

DOI: 10.19783/j.cnki.pspc.240967

基于 RLMTS 的小样本风力发电机齿轮箱故障检测

茅婷¹, 程龙生¹, 张月义², 胡静²

(1. 南京理工大学经济管理学院, 江苏 南京 210000; 2. 中国计量大学经济与管理学院, 浙江 杭州 310000)

摘要: 针对小样本风力发电机齿轮箱给故障检测模型带来的过拟合和泛化能力差等问题, 提出了基于强化学习马田系统(reinforcement learning Mahalanobis-Taguchi system, RLMTS)的故障检测模型。首先将经过正交表和信噪比筛选后的特征作为初始马氏空间, 其次利用强化学习和给定规则对其进行探索和优化, 最后采用蚁狮优化器对传统马田系统的阈值确定方式进行改进。实验结果显示, RLMTS 适用于不同小样本量下的故障检测, 且与 17 种比较方法相比, RLMTS 诊断性能更优, 鲁棒性更强, 适用性更广, 更适用于小样本风力发电机齿轮箱的故障检测。RLMTS 有利于提高齿轮箱运行的可靠性、高效性和安全性, 同时降低维护成本, 进而保障风力发电的稳定性和高效益。

关键词: 风电机齿轮箱; 故障检测; 小样本; 马田系统; 强化学习; 蚁狮优化器

Fault detection of small-sample wind turbine gearboxes based on RLMTS

MAO Ting¹, CHENG Longsheng¹, ZHANG Yueyi², HU Jing²

(1. School of Economics and Management, Nanjing University of Science and Technology, Nanjing 210000, China;

2. School of Economics and Management, China Jiliang University, Hangzhou 310000, China)

Abstract: To address issues such as overfitting and poor generalization caused by small-sample data in wind turbine gearbox fault detection, this paper proposes a fault detection model based on the reinforcement learning Mahalanobis-Taguchi system (RLMTS). First, features filtered by orthogonal array and signal-to-noise ratio analysis are used to construct the initial Mahalanobis space. Then, reinforcement learning and predefined rules are used to explore and optimize this space. Finally, an antlion optimizer is employed to improve the threshold determination of the traditional Mahalanobis Taguchi system. Experimental results show that RLMTS is effective for fault detection in different small-sample scenarios. Compared with 17 other methods, RLMTS has better diagnostic performance, greater robustness, and broader applicability, making it particularly suitable for small-sample wind turbine gearbox fault detection. It is conducive to improving the reliability, efficiency and safety of the gearbox operation, while also reducing maintenance cost and ensuring stable and high efficiency wind power generation.

This work is supported by the National Social Science Foundation of China (No. 23BGL079).

Key words: wind turbine gearbox; fault detection; small samples; Mahalanobis Taguchi system; reinforcement learning; antlion optimizer

0 引言

齿轮箱是风力发电机的关键部分, 由于经常面临高转速、重载荷等恶劣作业环境^[1-2], 齿轮箱极易受到损坏, 轻则导致设备停止作业, 造成经济

损失, 重则引发安全事故, 导致人员伤亡, 产生恶劣的社会影响^[3]。对风力发电机齿轮箱进行运行状态监测和故障检测是保证设备长期安全运行的有效手段, 不仅能提高动力传输系统的可靠性、安全性和效率^[4], 还能保持设备稳定运行, 避免安全事故的发生, 符合“视情维修”的要求^[5]。

在一些较为特殊的工作环境下, 风力发电机齿轮箱的故障检测并不那么容易。由于数据采集的难度和成本较大, 收集到的可供处理和分析的数据有

基金项目: 国家社会科学基金项目资助(23BGL079); 国家自然科学基金管理委员会项目资助(202406840086); 江苏省研究生科研与实践创新计划项目资助(KYCX23-0532)

限(即面临着小样本问题),给故障检测带来了巨大挑战。小样本问题是指样本数量有限,难以从中获取足够的有效信息^[6],它使得故障检测模型容易出现过拟合、方差大且泛化能力差等问题^[7],严重制约了故障检测模型的诊断性能^[8]。

当前相关研究主要可以分为改进检测模型和利用迁移技术两类。在前者的研究中,文献[9]结合弱分类器、K近邻、马氏距离(Mahalanobis distance, MD)和卷积神经网络(convolutional neural networks, CNN)对生成对抗网络(generative adversarial networks, GAN)进行改进,提升其诊断性能。文献[10]利用深度可分离卷积块构建轻量级多尺度架构来优化CNN结构,实现故障检测。文献[11]利用简化图小波神经网络和可学习的加权集成策略对特征进行提取和融合,进而实现故障检测。文献[12]利用时间同步平均技术对振动信号滤波的局部最小值进行插值,构建故障指数,实现对风力发电机组齿轮箱的故障检测。文献[13]结合短时傅里叶变换、核密度估计和 Kullback-Leibler 散度提出故障影响信号能量比,对齿轮箱进行故障检测。在后者的研究中,文献[14]在源域上利用多尺度 CNN 提取特征,并利用膨胀卷积和随机池化对特征进行融合,通过元学习对源域和目标域之间的样本进行评估,最终实现故障检测。文献[15]在源域上利用隔离森林对样本进行标记和分类,使用标记后的数据训练深度学习模型,最后将模型迁移至目标域,通过微调参数实现对小样本齿轮箱的故障检测。文献[16]构建了迁移诊断子任务,通过联合分布、自适应正则化等方法分析数据分布,通过元随机梯度下降方法优化模型参数,最终实现对齿轮箱的故障检测。但这两类检测模型的构建往往都较为复杂,需要耗费大量时间和成本。

在众多故障检测模型中,马田系统(Mahalanobis-Taguchi system, MTS)由于具有对数据分布无任何要求、考虑特征之间相关性和计算简单等优势^[17-18]而受到广泛关注。但 MTS 也存在一定的改进空间,例如在特征选择过程中,通过正交表和信噪比增益构建的马氏空间并不一定总是最优解^[18];在阈值确定过程中,质量损失函数的参数并不容易获取,且往往具有一定的主观性^[20]。

因此,针对常见故障检测模型复杂度高、计算量大以及 MTS 存在改进的空间等问题,本文构建了基于强化学习马田系统(reinforcement learning Mahalanobis-Taguchi system, RLMTS)的风力发电机齿轮箱故障检测模型。在构建有效马氏空间阶段,将正交表和信噪比增益获得的特征子集作为初始马

氏空间,利用强化学习(reinforcement learning, RL)技术,通过智能体与环境(样本的特征组合)的交互,结合 ϵ 贪心算法和给定的行动规则,制定最佳行动策略(特征选择情况),构建有效马氏空间。在阈值确定阶段,引入蚁狮优化器(ant lion optimizer, ALO)来探索最佳阈值,对故障样本进行识别。

本文创新点如下:1)针对风力发电机齿轮箱故障检测中的小样本问题,提出了 RLMTS 故障检测模型。该模型适用于不同小样本数量下的故障检测,降低了训练样本数量不足给模型带来的弱诊断能力的影响,有效提高了模型的诊断性能。2)与基于改进检测模型的小样本故障检测方法(如 GAN 等)相比,RLMTS 的模型复杂度低,无须探索网络结构,所需参数较少,极大地降低了计算代价。与基于迁移技术的小样本故障检测方法相比,RLMTS 不仅减少了计算量,而且节省了大量模型运行时间,提高了检测效率。3)创新性地将 RL 融入 MTS 以提高 MTS 的特征提取能力,将 ALO 引入 MTS 以优化 MTS 的阈值确定方法,极大拓宽了 MTS 的应用领域和范围。4)RLMTS 适用于不同小样本数量下的故障检测问题,适用场景多,应用范围广,潜在价值大,能实现对设备的自动化故障检测,节省了时间成本,有利于提高故障检测效率,降低生产成本,保障生产安全性和可靠性。

1 MTS 和 RL 理论

1.1 MTS

MTS 由日本质量学家田口玄一博士提出^[21],其核心内容包括 MD、正交表和信噪比,其中 MD 消除了量纲的影响,可以有效衡量样本之间的距离;正交表和信噪比增益可以减少试验次数,提高效率,构建马氏空间。

$$C^{-1} = \frac{1}{|M|} M^* \quad (1)$$

式中: M 为相关矩阵; M^* 为伴随矩阵; C^{-1} 为相关矩阵的逆矩阵。

$$D_i = Z_i C^{-1} (Z_i)^T \quad (2)$$

式中: D_i 为第 i 个样本的 MD; Z_i 为标准化后的第 i 个样本的特征空间。

利用正交表 $L_B(2^m)$ 安排特征组合,其中 B 为试验次数,2 为因素的水平(使用该特征和不使用该特征两种水平), m 为特征数量。根据正交表的安排计算信噪比 E 和信噪比增益 E_{gain} 。

$$E = -10 \lg \left(\frac{1}{n_y} \sum_{i=1}^{n_y} \frac{1}{D_i^2} \right) \quad (3)$$

