

doi: 10.7690/bgzd.2021.10.003

一种改进粒子群优化 HMM 的故障诊断方法

吴琼琼¹, 李英顺², 戴喜生¹, 刘胜永¹

(1. 广西科技大学电气与信息工程学院, 广西 柳州 545000; 2. 大连理工大学控制科学与工程学院, 辽宁 大连 116024)

摘要: 针对传统故障诊断方法不能准确定位故障位置的问题, 提出一种改进粒子群优化隐马尔科夫模型(hidden markov model, HMM)的故障诊断方法。应用 HMM 识别综合传动装置故障模式, 用模糊集定义模式研究电压信号特征提取方法, 并根据特征值的敏感程度进行优化选择; 应用 3 种 HMM 对综合传动装置在不同运行状态下的故障信号进行故障诊断, 并且对诊断结果进行对比。结果表明: 改进粒子群优化的 HMM 模型能快速有效地识别综合传动装置中磨损、损坏等故障模式, 适用性良好, 可应用于实际综合传动装置系统的故障诊断。

关键词: 隐马尔科夫模型; 综合传动装置; 电压信号; 故障诊断

中图分类号: E923.12; TP274+.5 **文献标志码:** A

A Fault Diagnosis Method Based on Improved Particle Swarm Optimization HMM

Wu Qionqiong¹, Li Yingshun², Dai Xisheng¹, Liu Shengyong¹

(1. School of Electrical & Information Engineering, Guangxi University of Science & Technology, Liuzhou 545000, China;

2. School of Control Science & Engineering, Dalian University of Technology, Dalian 116204, China)

Abstract: The traditional fault diagnosis methods can not locate the fault location accurately. Therefore, an improved particle swarm optimization hidden Markov mode (HMM) fault diagnosis method is proposed. The HMM is used to identify the fault mode of the integrated transmission device, the fuzzy set is used to define the mode to study the voltage signal feature extraction method, and the optimal selection is made according to the sensitivity of the eigenvalue; 3 HMM are applied to analyze the fault signals of the integrated transmission device under different operating conditions. And the diagnosis results are compared. The results show that the improved particle swarm optimization HMM model can quickly and effectively identify the wear, damage and other fault modes in the integrated transmission, and has good applicability, which can be applied to the fault diagnosis of the actual integrated transmission system.

Keywords: HMM; integrated transmission; voltage signal; fault diagnosis

0 引言

装甲车辆的核心组成部分为综合传动装置, 安装在装甲车辆动力舱中, 为车辆提供直驶变速、转向、制动、压气机驱动、风扇驱动等功能, 其运行的健康状态直接影响装甲车辆的任务可靠性水平^[1]。一般情况下履带车行驶的环境复杂多变, 道路路面非常恶劣, 事故突发情况多, 使得车辆在行驶的过程中, 用于传递动力的齿轮副以及支撑的输入、输出轴的轴承总是处在高速的荷载较大的情况下, 所以该部件非常容易发生故障, 却很难发现此类故障。在实际当中的很多事故表明, 车辆的综合传动装置出现故障问题, 对履带车辆的正常行驶产生很大的威胁, 极易发生事故, 造成很大的影响, 从而大大降低了工效, 可能错失战斗良机, 影响战争的局面, 甚至影响战局结果。由此可见, 研究综

合传动装置故障诊断势在必行。综合传动装置故障机理复杂, 仅仅从运行数据中难以判断其故障与否, 因此寻找一种算法既能够满足对运行数据特征提取的要求, 又能发现隐藏的故障或性能退化趋势十分必要。

隐马尔可夫模型(HMM)广泛应用到金融数据股市^[2-3]、无线信道异常检测^[4]、生物学与医学研究^[5-6]、图像压缩^[7]、故障诊断^[8]、语音识别^[9]等信号处理和模式识别^[10]领域。例如杨秀芳等^[11]研究了基于隐 Markov 模型的齿轮箱故障识别的方法, 李晓虎等^[12]阐述了齿轮箱中故障诊断的频谱的分析方法, 胡江等^[13]研究出最大熵隐马尔科夫模型的电网故障诊断, 曹亮等^[14]研究的轴承故障诊断是基于马尔科夫模型的, 许庆阳等^[15]研究一种基于 HMM 的道岔故障诊断, 江金源^[16]针对故障诊断识别的方

