

DOI: 10.13382/j.jemi.B2306316

基于 CEEMDAN 与改进核极限学习机的 S700K 转辙机健康状态诊断^{*}

米根锁 窦媛媛

(兰州交通大学自动化与电气工程学院 兰州 730070)

摘要:针对 S700K 转辙机健康状态分类过于粗放、诊断速度慢、效率低的问题,提出一种基于 CEEMDAN 与改进核极限学习机(kernel based extreme learning machine, KELM)的诊断方法。首先,对 S700K 转辙机功率数据进行自适应噪声完备集合经验模态分解,得到 6 个本征模态函数(intrinsic mode function, IMF);然后,计算本征模态函数的模糊熵值(fuzzy entropy, fuzzyEn, FE)作为表征转辙机健康状态的特征参数;最后,利用麻雀算法(sparrow search algorithm, SSA)改进的核极限学习机对 9 种健康状态进行健康诊断,并与 SVR 和 ELM 模型进行对比。仿真结果表明,改进核极限学习机模型准确率、精确率、召回率等指标分别达到 97.8%、98.0%、97.8%,相较于 SVR 和 ELM 模型,SSA-KELM 模型在保证运行速度的基础上,将诊断准确率至少提高 2.2%。

关键词: CEEMDAN;改进核极限学习机;S700K 转辙机;健康状态诊断

中图分类号: U284

文献标识码: A

国家标准学科分类代码: 580.80

Health state diagnosis of S700K switch machine based on CEEMDAN and improved kernel based extreme learning machine

Mi Gensuo Dou Yuanyuan

(School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Aiming at the problems of extensive classification of health status of S700K switch machine, slow diagnosis speed and low efficiency; a diagnosis method based on CEEMDAN and kernel based extreme learning machine (KELM) is proposed. Firstly, the power data of S700K switch machine is decomposed by adaptive noise complete set empirical mode decomposition, and six intrinsic mode functions (IMF) are obtained. Then, the fuzzy entropy (FE) value of the intrinsic mode function is calculated as the characteristic parameter to characterize the health state of the switch machine. Finally, the kernel limit learning machine improved by sparrow search algorithm (SSA) is used to diagnose nine health states, and compared with SVR and ELM models. The simulation results show that the accuracy rate and the recall rate of the improved kernel based extreme learning machine model are 97.8%, 98.0% and 97.8% respectively. Compared with SVR and ELM models, SSA-KELM model improves the diagnostic accuracy rate by at least 2.2% on the basis of ensuring the running speed.

Keywords: CEEMDAN; improved kernel based extreme learning machine; S700K switch machine; health status diagnosis

0 引言

S700K 转辙机作为重要的铁路基础信号设备,对其进行健康状态诊断能够有效降低安全风险和维修成本,保障列车安全运行^[1]。目前,辙机维修体制逐步从传统的事后维修、定期维修向状态维修转变,研究转辙机健康

状态诊断为实现状态维修提供依据,解决传统维修体制带来的设备故障预防重点不突出的问题,近年来,对转辙机故障诊断的研究层出不穷,而故障发生前的亚健康状态对于转辙机的运营维护更为重要。因此,通过分析全周期内的转辙机功率曲线来判断转辙机健康状态的诊断方法具有重大意义。

通过计算待诊断数据与数据库中各状态模板数据的

收稿日期: 2023-03-07 Received Date: 2023-03-07

^{*} 基金项目: 甘肃省科学计划项目(21JR7RA305)、中央引导地方科技发展资金项目(22ZY1QA005)、兰州交通大学青年科学研究基金项目(1200061027)资助