式中: n_y 为异常样本的数量。

$$E_{\text{gain}} = E_1 - E_2 \quad (4)$$

式中: E_1 为使用某特征变量的信噪比; E_2 为不使用某特征变量的信噪比。

若 E_{gain} 大于零, 则代表该特征对于标签而言是重要的, 需要进行保留; 否则认为是无用特征, 需要删除。

在完成特征选择之后, 计算正常样本的 MD 和异常样本的 MD, 若异常样本的 MD 大于正常样本的 MD, 则马氏空间的构建有效。

依据质量损失函数计算阈值, 依据待测样本的 MD 和计算得到的阈值实现样本分类, 若待测样本的 MD 大于阈值, 则将其划分为异常样本, 否则将其划分为正常样本。

1.2 RL

RL 最早出现于 20 世纪 60 年代, 文献[22]提出的 RL 影响最大, 文献[23]于 1989 年提出了 Q-learning 模型, DeepMind 研究机构于 2013 年和 2015 年分别提出和改进了 Deep Q Network 模型, RL 的发展进入了新的阶段。

RL 的基本主体包括智能体和环境, 主要元素包括状态、行动和奖励。在 t 时刻, 智能体从环境中获得状态 s_t , 并依据状态给出自己的行动 a_t , 行动与环境交互产生影响获得奖励 r_t , 智能体接着从环境中获取 $t+1$ 时刻的状态 s_{t+1} , 获取奖励 r_{t+1} , 不断循环, RL 基本框架详见图 1。

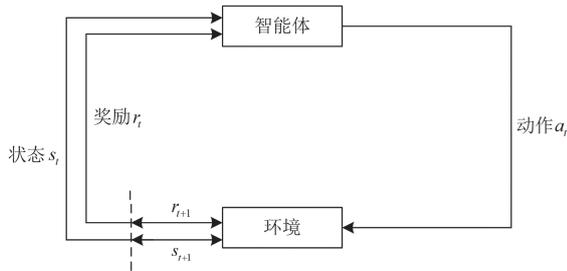


图 1 RL 基本框架

Fig. 1 Basic framework of RL

2 基于 RLMTS 的小样本风力发电机齿轮箱故障检测模型

RLMTS 利用 RL 和给定的规则对马氏空间的构建进行了优化, 利用 ALO 算法对阈值的确定方式进行了优化。RL 策略充分保证了构建的马氏空间具有足够的开发能力和探索能力; 给定的两条规则有效避免了智能体过度探索, 将其探索幅度进行了一定限制, RL 和给定的规则有利于提高马氏空间

的合理性和科学性, 为后续故障检测奠定了坚实的基础。ALO 算法替代传统使用质量损失函数确定阈值的方式, 不仅降低了质量损失函数确定时参数的主观性和不易获取性, 还以元启发式方法在较短时间内找到足够优异的阈值, 能够有效识别故障样本, 提高了故障检测的效率。

2.1 数据预处理

将若干个数据点作为一个信号段, 对收集到的振动信号进行分帧预处理。由于振动信号中可能存在杂波干扰, 故去除其直流分量后, 再使用低通滤波器和高通滤波器去除低频和高频分量, 最后提取其时域、频域和时频域特征。时域特征包括最大值、最小值、平均值、峰-峰值、整流平均值、方差、标准差、均方根 8 个有量纲特征和峭度、偏度、波形因子、峰值因子、脉冲因子、裕度因子 6 个无量纲特征; 频域特征包含平均频率、重心频率、均方频率、频率均方根、频率方差和频率标准差; 时频域特征从功率谱中进行信息提取, 包含功率最大值、功率最小值、功率中位数、功率平均值、信噪比和占用带宽。

采用五折交叉验证对数据进行处理, 经数据预处理后得到矩阵 $X_{n \times m}$, 其中 n 为样本数量。

2.2 初始马氏空间构建

设 X_{ij} 代表第 i 个样本的第 j 个特征, $i=1, 2, \dots, n$, $j=1, 2, \dots, m$, 对 X_{ij} 进行标准化处理得到 Z_{ij} 。引入合适的正交表对特征组合进行安排, 计算信噪比增益。选取信噪比增益大于零的特征, 重新计算正常样本和异常样本的 MD, 若正常样本的 MD 小于异常样本的 MD, 则将此时的特征组合作为初始的马氏空间 H_0 , H_0 同时作为智能体行动的初始状态 a_0 , 即 $a_0 = H_0$ 。

2.3 马氏空间优化和阈值计算

为提高检测模型的诊断能力, 利用 RL 实现开发和探索之间的均衡, 有效选择重要特征; 利用 ALO^[24]搜索不同类别样本之间的最佳阈值, 在减少计算时间的同时提高诊断准确率。在该过程中, 将特征选择和阈值计算进行封装处理。

1) 参数初始化

依据实际情况对参数进行设置, 设 ε 贪心策略中的阈值为 ε ; 第 j 个特征的 ALO 搜索空间上限和下限分别为 u_j 和 l_j ; 最大迭代次数为 T ; 蚂蚁和蚁狮的数量均为 N ; 蚂蚁和蚁狮的位置分别为 p 和 P , 第 k 只蚂蚁和蚁狮的初始位置分别为 p_0^k 和 P_0^k 。计算表达式如式(5)所示。

$$\begin{cases} p_0^k = r_1 \times (u_j - l_j) + l_j \\ P_0^k = r_2 \times (u_j - l_j) + l_j \end{cases} \quad (5)$$

式中: $k=1,2,\dots,N$; r_1 和 r_2 为 $N \times 1$ 的随机数组。

2) 马氏空间和阈值封装

此时智能体每次采取的行动由(6)决定,即智能体执行贪心策略,每次选择行动都使得在现有经验下,后续的收益达到最大。

$$a^*(s_t) = \arg \max_{a_t \in A} r_t^*(s_t, a_t) \quad (6)$$

式中: $a^*(s_t)$ 为给定 s_t 下的最优行动; t 为迭代次数, $t=1,2,\dots,T$; A 为所有 a_t 的集合; r_t^* 为最优的 r_t 。值得注意的是, r_t 与 t 时刻的适应度函数 F_t 成反比。

为权衡开发和探索之间的关系,引入 ε 贪心策略。智能体每次以 ε 的概率执行随机行动,以 $1-\varepsilon$ 的概率执行贪心策略。

除了 ε 贪心策略,另给定两条行动规则:(1)在 $t+1$ 时刻,若 a_{t+1} 与 a_t 相比只有一个特征的选择不同,当 $r_{t+1} > r_t$ (或 $F_{t+1} < F_t$)时,在之后的行动变化中,该特征始终保持 a_{t+1} 中的选择情况;当 $r_{t+1} < r_t$ (或 $F_{t+1} > F_t$)时,在之后的行动变化中,该特征始终保持 a_t 中的选择情况;当 $r_{t+1} = r_t$ (或 $F_{t+1} = F_t$)时,在之后的行动变化中,该特征被丢弃。(2)在 $t+1$ 时刻,若 a_{t+1} 与 a_t 相比有多个特征的选择不同,当 $r_{t+1} > r_t$ (或 $F_{t+1} < F_t$)时,在之后的行动变化中,任意固定两个选择情况不同的特征,这两个特征始终保持 a_{t+1} 中的选择情况;当 $r_{t+1} < r_t$ (或 $F_{t+1} > F_t$)时,在之后的行动变化中,任意固定两个选择情况不同的特征,这两个特征始终保持 a_t 中的选择情况;当 $r_{t+1} = r_t$ (或 $F_{t+1} = F_t$)时,在之后的行动变化中,任意固定两个选择情况不同的特征,这两个特征的选择情况依据“在其他条件相同时,特征数量越少越好”的原则进行确定。

智能体依据 ε 贪心策略和给定的两条行动规则,在 s_t 下给出 a_t 。在确定 a_t 后,对马氏空间进行更新,得到 t 时刻的马氏空间 H_t ,重新计算此时正常样本和异常样本的MD,若异常样本的MD大于正常样本的MD,则 H_t 构建有效。之后利用ALO计算阈值,获得当前奖励,最终依据适应度函数最小化(即误判率最小化)或奖励最大化求得最佳阈值。