收稿日期: 2021-07-08; 修回日期: 2021-08-20

基金项目: 国家自然科学基金项目(No.71801196); 辽宁省兴辽英才计划(XLYC1903015)

作者简介: 吴琼琼(1995—), 女, 浙江人, 硕士, 从事武器装备的故障诊断、人工智能研究。E-mail: 1210287660@qq.com。

法，滚动轴承故障的诊断也应用隐马尔科夫模型，季云等^[17]介绍了基于 HMM 的机械设备运行状态评估与故障预测研究。以上方法都证实了 HMM 算法在故障诊断方面的成就与优势。

众多事例表明，HMM 原有的训练算法存在的问题，会在应用于多种训练时体现出来。Baum-Welch 是最陡梯度下降的局部优化的算法，缺点是选取初始值依赖性较大，非常容易陷入局部最优解，最终限制了隐马尔可夫模型对故障诊断能力的进一步提升。笔者结合 HMM 算法，提出一种基于极值扰动和自适应惯性权重的粒子群算法的综合传动装置故障诊断方法。该方法采用全局搜索策略优化模型参数来提高模型在故障诊断中的准确性，快速定位故障位置，节约了工作人员寻找本传动故障的时间，具有容错能力较强、灵活性较高及准确度较高等优点。

1 隐马尔科夫模型

HMM 的观测事件和状态并非对应，在观测概率分布体现出来，所以此模型叫做隐 Markov 模型^[18]。HMM 的统计模型具有不全面的观测数据，有非常强的序列模式的分类，一般用于动态的时间序列的模型建立，在信号分析方面出现不平稳性、难以复现性。HMM 的应用广泛，有很大的包容性、适用性，不用做目标函数，时间短、识别准确率高。

1.1 HMM 基础理论

马尔科夫链是一些事件的序列组成，其中某个事件发生情况和之前的某一个事件存在一定关系，HMM 包含的随机序列同样遵循马尔科夫链的理论，序列中的事件是概率函数相关的，并且在研究中表明其不能够被直接观察到。观测向量序列的发生必然伴随着随机状态序列。研究结果发现，概率分布中，众多相对应的概率密度序列生成观测向量，从而可以看出观测向量拥有很多的状态。

HMM 统计模型是状态随机过程并且不会被直接观察到。HMM 凭借以下的参数进行定义：

1) 模型中的状态数量 N 。假设每个独立的状态为 $\{1, 2, \dots, N\}$ ，而在时间 t 时的状态表示为

$$S_t = \{S_1, \dots, S_n\}.$$

2) 观测值数量 M 是在多种状态下能够被直接观察到的值，对这些与系统的物理输出对应的观测特征，建立模型。 $V = \{V_1, \dots, V_M\}$ 表示为一个观测特征。

3) 状态转移概率矩阵 $A = \{a_{ij}\}$ ，其中：

$$a_{ij} = P(S_{t+1}=j/S_t=i) \quad 1 \leq i, j \leq N. \quad (1)$$

式中， $S_{t+1}=j$ 的概率条件为： a_{ij} 在 $S_t=i$ 时， t 的时刻状态是 S_t ； S_{t+1} 是 $t+1$ 时刻状态。

4) 观测的概率矩阵 $B = \{b_i(k)\}$ ，其中：

$$b_i(k) = P(V_k/S_t=i) \quad 1 \leq i \leq N, 1 \leq k \leq M. \quad (2)$$

式中： $b_i(k)$ 是在 t 时刻状态 S_t 是 i 的条件下； V_k 的概率为观察特征。

5) 初始状态矩阵 $\pi = \{\pi_i\}$ ，其中：

$$\pi_i = P[S_t=i], 1 \leq i \leq N(k). \quad (3)$$

定义 N 、 M 、 A 、 B 和 π ，使参数集 $\lambda = (\pi, A, B)$ 定义 HMM。

1.2 HMM 基本训练算法

HMM 的训练算法是利用 Baum-Welch 算法， $\xi_t(i, j)$ 的定义：确定训练序列 O 和模型 λ ，在 t 时刻马尔科夫模型链在状态 q_t 时为 θ_t 、在 $t+1$ 时刻状态 q_{t+1} 时为 θ_j 的状态概率。

$$\xi_t(i, j) = P(O, q_t = \theta_i, q_{t+1} = \theta_j | \lambda). \quad (4)$$

前向变量、后向变量推算出：

$$\xi_t(i, j) = [\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)] / P(O | \lambda). \quad (5)$$