Hausdorff 距离^[2]、费雷歇距离^[3], Pearson 相关系数^[4]等相似性度量来判断各状态类型,但转辙机早期故障样本积累较少,只适用于小样本诊断;基于模糊聚类^[5-6], k-means 等无监督学习的诊断方法,不需要人工标注样本作为待检数据集,但是分类精度低于监督学习;基于 CNN^[7]、熵及其变体^[8]、局部均值分解^[9]等信号处理方法结合支持向量机^[10]、极限学习机^[11]、深度神经网络^[12]、隐半马尔科夫模型 HSMM^[13]等监督学习的诊断方法实现方便,诊断精度高,但对于不同诊断方法的结果、特点、准确性具有一定程度的差异,所以进一步提高诊断精度与效率是目前的研究重点。

本文提出基于 CEEMDAN 和改进核极限学习机的转辙机健康状态诊断方法。利用 CEEMDAN 信号分解方法在提高运行效率的基础上减轻白噪声的干扰,减少重构误差;通过麻雀算法改进的核极限学习机进行健康状态诊断,既能发挥监督学习的优势又能进一步提高状态诊断的准确率和训练速度,还能避免深度学习算法带来的耗时耗资的问题。

1 S700K 转辙机动作功率曲线分析

根据转辙机全周期功率曲线数据将健康状态分为健康、亚健康 and 故障 3 个等级如表 1 所示。

1.1 健康状态动作功率曲线

通过分析 S700K 转辙机的动作功率曲线,可以清楚地反映出道岔尖轨扳动时的推拉力,从而更好地了解道岔转换时的整体运行状况,S700K 转辙机健康状态动作功率曲线如图 1 所示。

由图 1 可以看出,在设备启动过程中由于转辙机要克服阻力进行解锁工作,输出功率会出现较大的峰值;道岔开始动作,进入解锁、转换阶段,功率较为平稳,其中转换阶段时间较长,会导致电机空转的情况,造成严重故




图 1 转辙机健康状态动作功率曲线

Fig. 1 Switch machine health state action power curve

障;道岔转换到位后进入锁闭阶段,缓放过程中出现台阶;最后,启动电路断开接通表示电路,进入表示阶段后功率值逐渐降为 0。

1.2 亚健康状态动作功率曲线

实际现场中,由于机械磨损劣化、外界客观因素的干扰,会导致转辙机随时处于亚健康状态,存在安全隐患。以某电务段关于 S700K 转辙机动作功率曲线的历史数据为例,亚健康状态下,动作过程中功率曲线不平稳,呈现不同程度的波动,但都能转换到位。例如转辙机运行过程中出现回路电流偏大的问题,功率曲线在锁闭阶段 4.32 s 开始功率有小幅上升,锁闭阶段的小台阶比健康状态下动作功率曲线稍大^[14],如图 2(a)所示,将此种状态命名为“亚健康 1”;道岔杆件等装置安装不当导致功率曲线在 3.76 s 处出现轻微波动,但仍能正常转换,如图 2(b)所示,将此种状态命名为“亚健康 2”。对于亚健康状态下的转辙机及时进行预防维修,在固定检修日到来之前进行处理,降低发生故障的概率。

1.3 故障状态动作功率曲线

本文参考文献[8]的 6 种典型故障状态,其功率曲线如图 2 所示,曲线特征及故障原因如表 1 所示。

表 1 S700K 转辙机健康状态分类
Table 1 Health status classification of S700K switch machine

健康等级	健康状态	故障原因	曲线特征
健康	健康	正常	解锁峰值、转换平稳,锁闭“小台阶”
亚健康	亚健康 1	回路电流偏大	锁闭阶段“小台阶”比正常曲线稍大
	亚健康 2	道岔杆件等不牢固或安装不当	转换阶段出现波动,但能完成转换动作
健康等级	健康状态	故障原因	曲线特征
故障	故障 1	下拉装置异常,道岔不能正常解锁	解锁阶段曲线小程度上浮并保持
	故障 2	动作杆卡阻,道岔不能正常转换	锁闭阶段曲线明显上升,功率值偏大
	故障 3	锁闭块或锁舌被卡死,造成锁闭异常	曲线持续上升,并在锁闭阶段小幅上升并保持
	故障 4	转辙机卡缺口,无法锁闭	表示阶段不降反升,形成空转曲线
	故障 5	断相保护器发生故障	表示阶段曲线正常下降,但没降至 0
	故障 6	表示电路故障	表示阶段曲线大幅且无规则波动




