention mechanism and GRU-IKF[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2025, 51(3): 1028-1036.

作者简介



杨蕊璟, 2023 年于西安工业大学获得学士学位, 现为空军工程大学硕士研究生, 主要研究方向为故障预测与健康管理。

E-mail: yangrj135@163.com

Yang Ruijing received her B. Sc. degree from Xi'an Technological University in 2023.

Now she is a M. Sc. candidate at Air Force Engineering University. Her main research interest includes prognostics health management.



黄以锋, 分别在 2006 年、2008 年和 2011 年于空军工程大学获得学士学位、硕士学位和博士学位, 现为空军工程大学副教授, 主要研究方向为复杂设备测试性设计, 故障诊断与寿命预测。

E-mail: huangyiff@163.com

Huang Yifeng received his B. Sc. degree, M. Sc. degree

and Ph. D. degree from Air Force Engineering University in 2006, 2008 and 2011. Now he is an associate professor in Air Force Engineering University. His main research interests include complex equipment test design and prognostics and fault diagnosis and life prediction.



焦晓璇(通信作者), 分别在 2012 年、2014 年和 2019 年于空军工程大学获得学士学位、硕士学位和博士学位, 现为空军工程大学副教授, 主要研究方向为信息融合、故障诊断与预测。

E-mail: jiaoxx_sensor@outlook.com

Jiao Xiaoxuan (Corresponding author) received his B. Sc. degree, M. Sc. degree and Ph. D. degree from Air Force Engineering University in 2012, 2014 and 2019. Now he is an associate professor at Air Force Engineering University. His main research interests include information fusion, fault diagnosis and prognostics.