ALO中包含蚂蚁和蚁狮两个对象,两者服从以下假定: N 只蚂蚁在所有维度上使用不同的随机游走;蚂蚁的随机游走受到蚁狮所设陷阱的影响;随机游走会自适应减小;蚁狮可以建造与其适应度函数成比例的陷阱;陷阱越大则蚁狮抓到蚂蚁的概率

越大;每只蚂蚁都可以在每次迭代中被最厉害的蚁狮捕获;蚁狮会根据最近捕获的蚂蚁重新定位和构造陷阱以提高捕获另一只蚂蚁的概率;若蚂蚁比蚁狮的适应度更好,则意味着它已被蚁狮捕获并拉入陷阱。

每次迭代时,都对蚂蚁的随机游走进行归一化处理。由于蚂蚁的随机游走受到陷阱的影响,其行走轨迹始终在一个超球体上。

$$\begin{cases} l_t^k = P_t^k + l_t \\ u_t^k = P_t^k + u_t \end{cases} \quad (7)$$

式中: l_t^k 为 t 时刻第 k 只蚂蚁的搜索下限; u_t^k 为 t 时刻第 k 只蚂蚁的搜索上限; P_t^k 为 t 时刻第 k 只蚁狮的位置; l_t 为 t 时刻的搜索下限; u_t 为 t 时刻的搜索上限。

由于只有最厉害的蚁狮才能捕获蚂蚁,它能够影响所有蚂蚁的游走过程。

$$p_t^k = \frac{U_t^1 + U_t^2}{2} \quad (8)$$

式中: p_t^k 为 t 时刻第 k 只蚂蚁的位置; U_t^1 为第 t 次迭代时最厉害的蚂蚁的随机游走; U_t^2 为第 t 次迭代时转盘选择的蚁狮的随机游走。

蚂蚁和蚁狮的位置更新公式分别为

$$\begin{cases} p_t^k = \frac{(p_t^k - p_{t-1}^k) \times (u_t^k - l_t^k)}{u_t^k - p_{t-1}^k} + l_t^k \\ P_t^k = \frac{(P_t^k - P_{t-1}^k) \times (u_t^k - l_t^k)}{u_t^k - P_{t-1}^k} + l_t^k \end{cases} \quad (9)$$

当蚁狮建造好与其适应度函数成比例的陷阱后,一旦察觉到蚂蚁进入陷阱后便开始以陷阱为中心向外扔沙子。

$$\begin{cases} l_t = l_t / I \\ u_t = u_t / I \end{cases} \quad (10)$$

式中: I 为比率, $I = 10^w \frac{t}{T}$, w 为基于 t 的常数。

当 $0 < \frac{t}{T} \leq 0.1$ 时, $w=1$; 当 $0.1 < \frac{t}{T} \leq 0.5$ 时,

$w=2$; 当 $0.5 < \frac{t}{T} \leq 0.75$ 时, $w=3$; 当 $0.75 <$

$\frac{t}{T} \leq 0.9$ 时, $w=4$; 当 $0.9 < \frac{t}{T} \leq 0.95$ 时, $w=5$;

当 $0.95 < \frac{t}{T} < 1$ 时, $w=6$ 。

当蚁狮捕捉到蚂蚁并将其吃掉时,意味着蚂蚁的适应度函数 F_t^1 小于蚁狮的适应度函数 F_t^2 ,此时 $p_t^k = P_t^k$ 。

$$\begin{cases} F_t^1 = f_1 \times G_1 + f_2 \times G_2 \\ F_t^2 = f_1 \times G_1 + f_2 \times G_2 \end{cases} \quad (11)$$

式中: f_1 为第一类误分代价; f_2 为第二类误分代价; G_1 为正常样本 MD 大于阈值的数量; G_2 为异常样本 MD 小于阈值的数量。

此时该问题的决策变量为不同类样本之间的阈值 P_t , 希望 P_t 能够最大程度划分不同类样本的 MD; 优化目标为适应度函数最小化, 即 $\min F_t = f_1 \times G_1 + f_2 \times G_2$ 。

每次迭代都对蚂蚁和蚁狮的位置进行更新, 使用适应度函数重新进行评估, 保存最厉害的蚁狮的位置并更新, 最终获得最佳阈值 P_{best} , 直至目标函数不再变化或迭代次数达到设置的最大次数时, 迭代停止。马氏空间的优化和阈值寻优过程见图 2。

算法 1: 马氏空间优化和阈值计算

Initialize ε, u, l, N, F

Confirm a_0

Confirm the initial Mahalanobis space (H_0)

Calculate the MDs of samples

Verify the validity of the Mahalanobis space

Calculate p_0, P_0, F_0^1, F_0^2

For $t = 1:T$

 Calculate Q value

a_t is confirm by ε greedy algorithm and other two rules

 Update the Mahalanobis space (H_t)

 Verify the validity of the H_t

 Interact with the s_t to get r_t

 Update Q value

For N ants:

 Select an antlion using Roulette wheel

 Update u and l

 Calculate the random walk around the antlion and normalize the data

 Calculate the random walk around the best antlion

 Calculate the position and fitness of ants

 Save and update the position with best fitness value

 End for

For antlions: update antlion positions and fitnesses based of the ants

 Calculate the P and F^2 of antlions

 If $F^1 < F^2$

 Save the P_t and F^2

 End for

 Update the a_t and P_t according to the F

 Save the best a_t and P_t

End for

2.4 故障诊断

设 D_z 为待测样本的 MD, 若 $D_z > P_{\text{best}}$, 则将其判为故障样本, 否则将其判断为正常样本。

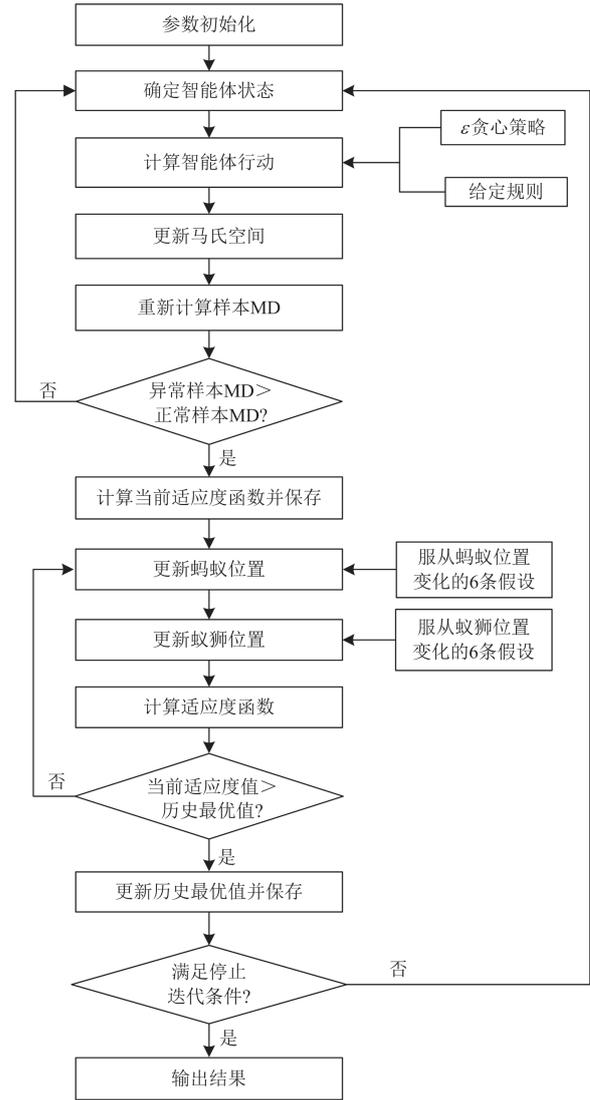


图 2 马氏空间优化和阈值寻优过程

Fig. 2 Mahalanobis space optimization and threshold optimization process

3 实验验证

3.1 数据集描述

本文使用的数据来自美国国家可再生能源实验室^[25], 将 1024 个数据点作为一个信号段, 对收集到的振动信号进行分帧预处理, 经去直流分量、低频分量和高频分量处理后, 提取时域、频域和时频域特征, 每个信号段上提取的特征向量作为一个样本。最终数据情况见表 1。

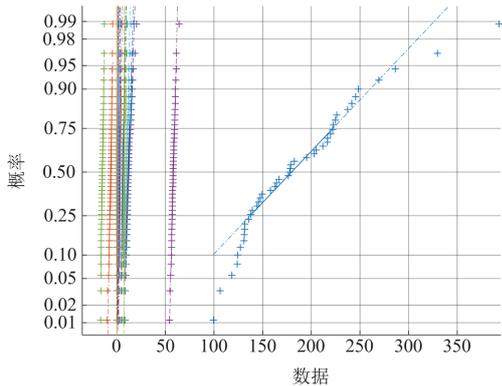
为验证 RLMTS 模型的有效性, 对 5 个数据集分别进行五折交叉验证。虽然健康样本数量与故障样本数量并不完全相等, 但由于差值不大, 故不再对其进行不平衡数据的处理。