图 2 S700K 转辙机样本功率曲线
Fig. 2 Sample power curve of S700K switch machine

2 健康状态诊断方案设计

针对不同健康状态下, S700K 转辙机功率曲线的差异性, 提出 CEEMDAN 算法对其进行信号分解; 计算各本征模态函数的模糊熵构成 IMF 模糊熵作为特征参数; 利用麻雀算法优化的核极限学习机进行健康状态诊断。

2.1 CEEMDAN-FE 特征提取

自适应噪声完备集合经验模态分解 (complete EEMD with adaptive noise, CEEMDAN) 是一种基于 EMD 的模态分解方法, 引入高斯噪声, 结合多次叠加并平均^[15], 有效抑制噪声和模态混叠问题, 减少重构误差, CEEEMDAN 作为 EMD 和 EEMD 方法的改进形式, 具有很好的完备性, 减少幅值很小的低频 IMF 分量的数目, 并获得更快的运行速度, 提高运行效率。CEEMDAN 具体分解步骤如下:

1) 添加 k 次高斯白噪声到待分解信号 $y(t)$, 得到 k 个待分解序列 $y_i(t)$ 。

$$y_i(t) = y(t) + \varepsilon \sigma_i(t) \tag{1}$$

式中: $i = 1, 2, 3, 4, \dots, k$; ε 为高斯白噪声的权值系数; $\sigma_i(t)$ 为第 i 次分解时产生的高斯白噪声。

2) 对序列 $y_i(t)$ 进行 EMD 分解, 分解得到 k 个 IMF_1^i 并取其均值得到 $IMF_1(t)$ 和残差信号 $r_1(t)$ 。

$$IMF_1(t) = \frac{1}{k} \sum_{i=1}^k IMF_1^i(t) \tag{2}$$

$$r_1(t) = y(t) - IMF_1(t) \tag{3}$$

3) 将分解后得到的第 ω 阶段残差添加特定噪声后, 继续进行 EMD 分解, 分解得到第 ω 个 IMF 分量和残差信

号 $r_\omega(t)$ 。


$$IMF_\omega(t) = \frac{1}{k} \sum_{i=1}^k E_1(r_{\omega-1}(t) + \varepsilon_{\omega-1} E_{\omega-1}(\sigma_i(t))) \tag{4}$$

$$r_\omega(t) = r_{\omega-1}(t) - IMF_\omega(t) \tag{5}$$

4) 如果满足 EMD 停止准则, 迭代停止, CEE-MDAN 算法分解结束。

以健康状态、“亚健康 1”状态和“故障 6”状态为例, CEEMDAN 分解结果如图 3 所示。

针对 S700K 转辙机各状态之间功率曲线存在很大相似性的问题, 本文采用 CEEMDAN 结合模糊熵的方法进行功率曲线特征提取。模糊熵在传统信息熵的基础上引入了模糊隶函数代替硬阈值判据是一种更加科学的表达






图3 CEEMDAN 分解结果
Fig.3 CEEMDAN decomposition results

信号复杂度的方法,熵值越大代表信号复杂度越大^[16],模糊熵的具体计算过程如下:

- 1) 对于给定的 N 维时间序列
[$u(1), u(2), \dots, u(N)$]
- 2) 定义相空间维数 $m(m \leq N - 2)$ 和相似容限度 r , 重构相空间

$$X(i) = [u(i), u(i + 1), \dots, u(i + m - 1)] - u_0(i)$$

(6)

式中: $i = 1, 2, \dots, N - m + 1$

$$u_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} u(i + j)$$

(7)

- 3) 引入模糊隶属函数

$$A(x) = \begin{cases} 1, & x = 0 \\ \exp\left[-\ln(2) \left(\frac{x}{r}\right)^2\right], & x > 0 \end{cases}$$