马尔科夫模型链在 t 时刻的 θ_i 状态概率：

$$\xi_t(i) = P(O, q_t = \theta_i | \lambda) = \sum_{j=1}^N \xi_t(i, j) = \alpha_t(i) \beta_t(i) P(O | \lambda). \quad (6)$$

3 个参数的重估公式为：

$$\bar{\pi} = \xi_1(i); \quad (7)$$

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \xi_t(i)}; \quad (8)$$

$$\bar{b}_j(k) = \frac{\sum_{t=1}^T \xi_t(j)}{\sum_{t=1}^T \xi_t(j)}. \quad (9)$$

式中： $\alpha_t(i)$ 是 t 时刻状态为 i 时的前向概率； $\beta_{t+1}(j)$ 是 $t+1$ 时刻状态为 j 时的后向概率；给定模型 λ ，观测序列 O 的概率为 $P(O | \lambda)$ ；状态转移概率矩阵 A 的元素为 a_{ij} ；观测概率矩阵 B 的元素是 $b_j(o_{t+1})$ ；状态 θ_i 转移期望值数量为 $\sum_{t=1}^{T-1} \xi_t(i)$ ； θ_i 状态转移至 θ_j 状态

期望值数量为 $\sum_{t=1}^{T-1} \xi_t(i, j)$ 。

训练过程为由重估公式求得一组新参数 $\bar{\pi}, \bar{a}_{ij}, \bar{b}_j(k)$ ，获得新模型 $\bar{\lambda} = (\bar{\pi}, \bar{A}, \bar{B})$ 。可证明 $P(O | \bar{\lambda}) > P(O | \lambda)$ 即重估公式所得 $\bar{\lambda}$ 能更好地表示观测值序列 O 。本过程多次重复，改变此参数，一

直满足 $P(O|\bar{\lambda})$ 收敛, 同时不增大, 这时 $\bar{\lambda}$ 为训练好的模型^[19]。

2 改进的粒子群算法

2.1 粒子群算法

粒子群算法是依靠迭代且主要是群体优化的一类算法。每个粒子拥有唯一的速度表示为 $V(t)$ 以及唯一的位置表示为 $X(t)$, 一个适应度值会伴随着粒子相应的位置产生。假如每个粒子可以看成问题的解答, 通过一个随机解进行系统初始化, 根据迭代搜寻从而得到最优值^[20]。在迭代过程中发现, 每个粒子都会追随 2 个不同的极值, 紧接着改变它的速度及位置。2 个极值中存在一个为粒子的最优解, 叫作 p_{best} ; 其余极值中的某一个可以在整个种群被找到, 称为种群的最优解, 也就是全局的最优值, 叫作 g_{best} , 表明其可以实现在空间的寻找最优解。其公式表示为:

$$V(t+1) = \omega V(t) + c_1 r_1 [p_{best}(t) - X(t)] + c_2 r_2 [g_{best}(t) - X(t)]; \quad (10)$$

$$X(t+1) = X(t) + V(t+1)。 \quad (11)$$

式中: 惯性权重是 ω ; 学习因子是 c_1 、 c_2 ; r_1 、 r_2 是 [0,1] 之间的伪随机数。

2.2 扰动

笔者提出扰动策略的算法, 使得种群是在非平衡状态, 粒子在精英学习机制的基础上而逐步扩大探测范围, 增加种群体的多样性。扰动算子如下:

$$\text{disturbance} = 0.5 * (\text{rand} - 0.5)。 \quad (12)$$

式中 rand 为 [0,1] 区间内的均匀分布。

改善粒子群算法通常利用扰动的策略, 此策略主要是在种群中对它的最优值进行持续的扰动, 扰动范围较小。在结果当中每隔十代, 来进行对比 2 个全局的最优值, 若阈值大于其差值, 则粒子群存在停滞的可能性很大, 也有可能存在局部的最优值的可能性。通过粒子群的一定的学习的机制, 当扰动全局的最优值时, 即可将整体带出局部的最优值。通过比较两代全局最优值可以看出, 减少运算量的方法为设定一定的步长, 从而提高了一定的算法的效率。表达式为:

$$g_{best}(t) = \begin{cases} g_{best}(t) + \text{disturbance}; [g_{best}(t) - g_{best}(t-10) \leq T] \\ g_{best}(t); [g_{best}(t) - g_{best}(t-10) > T] \end{cases}。 \quad (13)$$

