

信息融合的改进 SVM 风电齿轮箱故障诊断方法

蔺思玮, 徐志科

(东南大学电气工程学院, 南京 210096)

摘要: 为提升风电机组运行效率并优化运维成本, 将时域特征指标分析技术与多传感器信息融合策略相结合, 提出一种基于灰狼优化 (Grey wolf optimization, GWO) 算法-支持向量机 (Support vector machine, SVM) 的风电齿轮箱状态监测方法。首先计算了表征振动能量的不同时间统计特征值, 采用并行叠加方式进行特征级和数据级融合得到信息融合矩阵。在此基础上建立了基于 GWO-SVM 的故障诊断分类模型。为验证模型性能, 使用 QPZZ-II 旋转机械振动试验台所采集的齿轮箱实测数据对本文所提方法进行验证分析, 结果表明该方法明显优于其他传统方法, 其在分类诊断准确率上展现出显著优势。

关键词: 故障诊断; 风电齿轮箱; 灰狼优化-支持向量机; 时域分析; 信息融合

中图分类号: TP277

文献标志码: A

文章编号: 1005-2615(2025)03-0509-08

Improved SVM for Fault Diagnosis of Wind Turbine Gearbox with Information Fusion

LIN Siwei, XU Zhike

(School of Electrical Engineering, Southeast University, Nanjing 210096, China)

Abstract: To improve the operational efficiency of wind turbines and optimize the operation and maintenance costs of wind farms, this paper combines time-domain feature index analysis with multi-sensor information fusion technology to propose a wind turbine gearbox state monitoring method based on grey wolf optimization (GWO) algorithm-support vector machine (SVM). Firstly, different time-domain statistical eigenvalues representing vibration energy are calculated, and parallel stacking is used for feature level and data level fusion to obtain an information fusion matrix. Secondly, on this basis, establish a fault diagnosis classification model based on GWO-SVM. Finally, the proposed method is validated and analyzed using the measured data of the gearbox collected from the QPZZ-II rotating machinery vibration test. The results show that this method is significantly better than other traditional methods, and its classification and diagnostic accuracy demonstrate significant advantages.

Key words: fault diagnosis; wind turbine gearbox; grey wolf optimization-support vector machine (GWO-SVM); time domain analysis; information fusion

风力发电在全球能源转型中扮演着至关重要的角色, 中国在风电领域处于世界领先地位。根据数据统计显示中国的风电机组总装机容量在 2023 年高达 476.5 GW, 几乎占全球总装机容量的一半。然而, 由于风电机组运行环境是复杂的非线性、变

载荷和不稳定系统, 使得风电场的运营成本居高不下^[1-3]。据统计, 整个陆上风电的运维成本中其维修费用高达 62%, 如图 1 所示, 海上风电场更甚^[4-5]。齿轮箱是容易发生损伤的元件之一, 其如果产生损伤事故不仅会导致机组停机, 还会造成高

收稿日期: 2024-10-03; 修订日期: 2025-03-08

通信作者: 徐志科, 男, 副教授, E-mail: xuzhike@seu.edu.cn。

引用格式: 蔺思玮, 徐志科. 信息融合的改进 SVM 风电齿轮箱故障诊断方法[J]. 南京航空航天大学学报(自然科学版), 2025, 57(3): 509-516. LIN Siwei, XU Zhike. Improved SVM for fault diagnosis of wind turbine gearbox with information fusion[J]. Journal of Nanjing University of Aeronautics & Astronautics (Natural Science Edition), 2025, 57(3): 509-516.