图 3 展示了 Dataset A 的数据分布情况。

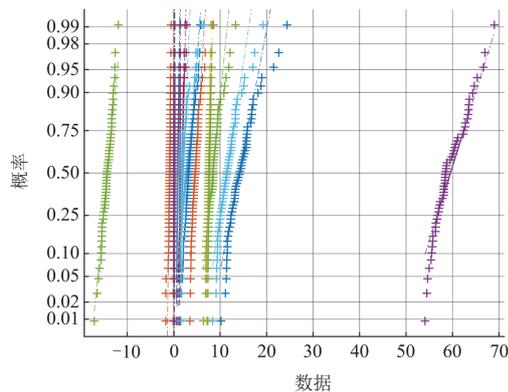
表 1 数据描述

Table 1 Data description

数据集名称	总健康样本数量	总故障样本数量
Dataset A	45	54
Dataset B	43	43
Dataset C	53	55
Dataset D	51	43
Dataset E	54	46



(a) 正常样本



(b) 故障样本

图 3 Dataset A 的数据分布情况

Fig. 3 Distribution of data in Dataset A

3.2 评价指标

为评价算法的分类性能，将精确度、特异度、召回率、准确率、F1 和 G-mean 作为评价指标。

3.3 比较方法

在小样本数据的处理中，合成少数类过采样技术(synthetic minority oversampling technique, SMOTE)和 GAN 是较为常见的处理方式；支持向量机(support vector machine, SVM)、随机森林(random forest, RF)、逻辑斯蒂回归(logistic regression, LR)、CNN 和循环神经网络(recurrent neural network, RNN)是较为常见的故障检测模型；卷积自编码器(convolutional auto-

encode, CAE)^[26]和基于细粒度多尺度符号熵和鲸鱼优化的多类支持向量机(fined-grained multi-scale symbolic entropy and whale optimization algorithm-multiclass support vector machine, FGMSE-WOA-MSVM)^[27]是新的故障检测模型，故将 SVM、RF、LR、CNN、RNN、SMOTE-SVM、SMOTE-RF、SMOTE-LR、SMOTE-CNN、SMOTE-RNN、GAN-SVM、GAN-RF、GAN-LR、GAN-CNN、GAN-RNN、CAE 和 FGMSE-WOA-MSVM 作为比较方法。

各比较方法的超参数确定情况如下。

1) SVM 相关比较方法

通过 Matlab 软件使用贝叶斯优化 SVM，优化的超参数包括 KernelScale 和 BoxConstraint，KernelScale 是尝试按原始内核比例缩放的径向基函数西格玛参数的几何序列，BoxConstraint 是正则化参数，它控制了模型对于训练样本的拟合程度。图 4 展示了 Dataset A 在五折交叉验证的第一次实验时 SVM 超参数的优化过程。

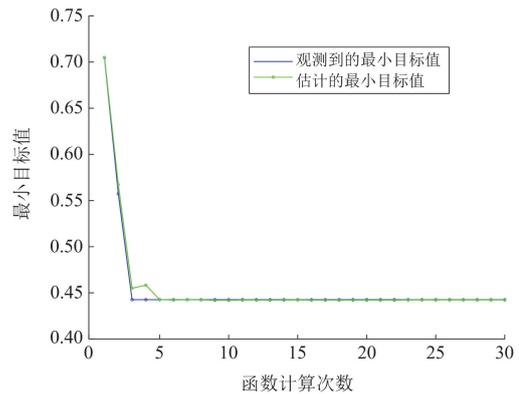


图 4 SVM 优化过程

Fig. 4 SVM optimization process

2) RF 相关比较方法

在与 RF 相关的比较方法中，树的数量是重要参数之一，考虑到样本数量较少，故将步长设置为 20，将树数量的探索范围设置为 20~120，结果显示在训练集上其准确率均为 1.00。通常而言，需要用足够多的树确保弱分类器的稳定性，但考虑到小样本问题，为防止过拟合，最终选择中位数 80 作为最终树的数量。

树的最大深度也是重要参数之一，以步长为 2 在 2~12 之间进行探索，以训练集上准确率最高为原则，结果如图 5 所示，故选取树的最大深度为 6。

拆分内部节点所需的最少样本数也是重要参数之一，以步长为 2 在 2~12 之间进行探索，以训练集上准确率最高为原则，结果如图 6 所示，最终将

拆分内部节点所需的最少样本数选取为 2。

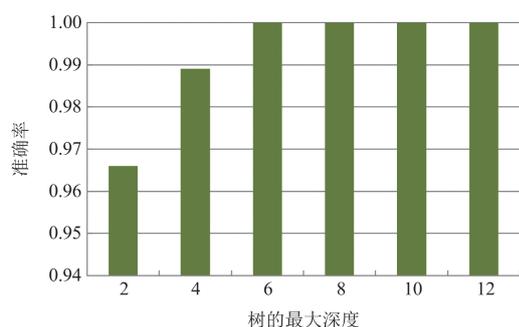


图 5 不同树最大深度下的检测准确率

Fig. 5 Detection accuracy with tree under different max depths

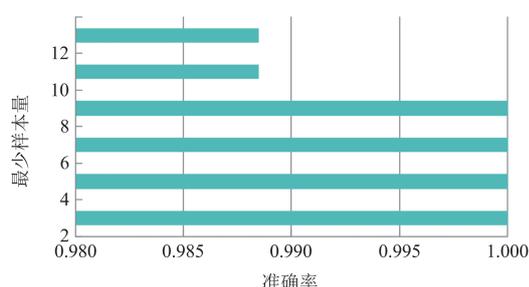


图 6 不同拆分内部节点所需最少样本数下故障检测准确率

Fig. 6 Fault detection accuracy with the minimum number of samples required for different internal nodes

3) CNN 相关比较方法

(1) 在 CNN 结构方面, 参照 2012 年 Imagenet 比赛冠军模型 Alexnet 结构设置, 由于原模型结构复杂且适用于大数据情形下的数据分类问题, 考虑到本文研究数据的规模较小, 为降低模型复杂度、提高计算速度, 同时为确保结构具有科学性和合理性, 选择 Alexnet 部分结构作为本文 CNN 结构。

(2) 在 CNN 的超参数方面, 考虑到特征数量不多, 同时为降低计算代价, 对每一层的主要超参数如卷积层和池化层的核大小(2 和 3)、Dropout 层的丢弃概率(0.1, 0.2 和 0.3)等进行了确定, 结果如表 2 所示。

最终 CNN 结构为卷积层(核大小为 2)、Relu 层、最大池化层(核大小为 2)、Flatten 层、Relu 层、dropout 层(概率为 0.2)和输出层。

4) RNN 相关比较方法

RNN 的隐藏层个数以步长为 5 在 5~30 之间进行搜索, 以训练集准确率高为评判原则, 结果如图 7 所示, 最终 RNN 的隐藏层个数取 5。

5) SMOTE 相关比较方法

在使用 SMOTE 和 GAN 生成伪样本的过程中, 提出以生成样本与真实样本之间的均值差之和为

表 2 不同参数下 CNN 的分类性能

Table 2 Classification performance of CNN with different parameters

卷积层核大小	池化层核大小	Dropout 层 丢弃概率	训练集准确率
2	2	0.1	0.51
		0.2	0.64
		0.3	0.52
	3	0.1	0.64
		0.2	0.54
		0.3	0.51
3	2	0.1	0.49
		0.2	0.46
		0.3	0.51
	3	0.1	0.62
		0.2	0.56
		0.3	0.43