(8)

式中: r 为相似容限度
对于 $i = 1, 2, \dots, N - m + 1$ 时, 计算:

$$A_{ij}^m = \exp\left[-\ln(2) \cdot \left(\frac{d_{ij}^m}{r}\right)^2\right]$$

(9)

式中: $j = 1, 2, \dots, N - m + 1, j \neq i$

功率曲线据经 CEEMDAN 进行预处理之后,计算各 IMF 的模糊熵值,设置嵌入维数 $m = 3$ 、模糊函数梯度为 $n = 2$ 、相似容限度 $r = 0.2 \times std$,得到表征功率数据特征的 6 维特征向量, S700K 转辙机各健康状态模糊熵值如表 2 所示,根据转辙机各健康状态的模糊熵值的差异性,说明不同状态下利用 CEEMDAN 结合模糊熵能够有效提取特征,将 9 种健康状态区分开来。

表 2 S700K 转辙机各状态模糊熵值
Table 2 Fuzzy entropy value of each state
of S700K switch machine

健康状态	FE1	FE2	FE3	FE4	FE5	FE6
健康	0.027 6	0.051 7	0.156 0	0.340 7	0.236 4	0.084 8
亚健康 1	0.024 1	0.026 0	0.129 8	0.346 2	0.221 3	0.086 9
亚健康 2	0.034 9	-0.017 6	0.060 8	0.231 8	0.224 6	0.075 0
故障 1	0.012 6	0.017 9	0.016 9	0.211 0	0.479 9	0.148 1
故障 2	0.034 0	0.055 5	0.072 8	0.301 5	0.202 5	0.051 4
故障 3	0.045 7	0.041 1	0.111 4	0.299 5	0.196 1	0.040 2
故障 4	0.002 2	-0.002 7	0.108 1	0.289 8	0.163 0	0.016 9
故障 5	0.053 9	0.019 0	0.165 3	0.280 9	0.232 0	0.082 3
故障 6	0.057 5	0.091 5	0.085 7	0.173 9	0.112 7	0.038 8

2.2 SSA-KELM 模型

KELM 利用核函数替代 ELM 中的内积运算,增强模型的稳定性,将正则化系数 C 引入核极限学习机^[17],提高模型的预测性能和泛化能力。

KELM 模型输入神经元节点数设置为 6,输出神经元节点数设置为 9,由于核函数 $K()$ 是一种内积形式,输出结果只需知道核函数的具体形式,不需要明确隐含层节点数。KELM 作为分类器,特征提取阶段选择不同样本不改变 KELM 多分类网络结构,经过测试训练确定其他合适的参数后,将标签标记后的 9 种健康状态功率曲线 IMF 模糊熵输入模型训练,用训练好的 KELM 模型对健康状态诊断特征信号进行分类,其模型示意图如图 4 所示。

核参数 K 和正则化系数 C 主要依靠经验进行人为设定,两者的设定将对 KELM 的诊断性能具有一定影响^[18],核参数的选取影响健康状态分类的精细程度,正则化系数的选取影响模型的复杂度。正则化系数越大模型泛化能力越强,越容易出现偏差;正则化系数越小模型




图 4 KELM 模型示意图

Fig. 4 Schematic diagram of KELM model

泛化能力弱,但易发生过拟合,所以本文引入麻雀算法对核极限学习机的核参数 K 和正则化系数 C 进行迭代寻优,进一步提高核极限学习机的诊断精度,麻雀优化算法搜索能力强、收敛速度快、稳定性好^[19],利用麻雀算法优化的核极限学习机能够有效提高 S700K 转辙机健康诊断的精度与效率。参数优化过程如图 5 所示,麻雀算法种群数设置为 30,迭代次数设置为 100,麻雀收敛曲线如图 6 所示。