昂的设备维修成本^[6-8]。因此,为提高机组可靠性,降低事故风险,如何及时、高效且精准地进行风电机组齿轮箱故障识别成为当今研究热点。




图1 陆上风电运维成本占比

Fig.1 Proportion of onshore wind power operation and maintenance costs

针对风电齿轮箱的故障诊断研究,国内外学者提出了多种不同的智能故障诊断算法。Shao等^[9]利用定子和转子电压方程导出状态空间模型,并采用双线性观测器来检测双馈感应发电机中的电流传感器故障。基于机理模型的方法基本简化了实际系统,使得该模型与实际响应相差较大,尤其当系统过于复杂时完全无法获取全部的内部机理信息。张李炜等^[10]提出基于Apriori算法与卷积神经网络相结合的风电机组故障诊断模型,以降低对专家系统的依赖程度。金晓航等^[11]针对风电机组数据采集和监视控制系统的误报、故障报警的滞后性等问题,提出一种基于单分类模型的风电机组变桨系统在线状态监测研究方法。Wang等^[12]提出一种基于改进时移多尺度波动离散熵和余弦成对约束监督流形映射的风电机组数据驱动故障诊断方法。周凌等^[13]提出基于萤火虫改进麻雀搜索算法优化深度置信网络的风电机组故障诊断与状态监测新方法。宋威等^[14]采用美国凯斯西储大学的公开轴承数据集,引入一维振动信号的灰度图像化数据预处理方法,结合改进的降噪自编码器方法对风电机组滚动轴承进行故障诊断研究。上述方法不需要过程模型和先验知识,只需针对过程数据进行处理和分析,简单性好,实用性强,但由于风电齿轮箱工作环境的复杂性导致单一传感器数据信息难以准确反映异常部件的故障情况。万若青研究团队^[15]提出了一种自适应盲去噪自编码器方法,通过设计邻域采样数据扩展方案构建训练集,利用该方法的大样本训练自动学习信号特征。该方法创新性地采用无需参考干净信号的处理机制,实现了对含噪振动数据的自适应降噪,但缺点是无法有效提取原始信号的频域特征。赵志宏等^[16]结合马尔可夫变迁场和卷积神经网络进行轴承的故障诊断研究,但由于该方法针对图像中的复杂信息识别能力有限,导致其分类精度下降。同时,风电齿轮箱故障具有并发性、继发性和随机性等多种特点,多

个故障同时发生是其常态之一,复合故障更加复杂的故障机理和表现形式,大大加剧了该工况下的模式识别的难度。

针对以上问题,为提高特征信息表征能力并降低计算复杂度,本文提出信息融合的改进支持向量机(Support vector machine, SVM)风电齿轮箱故障诊断方法。首先,为降低时间计算复杂度,通过时域分析获取反映振动能量的特征指标值,结合故障分类模式并采用并行叠加方式得到信息融合数据集。然后,为提高模型诊断精度,提出改进的SVM,并构建灰狼优化(Grey wolf optimization, GWO)算法的SVM模型,捕获隐藏于微弱原始振动数据信息中的故障特征。最后,结合在QPZZ-II旋转试验平台采集到的原始振动数据信息,进行齿轮箱的故障分类预测。与其他方法相比,该方法在分类诊断精度上表现最佳。

1 基本原理

1.1 时域分析与多传感器信息融合技术

风电齿轮箱故障发生时,故障特征的振动能量会发生显著变化,时域统计指标能够有效记录这一能量变化。但由于风电齿轮箱工作环境的复杂性,即使面对相同故障分类其判别标准并不具有一致性,使得故障诊断的困难性进一步加剧。为攫取更有效的故障特征信息,结合时域特征指标和信息融合技术对相关振动信息进行优化组合后可较大幅度地提高故障分类精度。如图2所示为基于时域分析的多传感器信息融合模型。




图2 多传感器信息融合模型

Fig.2 Multi-sensor information fusion model

过程具体如下:

(1)采集多个加速度传感器 n 的多源有限离散振动序列信号组 V_i ,原始数据信息为

$$V(t) = \begin{bmatrix} V_1^1 & V_1^2 & \cdots & V_1^n & fl_1 \\ V_2^1 & V_2^2 & \cdots & V_2^n & fl_2 \\ \vdots & \vdots & & \vdots & \vdots \\ V_N^1 & V_N^2 & \cdots & V_N^n & fl_i \end{bmatrix} \quad (1)$$

