

基于机器学习的燃气轮机控制系统分层故障诊断

彭道刚¹,裴浩然¹,尹德斌²,张 腾¹

(1. 上海电力大学 自动化工程学院,上海 200090;2. 上海工业自动化仪表研究院有限公司,上海 200233)

摘要:针对传统算法在实际应用中存在网络规模庞大、学习训练时间过长和知识“组合爆炸”而导致网络组织失败等问题,提出基于变分模态分解(Variational Mode Decomposition, VMD)、自回归模型(Autoregressive Model, AR)和轻量型梯度提升机(Light Gradient Boosting Machine, LightGBM)算法的燃气轮机控制系统分层故障诊断方法。首先对原始信号进行VMD-AR建模,获取最具表征性的故障特征向量;然后根据不同层级特点和故障类型设计多个LightGBM模型;最后采用贝叶斯优化算法优化分层诊断模型中的超参数,并将待测信号输入模型进行故障诊断。结果表明:所提算法不仅能够达到95%以上的故障识别率,而且具有更强的泛化能力。

关键词:燃气轮机控制系统;分层诊断;特征提取;轻量型梯度提升机

中图分类号:TK478 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2022.12.021

[引用本文格式]彭道刚,裴浩然,尹德斌,等. 基于机器学习的燃气轮机控制系统分层故障诊断[J]. 热能动力工程,2022,37(12):165-173. PENG Dao-gang, PEI Hao-ran, YIN De-bin, et al. Hierarchical fault diagnosis of gas turbine control system based on machine learning[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(12): 165-173.

Hierarchical Fault Diagnosis of Gas Turbine Control System based on Machine Learning

PENG Dao-gang¹, PEI Hao-ran¹, YIN De-bin², ZHANG Teng¹

(1. College of Automation Engineering, Shanghai University of Electric Power, Shanghai, China, Post Code:200090;
2. Shanghai Institute of Process Automation & Instrumentation, Shanghai, China, Post Code:200233)

Abstract: Aiming at the problems of large network scale, long learning and training time and easy knowledge "combination explosion" in practical applications of traditional algorithms which lead to network organization failure, a hierarchical fault diagnosis method of gas turbine control system based on variational mode decomposition (VMD), autoregressive model (AR) and light gradient boosting machine (LightGBM) algorithms was proposed. Firstly, the original signal was modeled by VMD-AR to obtain the most representative fault feature vector. Secondly, multiple LightGBM models were designed according to different hierarchical characteristics and fault types. Finally, the Bayesian optimization algorithm was used to optimize the hyperparameters of the hierarchical diagnosis model, and the signal to be tested was input into the model for fault diagnosis. The results show that the proposed algorithm can not only achieve a fault recognition rate of more than 95%, but also has stronger generalization ability.

Key words: gas turbine control system, hierarchical diagnosis, feature extraction, light gradient boosting machine

引言

燃气轮机控制系统是由大量的零部件按一定的方式、功能和要求集合而成的复杂非线性动态系统。当对其进行故障诊断,特别是用机器学习算法进行故障诊断时,如果仅用单个模型,将会出现模型规模复杂、学习训练时间过长、知识容易发生“组合爆炸”导致网络布局失败、匹配时间长等问题,不能满足系统故障诊断实际工作要求,且不利于系统学习新的知识以及对网络结构的维护^[1]。

基于模型的故障诊断方式是通过创建被诊断系统正常状态的数理模型,再分析实际值相对于目标值的偏离程度来确定故障原因^[2-4]。由于系统具有时变和不确定等成分,不宜应用在结构复杂,非线性较强的燃气轮机控制系统中。以知识为基础的故障诊断研究也被广泛关注,其原理基础是模式识别理论,先决条件是被观测目标可能发生的故障模式是一定的,进而通过对数据库中的专家经验、先验知识等有效利用,实现故障模式判别^[5-6],但有时很难提炼成规则。基于数据驱动的智能故障诊断主要通过支持向量机、极限学习机和神经网络等人工智能算法对原始信号进行数据处理后并结合一定的数学方法即可识别故障类别^[7-9]。