2.3 惯性权重的设计

每一个粒子的惯性权重与运动惯性都会相互关联, 且惯性其有一定的搜索空间。惯性权重主要用于全局的探索, 小的惯性权重主要是用于局部, 从而增加收敛算法。全局搜索中, 前面通过高的搜索, 来得到合适粒子, 高的开发能力靠后期, 加快收敛速度^[21]。一般情况下递减惯性权重, 使用的方法主要是运用高斯函数来平衡算法的全局搜索能力与其收敛速度, 即:

$$\omega(t) = (\omega_{max} - \omega_{min}) \exp\left[-\frac{t^2}{(k * \text{MaxDT})^2}\right] + \omega_{min}。 \quad (14)$$

式中: 最大循环次数是 MaxDT ; 迭代次数是 t ; k 为常数, k 越小 $\omega(t)$ 将迅速减小, k 越大 $\omega(t)$ 将变化减慢。

当常数 k 确定以后, 增大迭代次数 t , 降低 $\omega(t)$ 就会使得算法的收敛速度变快。在编程过程中为了体现算法的表达性, 将精准值设定为固定值 D , 若在算法程序执行变成 $\omega - \omega_{min} > D$ 时, 按照式(14)将惯性权重进行更新, 以满足计算要求; 反之, 当 $\omega - \omega_{min} \leq D$ 时, $\omega = \omega_{min}$ 。

笔者对于原始 HMM 训练算法中的众多问题, 训练 HMM 通过选取粒子群优化算法的方法来进行。此算法可以在全局范围内进行搜索并具有快速收敛的能力, 可以将初始值的影响降低, 更好地提高模型训练算法接近函数极值的能力。

3 算例步骤

3.1 HMM 解的编码

设定状态转移矩阵为 A 、观察值输出矩阵为 B 、初始状态分布矩阵为 π , 粒子位移表达式 $X(t)=[\pi, A, B]$ 。HMM 训练算法中的各个参数是由粒子群算法最终获得的全局最优解获得的。要想满足各元素的取值范围在 [0,1] 之间以及各行元素要满足和等于 1 的条件, 就必须先分别对 π 、 A 、 B 矩阵进行归一化的处理。接下来, 计算适应度函数的最大值就可以替代 HMM 参数的训练过程。

3.2 适应度函数

在 HMM 模型的训练过程中, 适应度函数由产生观测序列 O 的概率 $P(O|\lambda)$ 来确定, 具体函数为 $f(\lambda) = P(O|\lambda)$ 。因为 HMM 模型中的概率值 $P(O|\lambda)$ 较小, 而且只展现出每次模型输出概率值的相对大小, 因此本算法中的适应度函数将选择上述函数两边取对数。

3.3 算法流程

依靠粒子群优化的 HMM 算法，如图 1 所示。

1) 给定初始化条件：确定最大速度、学习因子 c_1 、 c_2 、粒子群规模 N 、惯性权重 ω 、最大迭代次数等多个参数，同时确定 HMM 的状态数、观测值数以及观测序列；