式中: N 代表单个传感器采集的信号长度; $V_i = \{V^1(t), V^2(t), \dots, V^n(t)\}$; fl_i 代表故障分类。

(2)有量纲时域指标,即均方根值、最大值、最小值、峰峰值、方差值和均值分别为

$$V_{\text{rms}} = \left(\frac{1}{K} \sum_{l=1}^K (V_l)^2 \right)^{1/2} \quad (2)$$

$$V_{\text{max}} = \max \{V_l\} \quad (3)$$

$$V_{\text{min}} = \min \{V_l\} \quad (4)$$

$$V_{\text{pp}} = V_{\text{max}} - V_{\text{min}} \quad (5)$$

$$\rho^2 = \frac{1}{K} \left(V_l - \left(\frac{1}{K} \sum_{l=1}^K V_l \right) \right)^2 \quad (6)$$

$$\bar{V}_l = \frac{1}{K} \sum_{l=1}^K V_l \quad (7)$$

式中: K 表示计算长度; V_l 代表采集的振动信号幅值。

无量纲时域指标,即脉冲、峭度、峰值、方根幅值、平均幅值、裕度和波形分别为

$$\xi = \frac{\max |V_l|}{(1/K) \sum_{l=1}^K |V_l|} \quad (8)$$

$$V_q = \frac{1}{K} \sum_{l=1}^K \frac{(V_l - \bar{V}_l)^4}{\left(\frac{1}{K} \sum_{l=1}^K (V_l)^2 \right)^2} \quad (9)$$

$$\xi = \frac{\max |V_l|}{V_{\text{rms}}} \quad (10)$$

$$V_r = \left(\frac{1}{K} \sum_{l=1}^K |V_l|^{1/2} \right)^2 \quad (11)$$

$$V' = \frac{1}{K} \sum_{l=1}^K |V_l| \quad (12)$$

$$v = \frac{\max |V_l|}{V_r} \quad (13)$$

$$\Gamma = \frac{V_{\text{rms}}}{V'} \quad (14)$$

(3) 结合并行叠加、数据集和特征级相融合的方法,得到数据融合集

$$R_V = \begin{bmatrix} R_1(1,1) & R_1(1,2) & \cdots & R_1(1,13) & \cdots & R_m(1,13) & fl_i^1 \\ R_1(2,1) & R_1(2,2) & \cdots & R_1(2,13) & \cdots & R_m(2,13) & fl_i^1 \\ \vdots & \vdots & & \vdots & & \vdots & \vdots \\ R_1(s,1) & R_1(s,2) & \cdots & R_1(s,13) & \cdots & R_m(s,13) & fl_i^m \end{bmatrix} \quad (15)$$

式中: $R_V \in R^{(N/K) \times (13 \times n + 1)}$; $s = N/K$ 。

1.2 SVM方法

SVM方法^[17]具有优秀的分类能力,其学习策略是通过间隔距离最大化搜寻最优决策超平面,假设 $X(x_1, x_2, \dots, x_n)$ 为样本中的点,超平面具体表达式为

$$W^T X + b = 0 \quad (16)$$

式中: W 为超平面法向量,决定超平面方向; b 为偏置项,表示超平面与原点之间的偏移距离。

样本至样本超平面的距离表达式为

$$D = \frac{|w^1 \times x_1 + w^2 \times x_2 + \cdots + w^n \times x_n + b|}{\sqrt{(w^1)^2 + (w^2)^2 + \cdots + (w^n)^2}} = \frac{W^T X + b}{\|w\|} \quad (17)$$

为对数据进行分类后并寻求最优特征空间,以实现较高分类精度,利用式(18)完成SVM的优化问题

$$\begin{cases} \max 1/\|w\| \\ \text{s.t. } \ell_i(w^T x_i + b) \geq 1 \end{cases} \quad (18)$$

式中: $\|w\|$ 表示超平面范数; w 表示超平面法向量; x_i 表示样本空间; ℓ_i 表示分类标签; $i = 1, 2, \dots, n$; n 表示样本个数,为使间隔距离最大化其本质就是使 $1/\|w\|$ 最大化,相当于最小化 $\|w\|^2/2$ 。

由于数据样本的噪声污染性,为防止该因素导致的问题可能无解,在式(18)的基础上引入松弛系数

$$\begin{cases} \min \|w\|^2/2 + C \sum_{i=1}^n \epsilon_i \\ \text{s.t. } \ell_i(w^T x_i + b) \geq 1 - \epsilon_i \quad \epsilon_i \geq 0 \end{cases} \quad (19)$$