本文提出的分层诊断模型方法是基于数据驱动的分类方法,将燃气轮机控制系统由上层的抽象模式向下层的具象模式逐级匹配,从而减少了分类中的模式关联搜索量,高效地处理了层次结构的组合爆炸等问题。

1 燃气轮机控制系统的层次特点

燃气轮机控制系统在结构和功能上可分成几个子回路,子回路又可以再分为若干子回路,直至零部件。图1为燃气轮机控制系统的构成图。

假设燃气轮机控制系统是由限定的装置按特定关联方式组成的复杂系统,装置称为“元素”(C),元素之间的关联为“联系”(R),则系统(L)为:

$$L = C \cup R \quad (1)$$

对于复杂的系统,元素能够进一步拆分,即上层较大的元素可拆分为下层较小的元素的集合。用子集合来表示可拆分的燃气轮机控制系统层级元素,

则系统架构的层级属性可表示为:

$$L_i^k = \{L_j^{k+1}\}, k = 1, 2, \dots, z \quad (2)$$

式中: L_i^k —第 k 层第 i 个元素; j —第 i 个元素包含的子元素个数,且规定 $k=0$ 时, $L^0 = L$ 为系统的最高层次,则:

$$L_i^k = C_j^{k+1} \cup R_j^{k+1} \quad (3)$$

由于燃气轮机控制系统具有结构上的层次特点,所以系统的故障也具有层次属性。故障的这种层级特性决定了可以采用层次化诊断策略和层次化诊断模型,从而降低了燃气轮机控制系统故障诊断问题的复杂程度。

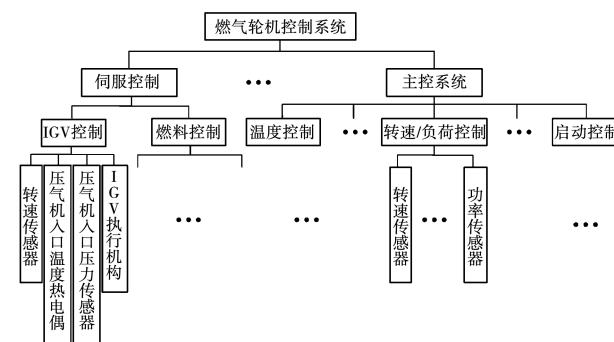


图1 燃气轮机控制系统构成图

Fig. 1 Structure diagram of gas turbine control system

2 故障类型与特征分析

依据燃气轮机控制系统的构成,最底层主要设备包括传感器与执行器,因此本文针对这两种设备进行分析。虽然传感器内部的故障形式迥异,但最后得到的结果是其运行值偏离目标值的允许范围。表1为传感器的常见故障形式^[10]。

表1 传感器的常见故障形式

Tab. 1 Common forms of sensor failure

故障形式	描述
恒增益故障	传感器输出增益减小或增大
恒偏差故障	实际信号与输出存在恒定偏差
卡死故障	不随被测量变化,保持某个值
偏移故障	输出逐渐偏离实际信号