2) 对 π 、 A 、 B 矩阵进行归一化处理，依据式 (10)、式(11)将速度与位移进行更新；

3) 按照式(14)将惯性权重进行更新，进一步将个体与全局的最优值进行更新，从而计算适应度函数；

4) 根据是否加入扰动算子，如果达到终止条件的话，那么输出适应值和最优解，不然就转向式(12)。

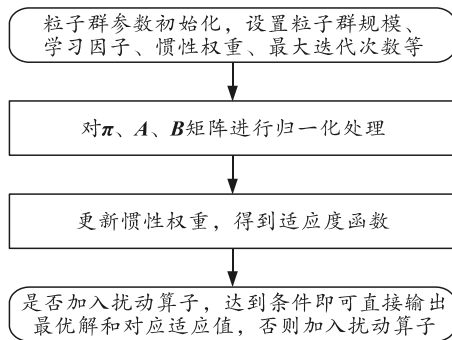


图 1 基于粒子群优化的 HMM 算法流程

HMM 对综合传动装置故障模式进行智能识别的步骤：首先在综合传动装置的电压信号中提取故障信息，作为特征提取；进而对特征参数进行优化，用作 HMM 模型的训练，可得到不同状态下 HMM 训练的模型；最后在测试电压信号中取出相对应的特征参数，将此作为输入 HMM 模型的测试数据。HMM 的综合传动装置故障诊断流程如图 2 所示。




图 2 HMM 故障诊断流程

输出概率是通过输入到已训练的 HMM 测试数据而得到的。综合传动装置状态的可能性大小，与训练数据所代表测试数据息息相关。相似概率越高，可能性越大。实际过程中通过综合传动装置采集正常、磨损、损坏等状态数据，通过数据的预处理进行实验仿真。

4 实例分析

4.1 HMM 训练过程

综合传动装置是全寿命周期过程。笔者以步战车综合传动装置的转向系统为例，研究故障诊断方法的有效性。综合传动装置采用变量柱塞泵驱动定量柱塞马达实现各档液压无级转向和空档原地中心转向。转向机构在工作状态下油压为 1.3~1.6 MPa 范围(信号输出显示为 1~6 V 电压信号)。文中选取正常、磨损、损坏 3 个阶段。根据电压信号幅值的不同，用模糊集定义的故障模式如表 1 所示。

表 1 故障模式确定表

测量电压/V	故障代码
1.0~2.0	2
2.0~2.6	1
2.6~3.2	0
3.2~3.8	1
3.8~6.0	2

注：0 为正常；1 为磨损；2 为损坏。

在正常、磨损、损坏这 3 种电压信号的状态下，训练数据将选取具有不同特征的特征参数，分别进行训练 3 种不一样的 HMM。不同状态特征参数结果不同，利用甚多的特征值作为初始训练数据，得到电压信号。

粒子群算法参数设定：粒子群个体数目 $N=150$ ，学习因子 c_1 、 c_2 都为 1.568 2， $\omega_{\min}=0.4$ ， $\omega_{\max}=0.9$ ，迭代次数最多有 200 次。首先对初始状态分布矩阵进行统一处理， $\pi=[1,0,0,0]$ ，状态转移矩阵 A 、观察值输出矩阵 B 设定为多种不同的随机值。然后通过传感器来采集上面的 3 种不同的电压信号，其中的一组数据有 2 000 个，总共收集 30 组，然后训练其中的 18 组数据，并且测试其中的 12 组数据。然后将所有的原始数据进行标准化处理，并进行量化，随后进行编码。迭代过程可由图 3 得出，即：满足收敛误差时需要迭代十几步，从而使得 HMM 逐渐趋向于稳定的状态。




图 3 3 种状态下训练数据训练迭代过程

计算敏感度需要同时利用相关的特征参数，利用聚类原理和距离测度等，选取敏感度较高的特征参数。笔者将选取标准差、方差、裕度指标、脉冲指标、峰值因子这 5 种特征值的样本，当作 HMM 训练的初始数据。

4.2 HMM 测试结果

在此测试中选取 3 种不同状态下的 12 组测试数据，然后分别代入 3 种不同的 HMM，其结果见表 2—4。

表 2 正常状态下 12 组测试数据输入 3 种 HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.6	2.1	1.2
2	2.8	2.0	1.5
3	2.9	2.4	4.0
4	2.6	3.3	4.2
5	3.0	3.6	3.9
6	3.2	2.0	4.5
7	3.0	2.3	5.0
8	3.1	3.4	1.3
9	2.6	2.1	1.9
10	2.7	3.3	5.3
11	3.2	3.7	1.2
12	3.0	2.2	1.3