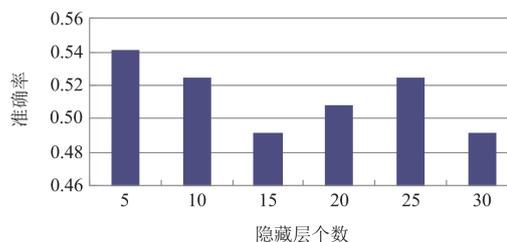


图 7 不同隐藏层数量下 RNN 分类性能

Fig. 7 Classification performance of RNN with different numbers of hidden layers

评判准则, 如式(12)所示。

$$d = \sum_{j=1}^m |(\bar{x}_j - \bar{x}'_j)| \quad (12)$$

式中: d 为生成样本与真实样本之间均值差之和; \bar{x}_j 为真实样本第 j 个特征的均值; \bar{x}'_j 为生成样本第 j 个特征的均值。

选择该准则的原因如下: (1) 生成的伪样本质量越高, 说明越接近原样本, 两者之间的数据特征(如均值)就越相近; 当伪样本在各个特征维度上与原样本的均值越接近, 两者之间的均值差之和越小, 伪样本的生成质量就越高, 越有利于提高后期故障检测模型的诊断能力。(2) SMOTE 和 GAN 大多从空间角度和函数拟合角度出发生成伪样本, 但由于本文的样本量较少, 从空间角度分析生成样本质量时样本点可能存在较大重合, 而且由于数据不符合正态分布, 从函数拟合角度考量样本生成质量较为困难, 使用生成样本与真实样本之间均值差之和作为评判指标, 不仅简单, 且可操作性和可实现性更强。

在 SMOTE 相关的比较方法中, 其重要超参数为 V , V 代表先随机选取某个少数类样本, 再从其 V 个邻近中选择样本来构建新的样本。由于本文为小样本数据, 故以步长为 1 在 3~8 之间进行搜索, 依据均值差之和最小化的原则, 最终确定 $V=5$, 详见图 8。

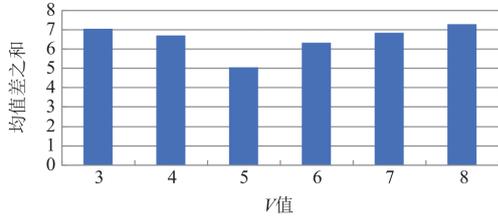


图 8 不同 V 值下的均值差之和

Fig. 8 Sum of mean differences at different V values

6) GAN 相关比较方法

第一, 在结构方面, GAN 网络结构使用最常见的结构, 生成器包括 Linear 层、Relu 层和 Linear 层; 鉴别器包括 Linear 层、Relu 层、Linear 层和输出层(Sigmoid 函数)。

第二, 在超参数方面, 隐空间的维数对使用生成器生成的伪样本有着重要影响, 能直接影响模型的故障检测性能, 故以 10 为步长, 在 10~50 内进行探索, 以生成样本与真实样本之间均值差为评判标准, 结果如图 9 所示, 最终确定隐空间维数为 20。

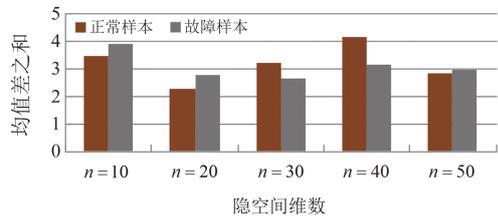


图 9 不同隐藏层维数下 GAN 真伪样本均值差

Fig. 9 Difference between the mean values of GAN true and false samples with different hidden layer dimensions

7) CAE

对卷积层核大小(2 和 3)、池化层核大小(2 和 3)和学习率(0.001~0.01)进行探索, 其中学习率的探索步长为 0.005, 发现其准确率结果均为 0.44。最终的 CAE 网络结构与参数见表 3。

8) FGMSE-WOA-MSVM

对超参数 KernelScale 和 BoxConstraint 进行优化, 每次优化后, 计算当前观测到的最小目标值和估计的最小目标值, 优化过程的最小目标值如图 10 所示, 最终观测到的最佳可行点为 BoxConstraint = 3.492, KernelScale = 315.990。

3.4 消融实验

为验证 RL 模块和 ALO 模块对所提模型故障诊

表 3 CAE 网络结构与参数

Table 3 CAE network structure and parameters

网络名称	网络结构
编码器	Conv (1,27,2)
	Relu
	MaxPool (2)
	Conv (27,2,2)
	Relu
解码器	MaxPool (2)
	ConvTranspose(2,27,2)
	Relu
	ConvTranspose(27,2,3)
	Relu
	ConvTranspose(2,1,2)
	Linear

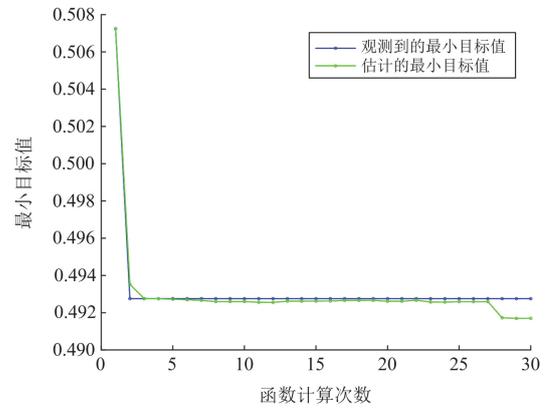


图 10 FGMSE-WOA-MSVM 参数优化过程

Fig. 10 FGMSE-WOA-MSVM parameter optimization process

断性能的影响, 分别去除 RL 模块和 ALO 模块进行消融实验, 分别命名为 MTS1 和 MTS2。5 个数据集五折交叉验证取均值后的比较结果见表 4。

表 4 消融实验结果

Table 4 Results of ablation experiments

方法	精确度	召回率	特异度	准确率	F1	G-mean
RLMTS	0.94	0.90	0.94	0.92	0.92	0.92
MTS1	0.97	0.68	0.98	0.82	0.77	0.80
MTS2	0.59	0.85	0.42	0.64	0.69	0.57

由表 4 可知: RLMTS 模型的各项指标值较为均衡, 且维持较高水平。RL 模块对于模型的召回率、准确率、F1 和 G-mean 指标有明显的提升作用, 同时 RL 模块使得模型对于不同类样本的判别能力更加均衡, 减少明显倾向性输出某个类别的情况发生。ALO 模块对于提高模型各类指标都有着显著作用。

3.5 不同小样本量下 RLMTS 诊断性能

为检验 RLMTS 模型在不同小样本数量下的诊断性能, 对 Dataset A 中的样本分别取 20%、40%、

60%和 80%构建数据集 Dataset A-1、Dataset A-2、Dataset A-3 和 Dataset A-4 进行实验, 对应的总样本量分别为 20、40、60 和 80, 再选取其中的 80%作为训练集, 20%作为验证集, 此时对应的训练样本数分别为 16、32、48 和 64, 故障检测结果如表 5 所示。

表 5 不同小样本量下 RLMTS 诊断性能

Table 5 Diagnostic performance of RLMTS with different small sample sizes

数据集	精确度	召回率	特异度	准确率	F1	G-mean
Dataset A-1	1.00	0.50	1.00	0.75	0.67	0.71
Dataset A-2	1.00	1.00	1.00	1.00	1.00	1.00
Dataset A-3	1.00	1.00	1.00	1.00	1.00	1.00
Dataset A-4	1.00	1.00	1.00	1.00	1.00	1.00

由表 5 可知: 在 Dataset A-2、Dataset A-3 和 Dataset A-4 上的 RLMTS 所有指标值均为 1.00, 在 Dataset A-1 上, 由于训练样本只有 16 个, 最终在验证集上误判了 1 个正常样本, 总体而言 RLMTS 对于不同数量的小样本均具有良好的诊断性能。

3.6 对比实验

3.6.1 Dataset A 实验过程和对比结果

使用所有特征计算正常样本和异常样本的 MD, 五折交叉验证计算得到的正常样本的均值分别为 0.86、0.86、0.86、0.86 和 0.86, 其对应的标准差分别为 0.27、0.27、0.20、0.22 和 0.22, 异常样本的均值分别为 207.02、207.18、291.40、65.82 和 325.77, 其对应的标准差分别为 179.71、234.91、355.44、83.45 和 487.68。

依据正交表和信噪比计算信噪比增益, 结果见图 11。保留信噪比增益大于零的特征, 剔除信噪比增益小于零的 4 个特征。使用经正交表和信噪比筛选后的 23 个特征构建初始马氏空间。

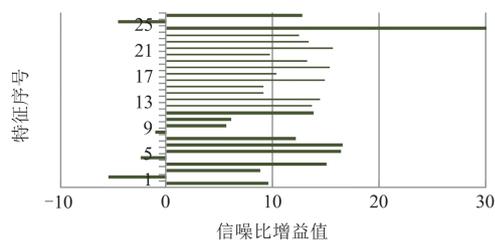


图 11 信噪比增益

Fig. 11 Signal-to-noise gain

图 12 为初始马氏空间下正常样本和异常样本的 MD, 其中 ξ 表示交叉验证的次数。

利用 RL 并结合两条给定规则对马氏空间的构建进行探索, 图 13 为五折交叉验证下智能体给出的

行动。其中蓝色代表选择该特征, 白色代表不选择该特征。

最终分别得到 12、7、9、14 和 13 个特征构建马氏空间, 计算正常样本和异常样本的 MD, 五折交叉验证计算得到的正常样本的均值分别为 0.97、0.97、0.97、0.90 和 0.97, 其对应的标准差分别为 0.60、0.88、0.65、0.54 和 0.52, 异常样本的均值分