以温度控制回路中透平排气温度热电偶为例,其部分故障如图2所示。

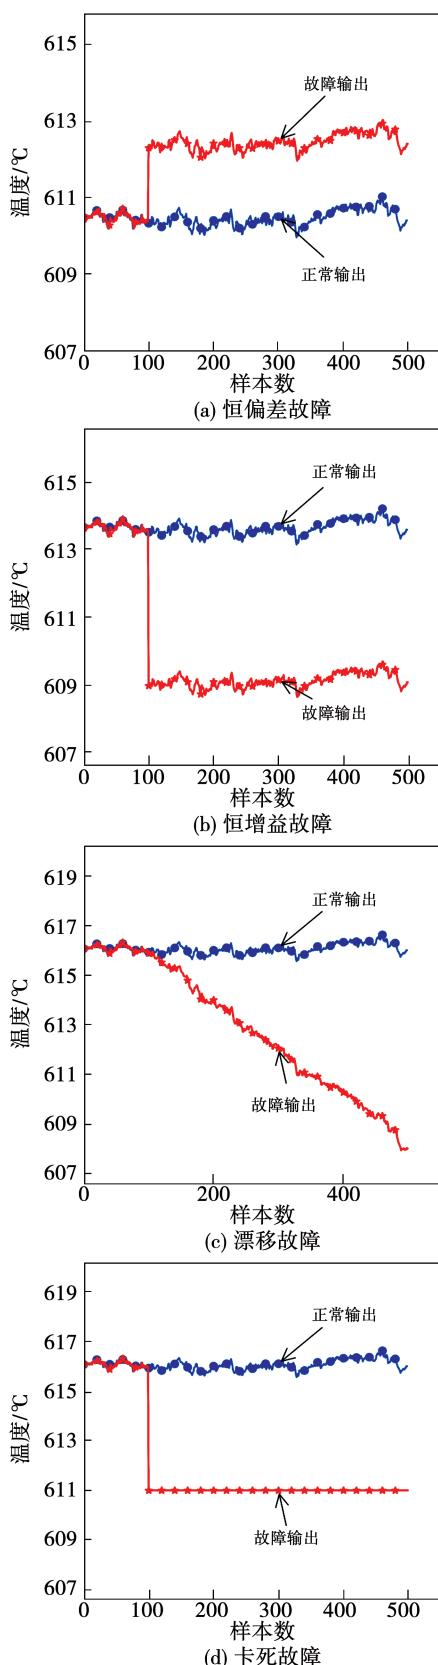


图 2 部分传感器故障示意图

Fig. 2 Schematic diagram of some sensor failures

执行器作为控制系统的执行终端组件, 常处于

高压、高温和高腐蚀性等恶劣的工作条件中, 比较容易发生故障。因此, 提升执行器本身的稳定性, 及时辨别其运行进程中潜在的故障, 是保证控制过程稳定运转的先决条件。表 2 列出了执行器的常见故障形式。部分故障的表现形式如图 3 所示。