表 3 磨损状态下 12 组测试数据输入 3 种 HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.5	2.0	1.5
2	2.5	2.2	1.8
3	2.4	2.2	1.9
4	2.6	3.4	3.9
5	3.0	2.0	4.2
6	3.1	3.8	4.5
7	2.8	3.0	4.3
8	2.9	3.3	3.5
9	2.6	3.5	3.9
10	2.7	3.1	4.0
11	3.2	3.7	1.2
12	3.0	3.5	1.5

表 4 损坏状态下 12 组测试数据输入 3 种 HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.6	2.3	1.5
2	2.8	3.5	3.9
3	2.9	3.4	4.0
4	2.6	2.4	1.4
5	3.0	2.3	1.8
6	3.2	3.5	3.9
7	3.1	2.1	4.5
8	3.0	2.5	4.2
9	2.7	3.3	3.9
10	2.7	3.7	4.7
11	3.2	3.3	4.2
12	3.0	3.3	4.0

通过以上 HMM 模型输出结果表明：正常测试数据被正常训练模型的识别率是 100%，磨损测试数据被磨损训练模型的识别率 75%，损坏测试数据被损坏训练模型的识别率是 100%，最终计算可以得到平均识别率为 91.6%；因此，可以得出正常信

号数据与磨损信号数据没什么区别。

4.3 GM-HMM 测试结果

同理采集训练数据 18 组、测试数据 12 组，输出结果见表 5—7。

表 5 正常状态下 12 组测试数据输入 3 种 GM-HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.6	2.2	1.4
2	2.9	2.0	1.7
3	3.0	2.4	4.2
4	2.7	3.4	4.0
5	3.0	3.7	4.6
6	3.1	2.1	4.1
7	3.0	2.3	5.5
8	2.7	3.4	1.2
9	2.7	2.1	1.8
10	2.9	3.5	5.8
11	3.0	3.6	1.0
12	3.1	2.1	1.1

表 6 磨损状态下 12 组测试数据输入 3 种 GM-HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.8	2.1	1.0
2	2.9	2.4	1.4
3	3.2	2.0	4.8
4	2.7	3.5	4.2
5	3.3	3.6	4.9
6	3.0	2.3	4.1
7	3.1	2.1	5.8
8	2.3	3.4	1.1
9	2.9	2.1	1.9
10	2.7	3.5	5.8
11	3.0	3.8	1.0
12	3.2	2.1	3.8

表 7 损坏状态下 12 组测试数据输入 3 种 GM-HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.6	1.9	1.4
2	2.7	1.8	1.7
3	3.2	2.2	4.2
4	2.6	3.4	4.0
5	2.9	3.7	3.8
6	3.1	3.4	4.8
7	3.0	5.0	5.5
8	2.5	2.3	1.2
9	2.7	2.1	1.8
10	2.9	3.5	5.8
11	2.6	1.8	1.0
12	3.6	2.1	2.0

以训练 GM-HMM 模型为基础的输出结果分别为 12/12、9/12、5/12，平均识别率为 72.2%。可看出，识别率比较低的是损坏信号训练出的模型。

4.4 改进粒子群的 HMM 测试结果 PSO-HMM

同理采集训练数据 18 组、测试数据 12 组，其输出结果见表 8—10。以训练改进粒子群的 HMM 模型为基础的输出结果分别为 12/12、11/12、12/12，平均识别率为 97.2%。在以下的输出结果中可以看出：磨损的信号训练出的模型，相对而言，具有较

表 8 正常状态下 12 组测试数据输入 3 种改进粒子群的 HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.7	2.5	1.9
2	2.6	2.4	1.7
3	3.0	2.3	1.8
4	2.7	3.3	4.0
5	3.2	3.7	4.8
6	2.9	3.5	4.3
7	3.0	3.8	5.8
8	2.6	3.5	1.9
9	2.8	3.7	1.9
10	3.0	3.3	5.9
11	3.2	3.5	1.5
12	2.8	2.2	1.6

表 9 磨损状态下 12 组测试数据输入 3 种改进粒子群的 HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.6	2.5	1.9
2	2.8	2.4	1.7
3	3.0	2.3	1.4
4	2.9	3.5	4.5
5	3.1	3.7	4.9
6	2.9	3.4	4.1
7	3.0	3.3	5.5
8	2.6	3.5	1.6
9	2.8	3.3	1.9
10	3.1	3.8	5.8
11	3.2	3.2	1.2
12	2.9	2.5	1.5