图 5 SSA 优化 KELM 参数

Fig. 5 SSA optimizes KELM parameters

$$F_x = h(x) \times \beta = H \times \beta = L \tag{10}$$

$$\Omega_{ELM} = HH^T = h(x_i)h(x_j) = h(x_i, x_j) \tag{11}$$

$$\beta = H^T(HH^T + \frac{1}{C})^{-1}L \tag{12}$$




图 6 麻雀收敛曲线

Fig. 6 Sparrow Convergence Curve

$$F_x = [K(x, x_1); \cdots; K(x, x_n)] (\frac{1}{C} + \Omega_{ELM})^{-1}L \tag{13}$$

其中: $(x_1, x_2, \cdots, x_n)$ 为给定训练样本, n 为样本总数, $K()$ 为核函数。

3 实例分析

本文利用 MATLAB 进行仿真,以某电务段关于 S700K 转辙机功率曲线的 450 组历史样本数据为例,9 种健康状态各抽取 40 组样本,共 360 组数据作为训练集,其余 90 组数据作为测试集。采用本文所提出的方法对转辙机进行健康状态诊断,并与极限学习机和支持向量回归^[20](support vector regression, SVR)进行比较。通过准确率,精确率,召回率, F_1 和模型训练时间对模型性能进行评价如式 (14) ~ (17) 所示。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{14}$$

$$Precision = \frac{TP}{TP + FP} \tag{15}$$

$$Recall = \frac{TP}{TP + FN} \tag{16}$$

$$F_1 = \frac{2TP}{2TP + FP + FN} \tag{17}$$

如图 7 所示,横坐标为测试样本,纵坐标为健康状态,由于曲线特征相似,健康状态与亚健康状态,亚健康 1 与亚健康 2,故障 3 与 4,亚健康 2 与故障 5,故障 4 与故障 5 之间最易发生诊断错误,除此以外,9 种健康状态诊断结果均与现场检修结果一致,相比 ELM 和 SVR 模型,SSA-KELM 提高了健康状态诊断结果的准确性。

为了直观表现模型诊断的准确性,引入混淆矩阵,ELM,SVR 和 SSA-KELM 模型混淆矩阵如图 8 所示。改进的核极限学习机模型准确率,精确率,召回率均优于传统核极限学习机;本文模型相比 ELM 模型准确率提高了

效率,不同模型性能对比如表 3 所示。

表 3 不同模型性能对比

Table 3 Performance comparison of different models					
模型	准确率/ %	精确率/ %	召回率/ %	F_1 值/ %	训练时间/ s
SSA-KELM	97.8	98.0	97.8	98.0	2.1
KELM	96.7	97.0	96.7	96.8	1.5
SVR	95.6	96.1	95.6	95.8	6.2
ELM	92.2	93.2	93.3	93.0	2.7

		混淆矩阵									
预测健康状态	健康	8 8.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.1%	0 0.0%	88.9% 11.1%
	亚健康1	2 2.2%	9 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	81.8% 18.2%
	亚健康2	0 0.0%	1 1.1%	10 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90.9% 9.1%
	故障1	0 0.0%	0 0.0%	0 0.0%	10 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	故障2	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	故障3	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 10.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	故障4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.1%	10 11.1%	2 2.2%	0 0.0%	76.9% 23.1%
	故障5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 7.8%	0 0.0%	100% 0.0%
故障6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 11.1%	100% 0.0%	
		80.0% 20.0%	90.0% 10.0%	100% 0.0%	100% 0.0%	100% 0.0%	90.0% 10.0%	100% 0.0%	70.0% 30.0%	100% 0.0%	92.2% 7.8%
		健康	亚健康1	亚健康2	故障1	故障2	故障3	故障4	故障5	故障6	
		实际健康状态									