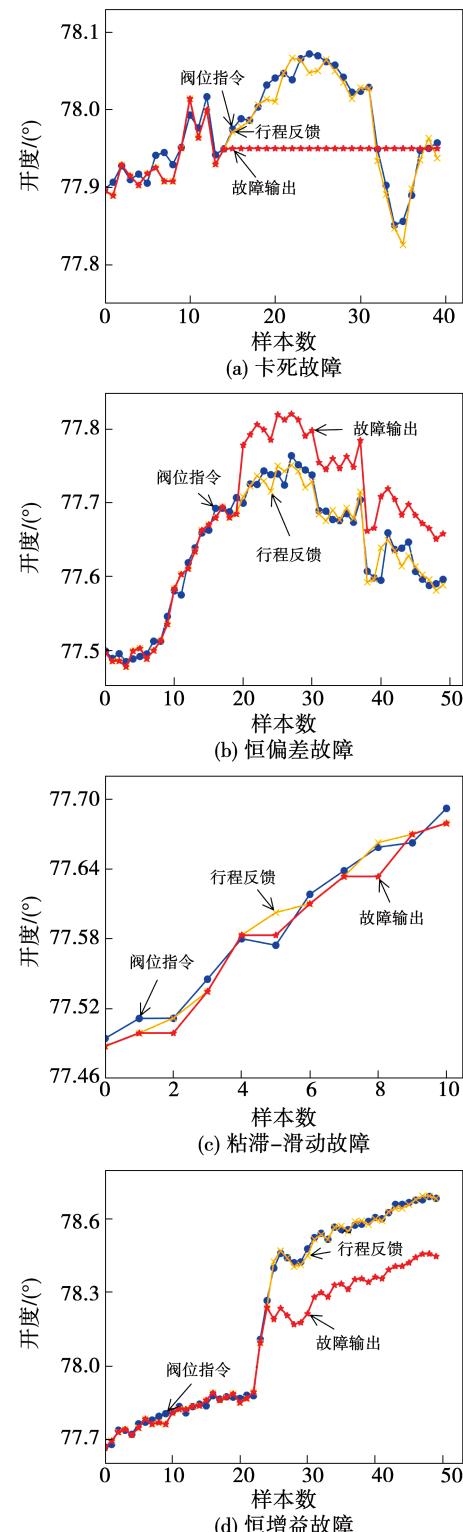


图 3 部分执行器故障示意图

Fig. 3 Schematic diagram of some actuator failures

表 2 执行器的常见故障形式

Tab. 2 Common forms of actuator failure

故障形式	描述
卡死故障	执行器输出阀位不随指令变动
恒偏差故障	阀位指令与输出阀位偏离过大
恒增益故障	执行器输入、输出增益变化
粘滞 - 滑动故障	执行器动作的卡涩现象

3 机器学习与分层故障诊断

3.1 基于 VMD-AR-LightGBM 算法的单层故障诊断模型

为了充分提取非平稳故障特征,提出了基于 VMD-AR 模型的特征提取方法。该方法的具体计算步骤为:

(1) 构建初始特征集。剔除异常数据以及冗余数据,并对数据进行归一化处理。

(2) 利用 VMD 将信号按式(4)分解为具有有限带宽的模态分量集^[11]。

$$\begin{cases} \min \left\{ \sum_k \left\| \left[\partial_t \left(\delta(t) + \frac{j}{\pi t} \right) * s_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \sum_{k=1}^K s_k(t) = x(t) \end{cases} \quad (4)$$

式中: $\delta(t)$ —单位脉冲数; ω_k —信号的中心频率; $s_k(t)$ —燃机控制系统故障信号 $x(t)$ 的第 k 个模态时域信号; ∂_t —偏导计算; K —模态分量集的总数; t —某时刻; $*$ —卷积计算; j —虚数单位。

(3) 对所有模态分量按式(5)进行 AR 建模,式(5)称为 w 阶 AR 模型。并采用最小信息量准则(Akaike information criterion, AIC)来对 AR 模型阶次进行判断^[12]。AIC 判据如式(6)所示。

$$\begin{cases} x_t = \phi_1 x_{t-1} + \cdots + \phi_w x_{t-w} + a_t \\ \phi_w \neq 0 \end{cases} \quad (5)$$