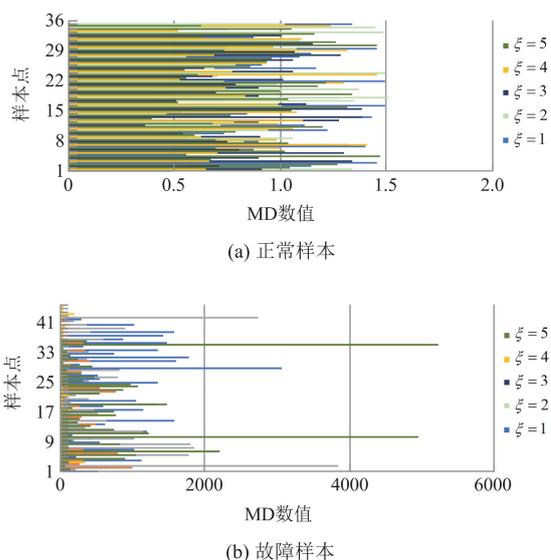
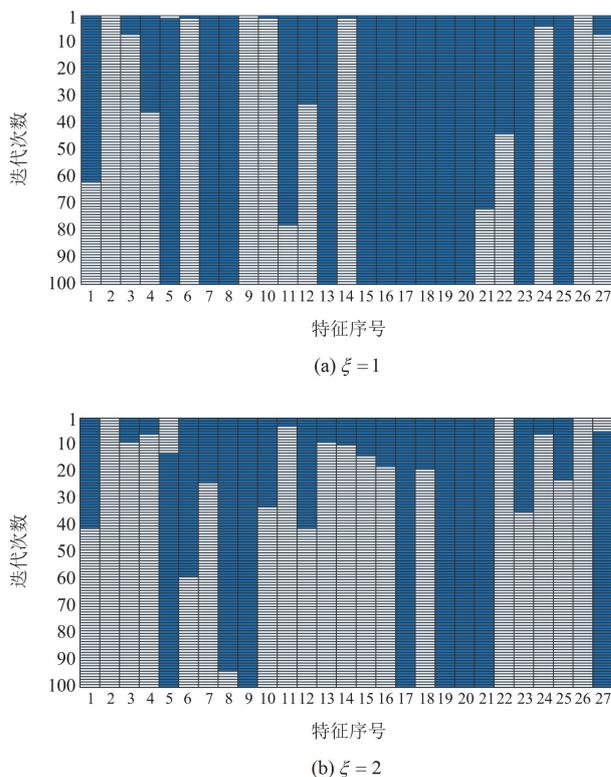


图 12 初始马氏空间下样本的 MD

Fig. 12 MDs of samples in initial Mahalanobis space

(a) $\xi = 1$ (b) $\xi = 2$

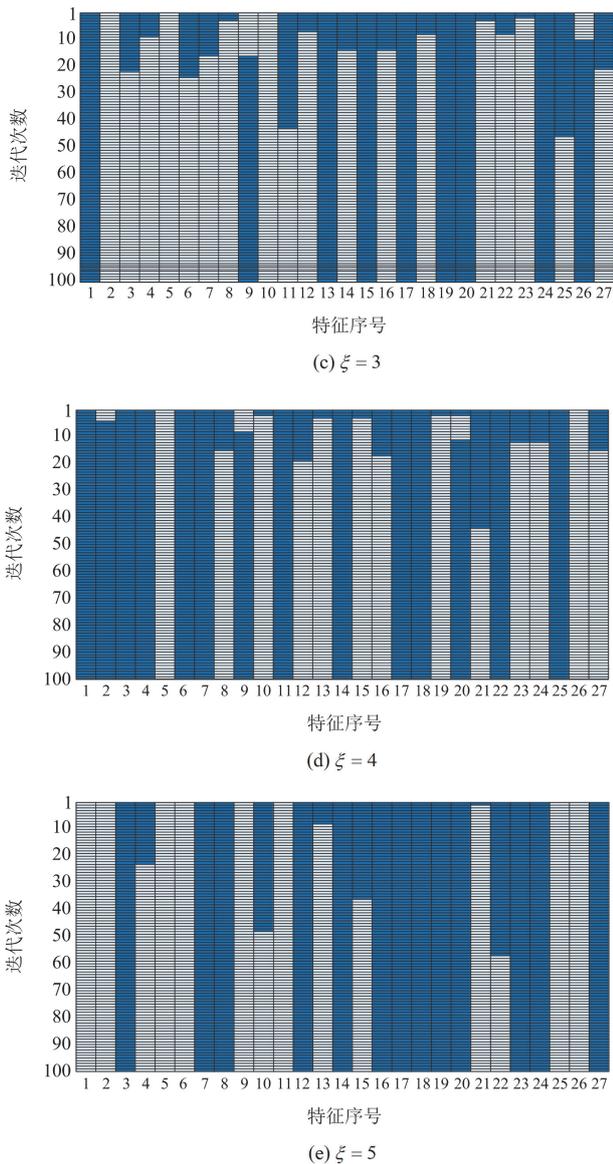


图 13 智能体行动轨迹

Fig. 13 Agent action trajectory

别为 629.98、91.58、32.94、821.52 和 610.53，其对应的标准差分别为 614.95、123.21、44.83、2150.95 和 950.09。

使用 ALO 计算阈值，其参数设置如下：数量 $N = 80$ ，最大迭代次数 $T = 200$ ，搜索空间的上限分别为 133.80、27.69、93.72、7.96 和 123.16，搜索空间的下限分别为 1.45、1.43、1.32、1.07 和 1.26。依据求得的阈值(5.48、4.77、2.53、3.37 和 2.73)和计算得到的待测样本 MD，对待测样本进行分类。并将结果与其他方法进行比较，取五折交叉验证结果的均值，比较结果见表 6，迭代过程中阈值变化情况的部分图见图 14。

表 6 不同方法在 Dataset A 上的诊断性能
Table 6 Diagnostic performance of different methods on Dataset A

方法	精确度	召回率	特异度	准确率	F1	G-mean
RLMTS	0.96	0.89	0.96	0.93	0.92	0.92
SVM	0.00	0.00	1.00	0.54	0.00	0.00
RF	0.88	0.77	0.90	0.84	0.81	0.83
LR	0.00	0.00	1.00	0.54	0.00	0.00
CNN	0.47	0.91	0.10	0.49	0.62	0.23
RNN	0.31	0.21	0.69	0.45	0.24	0.31
SMOTE-SVM	0.56	0.19	0.84	0.53	0.25	0.34
SMOTE-RF	0.93	0.80	0.95	0.87	0.84	0.86
SMOTE-LR	0.47	0.20	0.77	0.49	0.24	0.33
SMOTE-CNN	0.47	0.65	0.38	0.50	0.52	0.39
SMOTE-RNN	0.47	0.64	0.39	0.51	0.54	0.48
GAN-SVM	0.25	0.09	0.88	0.49	0.10	0.14
GAN-RF	0.91	0.81	0.94	0.87	0.85	0.87
GAN-LR	0.37	0.16	0.84	0.51	0.19	0.26
GAN-CNN	0.48	0.64	0.35	0.50	0.54	0.39
GAN-RNN	0.46	0.63	0.38	0.49	0.52	0.47
CAE	0.50	1.00	0.00	0.50	0.65	0.00
FGMSE-WOA-MSVM	0.26	0.52	0.47	0.43	0.34	0.09