(a) ELM模型混淆矩阵
(a) ELM model confusion matrix

		混淆矩阵									
预测健康状态	健康	9 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	亚健康1	0 0.0%	9 10.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	亚健康2	1 1.1%	1 1.1%	10 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	83.3% 16.7%
	故障1	0 0.0%	0 0.0%	0 0.0%	10 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	故障2	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	故障3	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 11.1%	1 1.1%	0 0.0%	0 0.0%	90.9% 9.1%
	故障4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 8.9%	0 0.0%	0 0.0%	100% 0.0%
	故障5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.1%	10 11.1%	0 0.0%	0 0.0%	90.9% 9.1%
	故障6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 11.1%	100% 0.0%
		90.0% 10.0%	90.0% 10.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	80.0% 20.0%	100% 0.0%	100% 0.0%	95.6% 4.4%
		实际健康状态									
		健康	亚健康1	亚健康2	故障1	故障2	故障3	故障4	故障5	故障6	

(b) SVR模型混淆矩阵
(b) SVR model confusion matrix




图 7 ELM,SVR,SSA-KELM 模型诊断结果

Fig. 7 ELM, SVR, SSA-KELM model diagnosis results

5.6%,相比 SVR 模型提高了 2.2%;训练时间提高至少 1.2 s,均优于其他两种模型,说明本文模能够满足健康状态诊断需求,能够有效提高现场工作人员进行状态检修

		混淆矩阵									
预测健康状态	健康	9	0	0	0	0	0	0	0	0	100%
		10.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
	亚健康1	1	10	0	0	0	0	0	0	0	90.9%
		1.1%	11.1%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	9.1%
	亚健康2	0	0	9	0	0	0	0	0	0	100%
		0.0%	0.0%	10.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
	故障1	0	0	0	10	0	0	0	0	0	100%
		0.0%	0.0%	0.0%	11.1%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
	故障2	0	0	0	0	10	0	0	0	0	100%
		0.0%	0.0%	0.0%	0.0%	11.1%	0.0%	0.0%	0.0%	0.0%	0.0%
实际健康状态	故障3	0	0	0	0	0	10	0	0	0	100%
		0.0%	0.0%	0.0%	0.0%	0.0%	11.1%	0.0%	0.0%	0.0%	0.0%
	故障4	0	0	0	0	0	0	10	0	0	100%
		0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	11.1%	0.0%	0.0%	0.0%
	故障5	0	0	1	0	0	0	0	10	0	90.9%
		0.0%	0.0%	1.1%	0.0%	0.0%	0.0%	0.0%	11.1%	0.0%	9.1%
	故障6	0	0	0	0	0	0	0	0	10	100%
		0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	11.1%	0.0%
		90.0%	100%	90.0%	100%	100%	100%	100%	100%	100%	97.8%
		10.0%	0.0%	10.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	2.2%

(c) SSA-KELM模型混淆矩阵
(c) SSA-KELM model confusion matrix

图 8 ELM,SVR,SSA-KELM 模型混淆矩阵

Fig.8 ELM, SVR, SSA-KELM model confusion matrix

4 结 论

本文提出了自适应噪声完备集合经验模态分解与改进核极限学习机结合的 S700K 转辙机健康状态诊断的方法,通过现场实际数据验证,得到如下结论。

针对 S700K 转辙机功率信号非平稳、非线性的特点,提出 CEEMDAN 结合模糊熵的特征提取的方法,减少白噪声和模态混叠现象对特征提取的影响,是一种有效的特征提取方法。

利用麻雀算法寻优能力强,收敛速度快的特点改进核极限学习机,使核极限学习机的诊断准确率提高了至少 1.1%。

相比于支持向量回归和传统极限学习机方法,改进的核极限学习机能够有效诊断 S700K 转辙机健康状态,在保证运行速度的同时,准确率达到 97.8%,能够适应实际现场需求。

参考文献

[1] 李政. 基于 VMD 排列熵和模糊聚类的 S700K 转辙机状态评估[D]. 兰州:兰州交通大学,2022.
LI ZH. State evaluation of S700K switch machine based on VMD permutation entropy and fuzzy clustering [D]. Lanzhou:Lanzhou Jiaotong University, 2022.