式中: w —模型的阶数; a_t —互不干扰的白噪声序列; ϕ —模型系数; x_t —模型变量在时刻 t 的值。

$$AIC(w) = Q \ln \sigma_w^2 + 2w \quad (6)$$

式中: σ_w^2 —模型预报误差方差; Q —序列元素个数; $AIC(w)$ —函数值。

(4) 由计算获取的 AR 模型参数组成故障数据

的特征向量。

(5) 基于主元分析(Principle component analysis, PCA)从所有特征属性中提取故障特征,并以之作为最终的故障特征向量。

(6) 采用贝叶斯优化算法对 LightGBM 分类模型的超参数进行选择。

(7) 将测试集数据代入最优 LightGBM 分类器,得到诊断结果。

基于 VMD-AR-LightGBM 算法的单层故障诊断模型流程如图 4 所示。

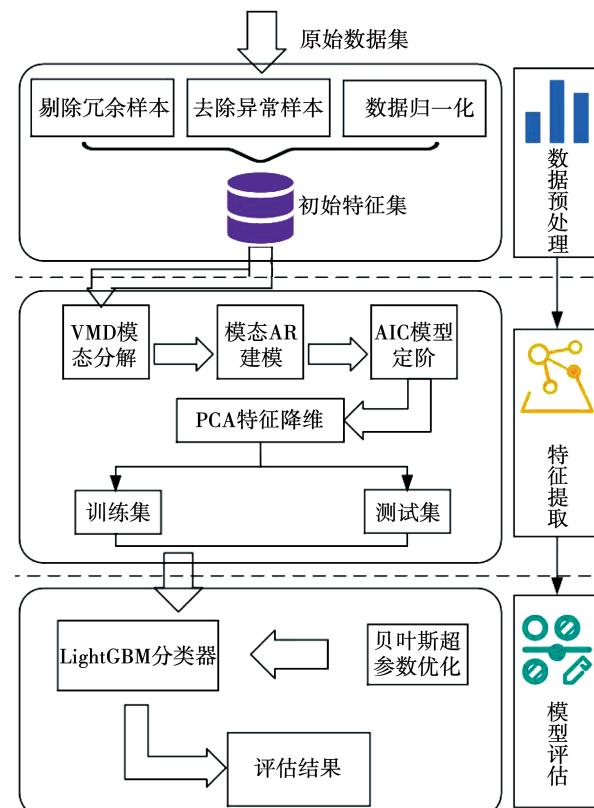


图 4 单层故障诊断流程图

Fig. 4 Single layer fault diagnosis flowchart

3.2 分层诊断模型

在故障诊断中,标准故障界限越具体越好,因为类别越明确,则燃气轮机控制系统分类就越具体。假设燃气轮机控制系统有 L_1, L_2, \dots, L_n 个状态,而每一个状态又可定义 z 个值,那么被诊断的状态空间就有 z^n 个标准模式。当 z, n 较大时,这个标准模式的数量就很大。因此,针对这类问题,宜选择分层诊断策略。图 5 是分层诊断模型结构。

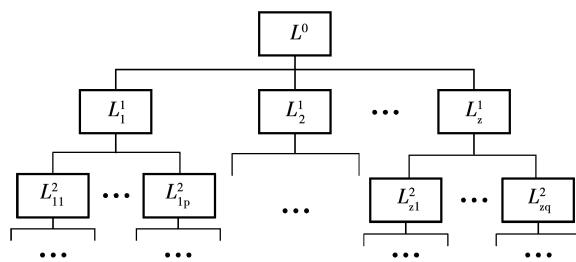


图 5 分层诊断模型结构

Fig. 5 Hierarchical diagnostic model structure

依照分层诊断模型的结构特点,可以构造如图 6 所示的分层诊断模型。顶层 LightGBM 模型与主系统相对应,第二层 LightGBM 模型与低层子回路对应,以下则与更低层的子回路对应。其核心要素是层次分类诊断模型中的各个子回路 L_i^k 皆通过一个相应的 LightGBM 子模型 G_i^k 来完成其层内故障诊断。同时模型采用全局并行的诊断方式,弥补了分层模型中可能存在的诊断“遗漏”与“误诊”问题。

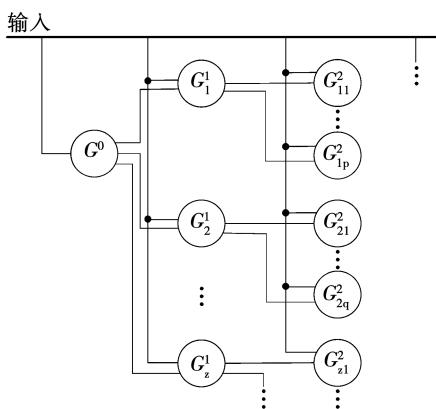


图 6 分层诊断模型

Fig. 6 Hierarchical diagnostic model

4 算例分析

4.1 实验准备

根据此模型策略,对进口可转导叶 (Inlet guide vanes, IGV) 回路建立分层诊断模型。该模型分为 4 个层次,顶层用以划分正常与故障状态;第 2 层为元素层,用以判断故障设备;第 3 和第 4 层为平行关系,其输出结果为各元素的故障原因。各层模型分别取名为 $n-f$ 层、元素层、元 1 层、元 2 层。IGV 回