式中: C 表示惩罚因数, ϵ_i 表示松弛常量。在具体应用中,由于数据的非线性特征,采用核函数将非线性数据映射至高维空间以实现分类并最终映射回低维空间。本文采用高斯核函数进行映射变换

$$K(x_i, x_j) = \exp(-g \|x_i - x_j\|^2) \quad g > 0 \quad (20)$$

式中 g 表示核参数。

惩罚因素 C 和核参数 g 的选择将影响SVM模型的分类精度^[18],为避免人工随机赋值造成的模型结构波动,提高故障诊断精度,本研究通过GWO算法优化 C 和 g 以获得最优参数值,构建基于最优参数的GWO-SVM故障分类模型。

1.3 GWO算法

GWO算法是由Mirjalili等^[19]受灰狼种群生态特征启发而设计的一种智能优化算法,其核心思想在于借鉴自然界中灰狼群体的阶层化社会结构和协同捕食策略,实现对复杂优化问题的高效求解。图3展示了灰狼社会的等级制度,由上至下分别代表不同优劣的解决方案,其中Alpha表示最优解决方案。




图3 灰狼等级制度

Fig.3 Grey wolf hierarchy

灰狼的围攻行为可表示为

$$\begin{cases} D = |2\text{rand}(0, 1) \cdot X_p(t) - X_w(t)| \\ X_w(t+1) = X_p(t) - 2a \cdot (\text{rand}(0, 1) - a) \cdot D \end{cases} \quad (21)$$

式中: t 表示当前迭代次数; $\text{rand}(0, 1)$ 为 $[0, 1]$ 区间分布的随机变量; X_p 和 X_w 分别对应猎物与灰狼个体的空间坐标向量; a 表示从 2 到 0 线性递减的值。

$X_w = \{X_1, X_2, \dots, X_n\}$ 表示狼群由 n 只灰狼组成, 可根据式 (22~24) 计算灰狼 X_n 与 X_{α} 、 X_{β} 和 X_{δ} 的距离

$$D_{\alpha} = |2\text{rand}_1(0, 1) \cdot X_{\alpha} - X| \quad (22)$$

$$D_{\beta} = |2\text{rand}_2(0, 1) \cdot X_{\beta} - X| \quad (23)$$

$$D_{\delta} = |2\text{rand}_3(0, 1) \cdot X_{\delta} - X| \quad (24)$$

该距离计算完毕后, 再根据式 (25~28) 更新 X_n 的位置, 灰狼 X_w 向 X_{α} 、 X_{β} 和 X_{δ} 移动的矢量分别用 X_1 、 X_2 、 X_3 表示, 有

$$X_1 = X_{\alpha} - 2a \cdot (\text{rand}_1(0, 1) - a) \cdot D_{\alpha} \quad (25)$$

$$X_2 = X_{\beta} - 2a \cdot (\text{rand}_2(0, 1) - a) \cdot D_{\beta} \quad (26)$$

$$X_3 = X_{\delta} - 2a \cdot (\text{rand}_3(0, 1) - a) \cdot D_{\delta} \quad (27)$$




图 4 信息融合的 GWO-SVM 模型结构

Fig.4 Structure of GWO-SVM model for information fusion

2.2 模型诊断流程

本文使用准确率、均方根误差作为故障诊断模型的量化指标, 同时, 利用训练精度和测试精度细化模型预测分类和实际分类的一致性, 构建了融合灰狼优化算法与支持向量机的风电齿轮箱故障诊断模型, 如图 5 所示。

具体步骤如下:

(1) 采集齿轮箱振动信号。利用 QPZZ-II 旋转机械振动试验台, 采集安装在不同位置的传感器加速度信号, 为保持与实际风场数据的一致性, 应考虑在变负载、变转速工况下的同一种故障类型。

(2) 多传感器信息融合。利用式 (2~14) 分别计算反映振动烈度的有量纲指标值和无量纲指标

2 信息融合的 GWO-SVM 风电齿轮箱故障诊断模型

2.1 模型基本结构

由于人工随机赋值 C 和 g 参数可能降低 SVM 模型的泛化能力, 且容易导致模型过拟合或欠拟合的发生。为选择最优参数, 提高模型故障诊断分类精度和泛化能力, 本文构建基于信息融合的 GWO-SVM 风电齿轮箱故障诊断模型, 如图 4 所示。首先, 为降低数据信息维度、提高计算效率并加强故障特征表征能力, 采用时域分析和多传感器信息融合技术将一维振动信号进行数据融合。其次, 为更深层次地提取融合数据信息的重要特征, 降低模型对人工随机赋值 C 和 g 参数的敏感性, 引入 GWO 寻求最优的惩罚参数和核参数。最后, 为提高模型泛化能力, 建立 GWO-SVM 齿轮箱故障分类模型, 并通过 softmax 层进行故障分类, 输出诊断结果。