表 10 损坏状态下 12 组测试数据输入 3 种改进粒子群的 HMM 模型

数据	正常模型	磨损模型	损坏模型
1	2.6	2.3	1.8
2	2.9	2.4	1.5
3	3.2	2.1	1.9
4	2.6	3.5	4.3
5	3.0	3.6	4.5
6	2.7	3.3	4.9
7	3.0	3.7	5.5
8	2.6	3.5	1.5
9	2.7	3.7	1.8
10	3.1	3.4	5.8
11	3.2	3.8	1.4
12	2.9	2.4	1.6

如表 11 所示,用改进粒子群的 HMM 诊断综合传动装置故障模式,用不同的数据有不同的变化值。整体而言,虽然耗费时间相对较长,但是准确率比较高、适用性较好,可以忽略耗时的影响。

表 11 HMM 模型、GM-HMM 模型和改进粒子群的 PSO-HMM 模型准确度与效率的比较

模型	准确度/%	耗时
HMM 模型	91.6	相对较长
GM-HMM 模型	72.2	相对较短
改进粒子群的 HMM 模型	97.2	相对最长

5 结束语

综合传动装置中的动态故障诊断问题可以通过基于改进粒子群算法的故障诊断来解决。本文中的训练数据是通过选择灵敏度较高的特征参数来提升

效率。在实车状态时原位检测,真实地反映了实际工况,并实现了研究对象的故障诊断,表明在军事作战中可以利用人工智能进行故障诊断。

这种故障诊断方法依靠综合传动装置系统故障诊断的能力提高了部队作战能力,为准确把握装备质量提供了科学依据,为提升装备的维修效益提供有效保障。基于改进粒子群算法的故障诊断对综合传动装置进行全方位的状态监测与故障诊断,具有十分重大的军事效益和经济效益。

参考文献:

- [1] 周锐, 蒋觉义, 乔丽. 综合传动装置一体化模型评价与验证研究[J]. 计算机测量与控制, 2020, 28(4): 246-250, 270.
- [2] 黄宇方. 基于波动率的隐马尔可夫模型在金融数据上的分析与应用[D]. 杭州: 浙江工业大学, 2019.
- [3] 王绍泽. 隐马尔可夫模型在股市中的应用[D]. 大连: 大连理工大学, 2019.
- [4] 袁莉芬, 郭涛, 何怡刚, 等. 马尔可夫模型于无线信道异常检测中的应用[J]. 电子测量与仪器学报, 2019, 33(3): 29-34.
- [5] 楼向阳. 隐马尔可夫模型在生物学和医学研究中的应用[J]. 郑州大学学报(医学版), 2017, 52(3): 237-246.
- [6] SHARMA R, KUMAR S, TSUNODA T, et al. Single-stranded and double-stranded DNA-binding protein prediction using HMM profiles[J]. Analytical Biochemistry, 2021, 612.
- [7] 徐圆圆, 田雨. 隐马尔可夫树模型在图像压缩中的应用[J]. 激光杂志, 2016, 37(6): 82-85.
- [8] 程晓龙. 基于隐 Markov 模型的齿轮箱故障分类方法研究[D]. 西安: 西安理工大学, 2020.
- [9] 李婉玲, 张秋菊. 基于 HMM/SVM 的抗噪语音特征提取及优化[J]. 传感器与微系统, 2019, 38(4): 55-58.
- [10] LIU L, YANG L, DING J, et al. Transfer Learning and Identification Method of Cross-View Target Trajectory Utilizing HMM[J]. Mathematical Problems in Engineering, 2020: 1-13.
- [11] 杨秀芳, 陈卓, 王驰. 基于隐 Markov 模型的齿轮箱故障识别方法研究[J/OL]. 电子测量与仪器学报: 1-9[2020-12-28]. <https://doi.org/10.13382/j.jemi.B2003275>.
- [12] 李晓虎, 贾民平, 许飞云. 频谱分析法在齿轮箱故障诊断中的应用[D]. 南京: 东南大学, 2003.
- [13] 胡江, 赵冬梅, 张旭, 等. 基于最大熵隐马尔科夫模型的电网故障诊断方法[J]. 电网技术, 2019, 43(9): 3368-3375.