路中传感器和执行器常见故障形式如表 1 和表 2 所列。为了验证方法的有效性,以某燃气轮机电厂的运行数据作为数据来源,选取压气机入口温度热电偶恒偏差故障、漂移故障以及 IGV 执行器的恒增益及恒偏差故障进行数据模拟验证。

4.2 特征提取与主元分析

对每个故障信号进行 VMD 分解,分解时有两个参数需要设置,即分解模态数 K 与惩罚参数 α 。为了实现各频带分量的充分分离,试验中 K 取 10, α 取默认值 2 000。由于不同信号的大小差距较大,采用如下公式进行归一化处理:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

式中: X —故障信号; X_{\min} 、 X_{\max} —信号中最小值和最大值; X_{norm} —归一化后信号。

图 7 为归一化后的压气机入口温度热电偶恒偏差故障信号,经过 VMD 分解得到的 10 个无量纲本征模态函数 (Intrinsic mode functions, IMF) 分量。

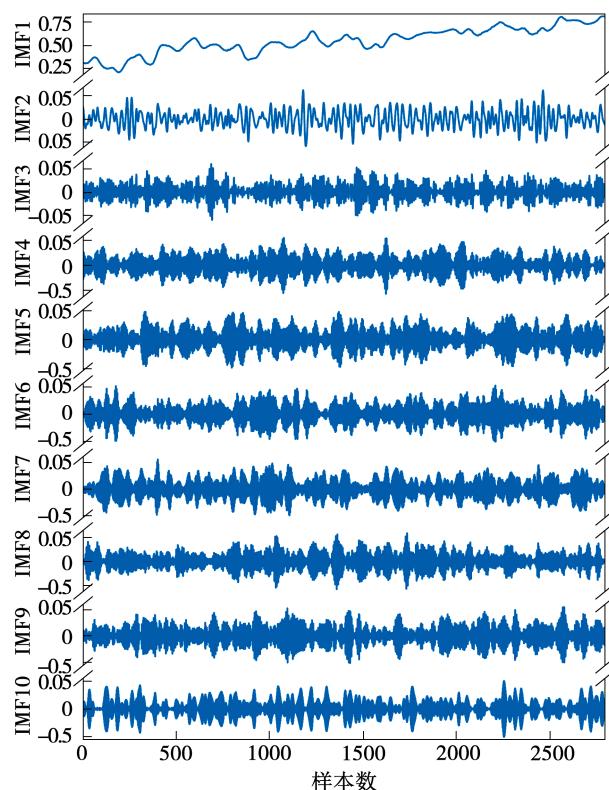


图 7 各模态分量波形

Fig. 7 Each mode component waveform

对分解后的所有分量建立 AR 模型,以故障样本的 VMD 分解结果作为参考确定 AR 模型阶数,AIC 函数值随阶数 p 的变化如图 8 所示。

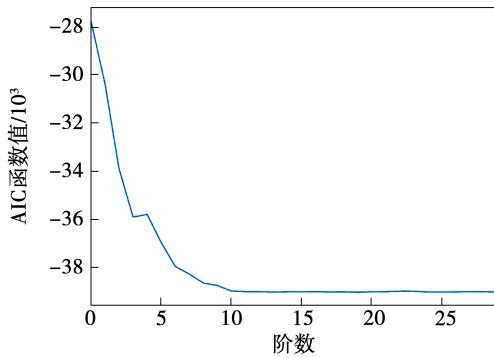


图 8 AIC 函数随阶数 p 的变化曲线

Fig. 8 Variation curve of AIC function with order p

从图中可以看出,阶数由 1 增加到 10 时函数值逐渐减小,增至 10 后随着阶数 p 的增加函数已经无明显变化,故该试验中 AR 模型阶数选为 10。建立模型后,提取模型参数并由此构成故障特征向量。