图 5 改进的 GWO-SVM 算法流程图

Fig.5 Flowchart of the improved GWO-SVM algorithm

值,并以并行叠加方式处理该数据以获取齿轮箱振动融合信息集。

(3)归一化信息处理。利用 min-max 方法处理步骤(2)的融合数据集,如式(29)所示,将其映射至[0,1]范围之类,得到归一化的数据信息,将其作为故障诊断模型的测试和训练样本集,即有

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \tag{29}$$

式中: y 代表原始数据; $y_{\min}$ 代表数据最小值; $y_{\max}$ 代表数据最大值; y' 代表归一化数据。

(4)确定 SVM 分类模型拓扑结构。利用 GWO 方法优化 SVM 模型,以式(30)为标准获得最优的 C 和 g 参数,有

$$\begin{aligned} \max \text{ fitness}(C, g) &= \frac{\text{Correct}}{\text{All}} \times 100\% \\ \text{s.t. } C &\in [C_{\min}, C_{\max}], g \in [g_{\min}, g_{\max}] \end{aligned} \tag{30}$$

式中: $C \in [C_{\min}, C_{\max}]$, $g \in [g_{\min}, g_{\max}]$ 分别代表惩罚因数 C 和核参数 g 的取值范围,设置为 $[0.01, 100]$; Correct 代表分类正确数据样本;All 代表全部数据样本。在确定 Alpha 狼、Beta 狼、和 Delta 狼的初始空间坐标情况下,利用式(30)对其位置进行评估以便寻求本次迭代的最优解,并依次迭代且以最大化诊断精度为依据寻求最优的 C 和 g 参数。

(5)建立 GWO-SVM 故障诊断模型。以一定比例设置诊断模型的训练、测试数据样本,并采用该模型对齿轮箱进行故障诊断分类,并以均方根误差(RMSE)来测试故障分类精准度,有

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^T (x(t) - \hat{x}(t))^2}{T}} \tag{31}$$

式中: $\hat{x}(t)$ 、 $x(t)$ 分别表示为第 t 个样本的预测值和实际值, T 代表总样本数量。

3 实例验证

为验证本文所提 GWO-SVM 方法的有效性和实用性,采用 QPZZ-II 旋转机械振动试验台采集齿轮箱原始故障振动数据信息,系统采样频率为 5.12 kHz 且可以模拟齿轮箱多种故障分类模式。针对采集到原始振动数据进行信息融合,基于 GWO-SVM 方法能准确判断设备的健康状态和故障类型,相比于其他方法,该方法分类性能最佳。

3.1 实验装置平台

QPZZ-II 旋转机械振动平台如图 6 所示^[20],主要由齿轮箱、三相交流变频电机、联轴和磁粉扭力矩等部件构成。为与风电齿轮箱的复杂环境相适




图 6 实验装置平台

Fig.6 Platform of the experimental setup

应,本系统平台充分模拟了变负载、变转速等工况下齿轮箱的不同故障分类。

为提高数据的准确性,增强系统的冗余度和容错性,通过安装在齿轮箱部件的 5 个加速度传感器采集原始振动数据信息,通过 0.75 kW 三相交流变频电机驱动齿轮系统运转(具体参数见表 1),最终获取到 $1\,212\,928 \times 5$ 的原始振动加速度信号矩阵。

表 1 旋转机械振动平台参数设置

Table 1 Parameter settings for rotating mechanical vibration stage

采样频率/ kHz	润滑方式	输入齿轮 齿数	输出齿轮 齿数	模数
5.12	油浸式	55	75	2

3.2 多传感器数据信息处理

实验中,通过调节负载扭矩以适应生产实际变负荷工况,调节输入转速以适应生产实际生产实际变转速工况,并模拟齿轮点蚀、磨损、断齿以及复合故障等 6 种故障分类,如表 2 所示。将 512 行作为计量单位,利用式(2~14)计算时域特征指标值,采用并行叠加方式融合该数据信息,得到 1 组 $2\,369 \times 66$ 的模型样本数据集,利用该组数据进行 GWO-SVM 模型的训练与测试。