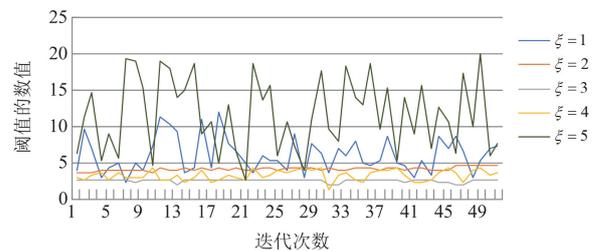


图 14 迭代中阈值情况部分图

Fig. 14 Partial plot of the threshold case in the iteration

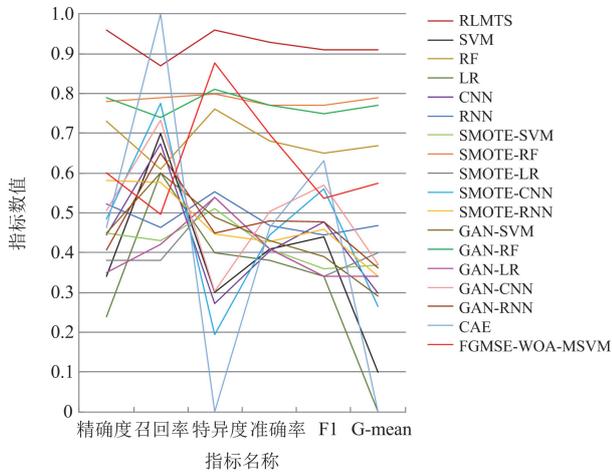
由表 6 可知：RLMTS 的各项指标值均大于 0.85，与其他方法相比，除特异度指标(0.96)稍逊于 SVM 和 LR(1.00)，召回率指标(0.89)逊于 CAE(1.00)，其他指标都优于其他方法。且 SVM 和 CAE 的指标值之所以高，是因为其将所有样本都判为同一类样本，实质上它们的诊断性能并不高。

3.6.2 Dataset B—Dataset E 实验过程和结果

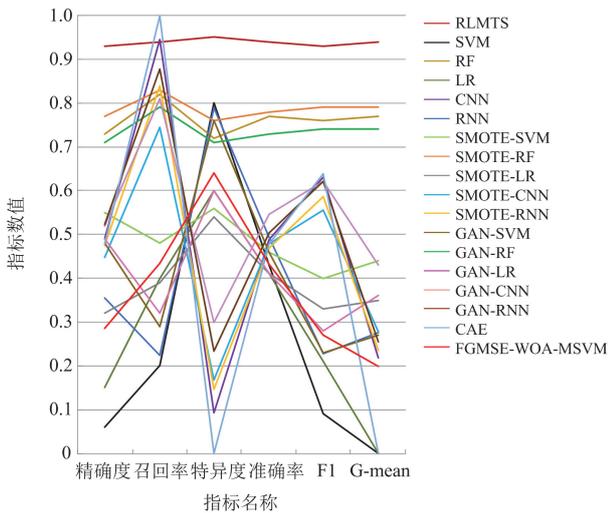
采取和 Dataset A 同样的过程对 Dataset B—Dataset E 进行实验。图 15 展示了 RLMTS 在各数据集上进行五折交叉验证后的结果，表 7 展示了不同方法在 Dataset B—Dataset E 上的诊断性能。

由表 7 可知：与其他 17 种方法相比，面向小样本数据，RLMTS 对于风力发电机齿轮箱具有更优的综合故障诊断能力。CNN 和 RNN 相关的深度学习方法以及 CAE 的诊断性能较弱，究其原因可能在

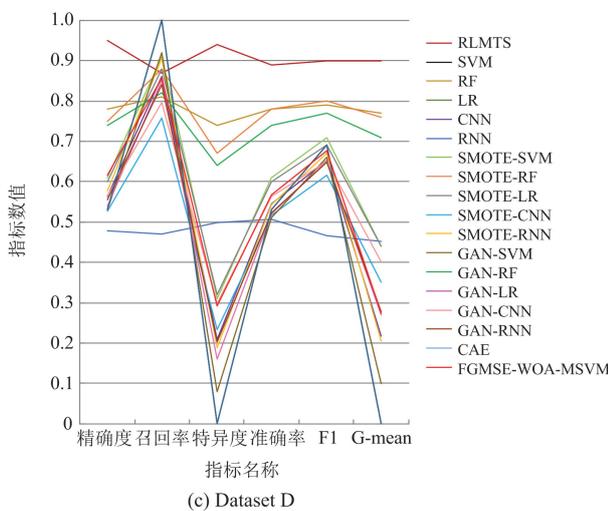
于训练样本过少, 模型易出现过拟合, 泛化能力差等。尽管使用不同的方法生成伪样本以扩充训练样本数量, 但仍存在两方面的问题, 一是在引入生成



(a) Dataset B



(b) Dataset C



(c) Dataset D

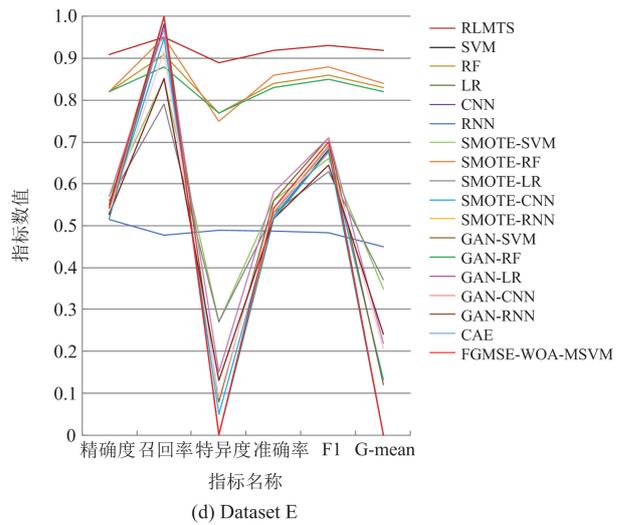


图 15 不同方法的诊断性能

Fig. 15 Diagnostic performance of different methods

表 7 不同方法在 Dataset B—Dataset E 上的诊断性能

Table 7 Diagnostic performance of different methods

on Dataset B—Dataset E						
方法	精确度	召回率	特异度	准确率	F1	G-mean
RLMTS	0.94	0.91	0.94	0.92	0.92	0.92
SVM	0.36	0.72	0.27	0.48	0.48	0.02
RF	0.77	0.79	0.75	0.77	0.77	0.76
LR	0.36	0.75	0.25	0.46	0.48	0.00
CNN	0.51	0.87	0.14	0.49	0.61	0.18
RNN	0.47	0.41	0.58	0.49	0.41	0.41
SMOTE-SVM	0.54	0.66	0.41	0.51	0.53	0.40
SMOTE-RF	0.78	0.86	0.74	0.80	0.81	0.79
SMOTE-LR	0.46	0.61	0.42	0.49	0.50	0.39
SMOTE-CNN	0.50	0.81	0.16	0.49	0.60	0.26
SMOTE-RNN	0.54	0.83	0.20	0.49	0.60	0.20
GAN-SVM	0.50	0.70	0.35	0.49	0.50	0.20
GAN-RF	0.77	0.81	0.73	0.77	0.78	0.76
GAN-LR	0.49	0.64	0.36	0.48	0.50	0.30
GAN-CNN	0.53	0.81	0.25	0.54	0.63	0.35
GAN-RNN	0.50	0.80	0.25	0.51	0.60	0.28
CAE	0.50	1.00	0.00	0.50	0.66	0.00
FGMSE-WOA-MSVM	0.51	0.70	0.45	0.56	0.55	0.26

样本的同时也引入了新的噪声, 使得样本质量无法与真实样本相比; 二是由于小样本本身数量少, 即使以此为基础生成了新的样本, 但为兼顾伪样本的质量, 需对生成样本的数量进行控制, 因此真实样本和伪样本组成的训练样本数量仍较为有限, 虽然现有文献尚未对深度学习方法所需要的最少训练样本数量进行规定, 但通常认为深度学习需要较多的

训练样本,因此在本文的研究中,真实样本和伪样本数量之和可能也无法达到深度学习方法对于样本量的要求。

4 结论

小样本风力发电机齿轮箱故障检测由于样本数量少,往往使得诊断模型易出现过拟合、方差大和泛化能力差等问题,因此,本文提出了 RLMTS 故障检测模型。实验证明,该模型适用于不同小样本数量下的故障检测,能有效应用于多种小样本场景下的工业设备故障检测。此外,在实现高诊断性能的同时,RLMTS 减少了计算量,大幅降低了计算代价。与常见模型和技术相比,RMLTS 的模型结构更简单,计算成本更低,故障检测效率更高,具有较高的工业应用价值,能够有效保证设备运行的稳定性、安全性和可靠性。

本文将正交表和信噪比计算得到的特征空间作为初始马氏空间,结合 RL 和给定的行动规则,对马氏空间进行优化,最后利用 ALO 探索最佳阈值,实现故障检测。该方法在 5 个小样本风力发电机齿轮箱数据集上进行了五折交叉验证,可以得到以下结论。

1) 面对小样本风力发电机齿轮箱数据,RLMTS 与其他方法相比具有更优的故障诊断性能,平均精确度为 0.94、平均召回率为 0.90、平均特异度为 0.94、平均准确率为 0.90、平均 F1 值为 0.92、平均 G-mean 值为 0.92,各项指标值都大于 0.90,不仅各项指标能力较均衡,且都处于较高水平。