[2] 郑云水,白邓宇,王妍. 基于相似度的道岔健康状态评估及故障检测方法研究[J]. 铁道科学与工程学报,

2021,18(4):877-884.

ZHENG Y SH, BAI D Y, WANG Y. Research on health status assessment and fault detection method of turnout based on similarity [J]. Journal of Railway Science and Engineering, 2021,18 (4): 877-884.

[3] 黄世泽,陈威,张帆,等. 基于弗雷歇距离的道岔故障诊断方法[J]. 同济大学学报(自然科学版),2018,46(12):1690-1695.

HUANG SH Z, CHEN W, ZHANG F,et al. Switch fault diagnosis method based on Frescher distance [J]. Journal of Tongji University (Natural Science Edition), 2018,46 (12): 1690-1695.

[4] 钟志旺. 铁路道岔健康状态评估与预测方法研究[D]. 北京:北京交通大学,2019.

ZHONG ZH W. Research on evaluation and prediction methods of railway turnout health status [D]. Beijing: Beijing Jiaotong University, 2019.

[5] 武晓春,楚昕. 基于小波包分解与 GG 模糊聚类的转辙机退化阶段划分研究[J]. 铁道学报,2022,44(1):79-85.

WU X CH, CHU X. Research on the degradation stage division of switch machine based on wavelet packet decomposition and GG fuzzy clustering [J]. Journal of Railway, 2022,44 (1): 79-85.

[6] 张友鹏,张迪,杨妮,等. 基于 CEEMDAN 与 KFCM 聚类的转辙机退化状态识别方法[J]. 中国铁道科学,2023,44(1):194-201.

ZHANG Y P, ZHANG D, YANG N, et al. Recognition method of switch machine degradation state based on CEEMDAN and KFCM clustering [J]. China Railway Science, 2023,44 (1): 194-201.

[7] 池毅,陈光武. 基于一维卷积神经网络的实时道岔故障诊断[J]. 计算机工程与应用,2022,58(20):293-299.

CHI Y, CHEN G W. Real-time turnout fault diagnosis based on one-dimensional convolutional neural network[J]. Computer Engineering and Applications, 2022,58 (20): 293-299.

[8] 魏文军,刘新发,张轩铭,等. 基于 EEMD 多尺度模糊熵的 S700K 转辙机故障诊断[J]. 铁道学报,2022,44(5):60-66.

WEI W J, LIU X F, ZHANG X M,et al. Fault diagnosis of S700K switch machine based on EEMD multi-scale fuzzy entropy [J]. Journal of Railway, 2022,44 (5): 60-66.

[9] 魏文军,李政,武晓春,等. 基于模糊聚类算法的 S700K 型电动转辙机运行状态评估[J]. 铁道学报,2022,44(4):74-81.