表 2 齿轮箱故障种类

Table 2 Gearbox failure types

故障 分类	故障 位置	故障 模式	输入 转速/($r \cdot \min^{-1}$)	负载/W
1	输入齿轮 输出齿轮	点蚀 磨损	825/880/1 470	104.4/0/0
2	输入齿轮	点蚀	834/880/1 500	104.4/0/0
3	输入齿轮	断齿	840/878/1 470	104.4/0/0
4	输出齿轮	磨损	830/881/1 478	104.4/0/0
5	正常	正常	800/880/1 475	104.4/0/0
6	输入齿轮 输入齿轮	断齿 磨损	812/878/1 474	104.4/0/0

3.3 实验结果分析

分别利用原始数据信息矩阵、融合数据信息矩阵,训练样本和测试样本依据 8:2 的比例进行设置,建立 GWO-SVM 故障诊断模型,同时构建标准 SVM 模型及蚁狮优化(Ant lion optimization, ALO)-SVM(ALO-SVM)算法模型,为了尽可能减少误差,对每种方法进行 20 次重复实验,验证不同数据集以及不同诊断方法的分类性能。最大迭代次数的参数设为 50,种群数量设为 10,惩罚因数 C 和核参数 g 均为 $[0.01, 100]$,以式(31)作为判断标准,依据式(30)确定种群最优值。SVM 算法采用高斯核函数进行映射变换,将信息融合矩阵中的 65 个时域特征指标值作为模型的输入,将表 2 中的 6 种故障模式作为模型输出,构建 GWO-SVM 故障诊断模型,如图 7 所示。




图 7 基于 GWO-SVM 的故障诊断模型

Fig.7 Fault diagnosis model based on GWO-SVM

由于极限学习机(Extreme learning machine, ELM)具有学习速度快、泛化能力较强等优点,近年来在故障诊断领域使用较多,本文采用的 ELM

方法将隐藏层神经元数量设为 100,与输入特征和输出类别相适应,并设置调节系数波动范围为 10~50,原始数据集输入层节点数设为 3,融合数据集设为 65,输出层节点个数设为 6,与故障分类相适应,单隐层节点激活函数采用 Sigmoid 函数。为验证本文方法的有效性和优越性,根据融合数据信息,采用相同的模型参数设置,分别构建基于 GWO-SVM、ALO-SVM、SVM 和 ELM 的不同故障诊断模型,同时设置未进行信息融合原始振动信号作为对照组。实验采用随机抽取的 23 696 组原始振动信号作为样本,以 5 个传感器对应的信号作为模型输入,将 6 种故障模式作为模型输出,进行 20 次独立重复实验验证,诊断结果如图 8 所示。由图 8 可知,基于信息融合的故障诊断精度远远大于初始数据的故障诊断精度。

进一步分析可知,基于多传感器信息融合技的 GWO-SVM、ALO-SVM、SVM 和 ELM 都能不同程度的进行故障诊断,4 种模型依次取得的平均训练、测试和诊断时间如表 3 所示。根据表 3 可知:(1)GWO-SVM 模型的平均训练精度和平均测试精度分别达到 99.68%、98.51%,高于同类的其余 3 种方法;(2)针对原始数据信息,基于 GWO-SVM 的故障诊断精度也高于其他方法;(3)相比于 SVM、ELM 方法,GWO-SVM 和 ALO-SVM 的诊断方法所需要的时间更长,GWO-SVM 的时间长 100 s 左右,但诊断精度的提高可以忽略此种影响。因此,信息融合的 GWO-SVM 故障诊断方法具有最佳分类精度。风电机组的运行工况表明,故障诊断精度的提高更能促使现场工作人员及时停机检




图 8 故障诊断结果图

Fig.8 Diagrams of trouble shooting results

表 3 同类算法比较				
Table 3 Comparison of similar algorithms				
诊断方法	平均诊断 时间/s	平均训练 精度/%	平均测试 精度/%	数据类型
GWO-SVM	110	99.68	98.51	融合数据
	105	56.53	50.36	原始数据
ALO-SVM	360	98.50	96.06	融合数据
	128	53.06	47.11	原始数据
SVM	6	97.67	94.66	融合数据
	4	41.93	36.18	原始数据
ELM	7	71.03	68.64	融合数据
	5	36.56	34.58	原始数据