2) 对不同小样本数量下 RLMTS 模型的诊断能力进行了探究,结果证明即使训练样本的数量低至 32,RLMTS 仍能对其进行有效故障检测。

3) SMOTE 对于生成新样本以提高模型在小样本场景下的故障诊断能力具有一定效果。在使用 SMOTE 扩充样本数量之后,SVM、RF、LR 和 CNN 的综合指标值均有所上升。SVM 的准确率、F1 值和 G-mean 值分别提高了 0.02、0.10 和 0.37; RF 的准确率、F1 值和 G-mean 值分别提高了 0.03、0.04 和 0.04; LR 的准确率、F1 值和 G-mean 值分别提高了 0.01、0.06 和 0.38; CNN 的准确率、F1 值和 G-mean 值分别提高了 0.03、0.002 和 0.19。

4) GAN 对于生成新样本以扩充样本训练量具有一定作用。在使用 GAN 对样本数量进行扩充后,SVM、RF 和 LR 的准确率、F1 值、G-mean 值有所提高,SVM 分别提高了 0.005、0.04、0.17,RF 分别提高了 0.01、0.02、0.01,LR 分别提高了 0.01、0.05、0.29,CNN 分别提高了 0.04、0.01、0.17。

GAN-CNN 与 CNN 相比,准确率提高了 0.01,G-mean 值提高了 0.18,但 F1 值下降了 0.05。GAN-RNN 与 RNN 相比,准确率下降了 0.01,F1 值提高了 0.14,但 G-mean 值下降了 0.12。说明在小样本数据特征下,受样本数量和维度等条件限制,使用 GAN 生成的新样本不一定能满足深度学习对于训练样本量的要求,其表现可能不佳。而与深度学习相比,传统浅层机器学习方法相对而言对于样本数量的要求较低,因此在本文中 GAN 与浅层机器学习方法相结合的模型呈现出较好的诊断能力。

RLMTS 聚焦于小样本场景,目前最少的训练样本数为 32,对于更小样本量下的工业设备故障检测(尤其是大型昂贵设备的破坏性实验)尚未进行深入研究。此外,当前研究的故障为单一故障,未对复合故障进行研究,未来将结合复合故障,开展更小样本量下的设备故障检测研究。

参考文献

- [1] 刘军,安柏任,张维博,等.大型风力发电机组健康状态评价综述[J].电力系统保护与控制,2023,51(1): 176-187.
LIU Jun, AN Bairen, ZHANG Weibo, et al. Review of health status evaluation of large wind turbines[J]. Power System Protection and Control, 2023, 51(1): 176-187.
- [2] 黄简,杨程,冯天波,等.面向风电机组运维的知识图谱构建研究与应用[J].电力系统保护与控制,2024,52(8): 167-177.
HUANG Jian, YANG Cheng, FENG Tianbo, et al. Research and application of knowledge graph construction for wind turbine operation and maintenance[J]. Power System Protection and Control, 2024, 52(8): 167-177.
- [3] 李东东,蒋海涛,赵耀,等.极端条件下基于改进深度森林的行星齿轮箱故障诊断方法[J].电力系统保护与控制,2023,51(11): 39-50.
LI Dongdong, JIANG Haitao, ZHAO Yao, et al. Fault diagnosis technology of a planetary gearbox based on an improved deep forest algorithm under extreme conditions[J]. Power System Protection and Control, 2023, 51(11): 39-50.
- [4] SHI J, PENG D, PENG Z, et al. Planetary gearbox fault diagnosis using bidirectional-convolutional LSTM networks[J]. Mechanical Systems and Signal Processing, 2022, 162.
- [5] 苏向敬,山衍浩,周汶鑫,等.基于 GRU 和注意力机制的海上风机齿轮箱状态监测[J].电力系统保护与控制,2021,49(24): 141-149.
SU Xiangjing, SHAN Yanhao, ZHOU Wenxin, et al. GRU and attention mechanism-based condition monitoring of

- an offshore wind turbine gearbox[J]. *Power System Protection and Control*, 2021, 49(24): 141-149.
- [6] HE Y, HUA Q, ZHU Q, et al. Enhanced virtual sample generation based on manifold features: applications to developing soft sensor using small data[J]. *ISA Transactions*, 2022, 126: 398-406.
- [7] LI X, CHANG D, MA Z, et al. Deep InterBoost networks for small-sample image classification[J]. *Neurocomputing*, 2020, 456.
- [8] SUN C, ZHANG X, MENG H, et al. AC-WGAN-GP: generating labeled samples for improving hyperspectral image classification with small-samples[J]. *Remote Sensing*, 2022, 14(19).
- [9] SU Y, MENG L, KONG X, et al. Small sample fault diagnosis method for wind turbine gearbox based on optimized generative adversarial networks[J]. *Engineering Failure Analysis*, 2022: 140.
- [10] WANG Y, WANG J, TONG P. Small sample fault diagnosis for wind turbine gearbox based on lightweight multiscale convolutional neural network[J]. *Measurement Science and Technology*, 2023, 34(9).
- [11] JIAO C, ZHANG D, FANG X, et al. Ensemble of simplified graph wavelet neural networks for planetary gearbox fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72.
- [12] TOUTI W, SALAH M, SHENG S, et al. An envelope time synchronous averaging for wind turbine gearbox fault diagnosis[J]. *Journal of Vibration Engineering & Technologies*, 2024, 12(4).
- [13] NA K, KIM Y, YOON H, et al. FASER: fault-affected signal energy ratio for fault diagnosis of gearboxes under repetitive operating conditions[J]. *Expert Systems with Applications*, 2024, 238.
- [14] MA R, HAN T, LEI W. Cross-domain meta learning fault diagnosis based on multi-scale dilated convolution and adaptive relation module[J]. *Knowledge-Based Systems*, 2023, 261.
- [15] LIANG J, LIANG Q, WU Z, et al. A novel unsupervised deep transfer learning method with isolation forest for machine fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(1): 235-246.
- [16] SHE D, YANG Z, DUAN Y, et al. A meta transfer learning method for gearbox fault diagnosis with limited data[J]. *Measurement Science and Technology*, 2024, 35(8).
- [17] LI F, MIN Y, ZHANG Y, et al. Evaluation method for consistency of lithium-ion battery packs in electric vehicles based on the Mahalanobis-Taguchi system[J]. *Journal of Energy Storage*, 2024, 78.
- [18] SIKDER S, MUKHERJEE I, PANJA S C. A synergistic Mahalanobis-Taguchi system and support vector regression based predictive multivariate manufacturing process quality control approach[J]. *Journal of Manufacturing Systems*, 2020, 57: 323-337.
- [19] TAN L, MUHAMAD W Z A, YAHYA Z R, et al. A survey on improvement of Mahalanobis Taguchi system and its application[J]. *Multimedia Tools and Applications*, 2023, 82(28): 43865-43881.
- [20] RAMLIE F, MUHAMAD W Z A W, HARUDIN N, et al. Classification performance of thresholding methods in the Mahalanobis-Taguchi system[J]. *Applied Sciences-Basel*, 2021, 11(9).
- [21] TAGUCHI G, WU Y, CHODHUEY S. Mahalanobis-Taguchi system[M]. McGraw-Hill Professional, 2000.
- [22] MINSKY M. Steps toward artificial intelligence[J]. *Proceedings of the IRE*, 1963, 49(1): 8-30.
- [23] WATKINS C J C H. Learning from delayed rewards[J]. *Robotics & Autonomous Systems*, 1989.
- [24] MIRJALILI S. The ant lion optimizer[J]. *Advances in Engineering Software*, 2015, 83: 80-98.
- [25] National Renewable Energy Laboratory. Gearbox fault diagnosis data[data set]. 2018. <https://data.openei.org/submissions/623>.
- [26] LÜ Y, ZHANG Q, CHEN A, et al. Interval prediction of remaining useful life based on convolutional auto-encode and lower upper bound estimation[J]. *Eksploracja I Niezawodnosc-Maintenance and Reliability*, 2023, 25(2).
- [27] WANG B, QIU W, HU X, et al. A rolling bearing fault diagnosis technique based on fined-grained multi-scale symbolic entropy and whale optimization algorithm-MSVM[J]. *Nonlinear Dynamics*, 2024, 112(6): 4435-4447.

收稿日期: 2024-07-23; 修回日期: 2024-10-14

作者简介:

茅婷(1996—), 女, 博士研究生, 研究方向为故障诊断、强化学习、马田系统; E-mail: maoting@njust.edu.cn

程龙生(1964—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为设备故障预测与健康管理、数据挖掘。

E-mail: cheng_longsheng@njust.edu.cn

(编辑 周金梅)