- WEI W J, LI ZH, W X CH, et al. Evaluation of operation status of S700K electric switch machine based on fuzzy clustering algorithm [J]. Journal of Railway, 2022, 44 (4): 74-81.
- [10] 刘应君, 司涌波, 陈光武, 等. 基于 CDET/MPSO-SVM 的道岔故障诊断 [J]. 北京交通大学学报, 2021, 45(2): 52-59.
- LIU Y J, SI Y B, CHEN G W, et al. Switch fault diagnosis based on CDET/MPSO-SVM [J]. Journal of Beijing Jiaotong University, 2021, 45 (2): 52-59.
- [11] 刘伯鸿, 王萌萌. 基于小波能谱熵和改进 ELM 的转辙机故障预测 [J]. 云南大学学报 (自然科学版), 2022, 44(3): 497-504.
- LIU B H, WANG M M. Fault prediction of switch machine based on wavelet energy spectrum entropy and improved ELM [J]. Journal of Yunnan University (Natural Science Edition), 2022, 44 (3): 497-504.
- [12] 王瑞峰, 李扬. 基于 1DCNN-BiLSTM 组合模型的 S700K 转辙机故障诊断 [J]. 电子测量与仪器学报, 2022, 36(11): 193-200.
- WANG R F, LI Y. Fault diagnosis of S700K switch machine based on 1DCNN-BiLSTM combined model [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (11): 193-200.
- [13] 陈永刚, 戴乾军, 李俊武. 基于 SA-CPSO 优化 HSMM 的转辙机故障预测模型研究 [J]. 铁道科学与工程学报, 2019, 16(4): 1050-1057.
- CHEN Y G, DAI Q J, LI J W. Research on fault prediction model of switch machine based on SA-CPSO optimized HSMM [J]. Journal of Railway Science and Engineering, 2019, 16 (4): 1050-1057.
- [14] 魏文军, 李政, 武晓春. 基于功率曲线时域特征和变分模态分解的 S700K 转辙机运行状态诊断算法 [J]. 中国铁道科学, 2022, 43(3): 144-154.
- WEI W J, LI ZH, WU X CH. S700K switch machine operation state diagnosis algorithm based on time domain characteristics of power curve and variational mode decomposition [J]. China Railway Science, 2022, 43 (3): 144-154.
- [15] 费鸿禄, 山杰. CEEMDAN-小波阈值法在爆破振动信号处理中的应用 [J]. 爆破, 2022, 39(3): 41-47, 164.
- FEI H L, SHAN J. Application of CEEMDAN-wavelet threshold method in blasting vibration signal processing [J]. Blasting, 2022, 39(3): 41-47, 164.
- [16] 张勇, 刘洁, 路敬祯, 等. 基于 VMD 去噪及多尺度模糊熵的管道小泄漏研究 [J]. 电子测量技术, 2021, 44(22): 37-43.
- ZHANG Y, LIU J, LU J Y, et al. Research on small pipeline leakage based on VMD denoising and multi-scale fuzzy entropy [J]. Electronic Measurement Technology, 2021, 44 (22): 37-43.
- [17] 赵翔, 涂娟, 黄紫娟. 基于优化模糊加权核极限学习机的下肢运动识别方法 [J]. 传感技术学报, 2022, 35(5): 621-626.
- ZHAO X, TU J, HUANG Z J. Lower limb motion recognition method based on optimized fuzzy weighted kernel limit learning machine [J]. Journal of Sensing Technology, 2022, 35 (5): 621-626.
- [18] WANG L, YUE J, WU C, et al. KPCA-KELM ensemble based incipient fault diagnosis approach of analog circuits [C]. 2018 Chinese Automation Congress (CAC). IEEE, 2018: 3577-3582.
- [19] 郭建帅, 崔双喜, 郭建斌, 等. 基于 VMD-SSA-HKELM 的超短期负荷预测 [J]. 国外电子测量技术, 2022, 41(6): 105-111.
- GUO J SH, CUI SH X, GUO J B, et al. Ultra short-term load forecasting based on VMD-SSA-HKELM [J]. Foreign Electronic Measurement Technology, 2022, 41(6): 105-111.
- [20] CUI J, ZHAO J, CUI X, et al. Remaining useful life prediction of aviation lithium-ion battery based on SVR-MC [C]. 2022 34th Chinese Control and Decision Conference (CCDC). IEEE, 2022: 505-510.

作者简介



米根锁 (通信作者), 1998 年于西南交通大学获得工学硕士学位, 现为兰州交通大学教授, 主要研究方向为交通信息工程及控制。

E-mail: 3573901427@qq.com

Mi Gensuo (Correspondence author)

received a M. Sc. degree of Engineering degree from Southwest Jiaotong University in 1998. He is now a professor of Lanzhou Jiaotong University. His main research interest includes traffic information engineering and control.



窦媛媛, 现为兰州交通大学硕士研究生, 主要研究方向为转辙机健康状态评估。

E-mail: 1084174490@qq.com

Dou Yuanyuan is now a M. Sc. candidate at Lanzhou Jiaotong University. Her

main research interest includes switch machine health status assessment.