查并做好有效的防范或检修措施,以便提高机组运行效率,并防止事故进一步扩大,从而降低整个风场的生产运营成本。

4 结 论

本文结合多传感器信息融合技术和时域特征分析技术,并结合灰狼优化算法支持向量机诊断模型,有效地进行风电齿轮箱的故障诊断。针对风电齿轮箱复杂运行工况下的故障诊断问题,重点探讨了不同负载与转速条件下的单一及复合故障。采用QPZZ-II 旋转机械平台所采集到的齿轮箱原始振动数据,分别基于原始数据、融合数据集训练 GWO-SVM 模型,并与几种传统方法进行对比。实验结果表明,该方法较传统算法展现出更优的故障辨识精度,为风电齿轮箱状态监测提供了新的技术手段。但受限于目前风电场在线故障诊断系统的安装有限以及业主对数据的保密性要求,本文所提 GWO-SVM 方法仅通过实验平台数据进行了验证,联系实际风场进行数据采集并评估该算法应用于生产实际的优劣性是下一步待解决的问题。

参考文献:

[1] 吴岚,柳亦兵,吴仕明,等. 基于 VMD 倒频变换的风电机组齿轮箱复合故障诊断[J]. 振动与冲击, 2023, 42(24): 221-227.
WU Lan, LIU Yibing, WU Shiming, et al. Composite fault diagnosis of wind turbine gearboxes based on VMD cepstral transform[J]. Journal of Vibration and Shock, 2023, 42(24): 221-227.

[2] 谭启瑜,马萍,张宏立,等. 基于图注意力网络的风力发电机齿轮箱故障诊断[J]. 太阳能学报, 2024, 45(1): 265-274.
TAN Qiyu, MA Ping, ZHANG Hongli, et al. Fault diagnosis for wind turbine gearbox based on graph attention networks[J]. Acta Ener-giae Solaris Sinica, 2024, 45(1): 265-274.

[3] GU H, LIU W Y, GAO Q W, et al. A review on wind turbines gearbox fault diagnosis methods[J]. Journal of Vibroengineering, 2021, 23(1): 26-43.

[4] 王笑笑. 基于小波分析的风电机组齿轮箱振动信号识别方法[J]. 电工技术, 2023(14): 46-48,148.
WANG Xiaoxiao. Vibration signal recognition method of wind turbine gearbox based on wavelet analysis[J]. Electric Engineering, 2023(14): 46-48,148.

[5] 任巍曦,张文煜,李明,等. 基于数字孪生的风电机组轴承故障诊断方法研究[J]. 弹箭与制导学报, 2022, 42(3): 97-104.
REN Weixi, ZHANG Wenyu, LI Ming, et al. Fault diagnosis of wind turbine bearing based on digital twin [J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2022, 42(3): 97-104.

[6] 李雄威,郭晓雅,李庚达,等. 一种基于非线性偏最小二乘的风电机组齿轮箱状态监测方法[J]. 可再生能源, 2022, 40(10): 1346-1351.
LI Xiongwei, GUO Xiaoya, LI Gengda, et al. A non-linear PLS method for condition monitoring of wind turbine gearbox[J]. Renewable Energy Resources, 2022, 40(10): 1346-1351.

[7] 陈萱,杨永超,袁博洋,等. NGO-VMD 和 SSNGO-RF 算法在风机齿轮箱故障诊断中的应用[J]. 湖北民族大学学报(自然科学版), 2023, 41(4): 520-529.
CHEN Xuan, YANG Yongchao, YUAN Boyang, et al. Application of NGO-VMD and SSNGO-RF algorithms in fault diagnosis of wind turbine gearboxes[J]. Journal of Hubei Minzu University (Natural Science Edition), 2023, 41(4): 520-529.

[8] 雷春丽,薛林林,焦孟莹,等. 结合改进 ResNet 与迁移学习的风力机滚动轴承故障诊断方法[J]. 太阳能学报, 2023, 44(6): 436-444.
LEI Chunli, XUE Linlin, JIAO Mengxuan, et al. Fault diagnosis method of wind turbines rolling bearing based on improved resent and transfer learning[J]. Acta Ener-giae Solaris Sinica, 2023, 44(6): 436-444.

[9] SHAO Hui, GAO Zhiwei, LIU Xiaoxu, et al. Parameter-varying modelling and fault reconstruction for wind turbine systems[J]. Renewable Energy, 2018, 116: 145-152.

[10] 张李炜,李孝忠. 基于 Apriori 算法和卷积神经网络的风电机组故障诊断模型[J]. 天津科技大学学报, 2022, 37(5): 50-55.
ZHANG Liwei, LI Xiaozhong. Fault diagnosis model of wind turbine based on apriori and convolutional neural network[J]. Journal of Tianjin University of Science and Technology, 2022, 37(5): 50-55.

[11] 金晓航,泮恒拓,徐正国. 数据驱动的风电机组变桨系统状态监测[J]. 太阳能学报, 2022, 43(4): 409-417.

- JIN Xiaohang, PAN Hengtuo, XU Zhengguo. Condition monitoring of wind turbine pitch system using data-driven approach[J]. *Acta Energiæ Solaris Sinica*, 2022, 43(4): 409-417.
- [12] WANG Zhenya, LI Gaosong, YAO Ligang, et al. Data-driven fault diagnosis for wind turbines using modified multiscale fluctuation dispersion entropy and cosine pairwise-constrained supervised manifold mapping[J]. *Knowledge-Based Systems*, 2021, 228: 107276.
- [13] 周凌, 赵前程, 朱岸锋, 等. 基于 FISSA-DBN 模型的风电机组运行状态监测[J]. *振动、测试与诊断*, 2023, 43(1): 80-87.
- ZHOU Ling, ZHAO Qiancheng, ZHU Anfeng, et al. Wind turbine operation status monitoring based on FISSA-DBN model[J]. *Journal of Vibration, Measurement & Diagnosis*, 2023, 43(1): 80-87.
- [14] 宋威, 林建维, 周方泽, 等. 基于改进降噪自编码器的风机轴承故障诊断方法[J]. *电力系统保护与控制*, 2022, 50(10): 61-68.
- SONG Wei, LIN Jianwei, ZHOU Fangze, et al. Wind turbine bearing fault diagnosis method based on an improved denoising autoencoder[J]. *Power System Protection and Control*, 2022, 50(10): 61-68.
- [15] 万若青, 张纯, 江汇强, 等. 基于深度自编码器的振动信号盲去噪方法[J]. *振动与冲击*, 2023, 42(12): 118-125.
- WAN Ruqing, ZHANG Chun, JIANG Huiqiang, et al. A blind denoising method of vibration signals based on a deep autoencoder[J]. *Journal of Vibration and Shock*, 2023, 42(12): 118-125.
- [16] 赵志宏, 李春秀, 窦广鉴, 等. 基于 MTF-CNN 的轴承故障诊断研究[J]. *振动与冲击*, 2023, 42(2): 126-131.
- ZHAO Zhihong, LI Chunxiu, DOU Guangjian, et al. Bearing fault diagnosis method based on MTF-CNN[J]. *Journal of Vibration and Shock*, 2023, 42(2): 126-131.
- [17] 孙绳山, 徐常凯, 何亚群. 基于 RS-PSO-SVM 的航材消耗预测模型[J]. *南京航空航天大学学报*, 2021, 53(6): 881-887.
- SUN Shengshan, XU Changkai, HE Yaqun. Prediction model of air material consumption based on RS-PSO-SVM[J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2021, 53(6): 881-887.
- [18] 谢国民, 王嘉良. 基于混合采样与 IHBA-SVM 的变压器故障辨识方法[J]. *电子测量与仪器学报*, 2022, 36(12): 77-85.
- XIE Guomin, WANG Jialiang. Transformer fault identification method based on hybrid sampling and IHBA-SVM[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(12): 77-85.
- [19] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [20] 高爽. 齿轮故障特征参数提取及最佳特征参数选择研究[D]. 沈阳: 沈阳航空航天大学, 2017.
- GAO Shuang. Research on fault feature extraction and optimal parameters selection for gear[D]. Shenyang: Shenyang Aerospace University, 2017.

(编辑: 孙静)