为了直观展示所提特征向量的有效性,对模型所得故障特征向量进行主元分析,得到故障特征向量主元分布,如图 9 所示。

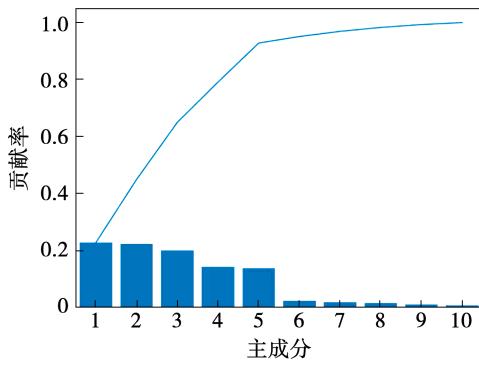


图 9 故障特征向量主元分布

Fig. 9 Pivot distribution of fault eigenvectors

从图中可以看出,故障特征向量的主要成分集中在前 5 个主元。因此以之构成最终的故障特征向量。

4.3 分类器效果对比

为了验证不同分类器分类效果,采用 LightG-

BM^[13]、支持向量机(Support vector machine,SVM)、随机森林(Random forest,RF)、K-近邻(K-nearest-neighbor,K-NN)、基于树的管道优化工具(Tree-based pipeline optimization tool,TPOT)^[14]5 种算法,每种分类器训练时均采用留一法交叉验证,以综合识别率作为指标。5 种分类器均采取默认参数。

同时,为了验证特征提取方法的有效性,对比试验采用 VMD 与经验模态分解(Empirical mode decomposition,EMD)分解故障信号后提取的时域特征。在 EMD 分解的结果中,原始信号的主要成分集中在前 5 个分量,因此试验中仅对 EMD 分解后的前 5 个分量计算时频特征,VMD 的分解模态数 K 取 5, α 取默认值 2 000。

对于每种分类器,计算流程如下:(1) 将样本按式(7)进行归一化处理;(2) 采用 3 种方式对归一化后的样本进行特征提取;(3) 对故障类型进行编号,作为分类目标;(4) 输入分类器,并采用“5 折”交叉验证,得到最优识别率。

各诊断层中,采取不同特征提取方式时,各分类器的故障识别率如表 3~表 6 所示。

表 3 $n-f$ 层故障识别率(%)

Tab. 3 Fault recognition rate of $n-f$ layer(%)

分类器	EMD	VMD	VMD + AR
LightGBM	90.68	92.05	92.37
RF	89.42	90.58	91.14
TPOT	91.36	92.05	92.73
K-NN	88.09	89.83	90.13
SVM	87.86	88.29	88.57

表 4 元素层故障识别率(%)

Tab. 4 Fault recognition rate of element level(%)

分类器	EMD	VMD	VMD + AR
LightGBM	92.86	92.57	93.79
RF	90.92	90.73	92.46
TPOT	91.56	93.11	93.35
K-NN	89.51	91.19	92.27
SVM	89.28	89.60	89.71

表 5 元 1 层故障识别率(%)

Tab. 5 Fault recognition rate of element-layer 1 (%)

分类器	EMD	VMD	VMD + AR
LightGBM	91.43	92.15	92.85
RF	89.75	90.29	91.52
TPOT	91.13	92.28	92.37
K - NN	90.54	91.10	91.97
SVM	89.04	89.63	90.56

表 6 元 2 层故障识别率(%)

Tab. 6 Fault recognition rate of element-layer 2 (%)

分类器	EMD	VMD	VMD + AR
LightGBM	91.52	93.22	93.92
RF	90.12	91.27	91.76
TPOT	92.13	92.85	93.55
K - NN	91.23	90.21	91.61
SVM	90.15	89.32	90.82

分析表 3 ~ 表 6 结果可知,在 $n-f$ 层中 LightGBM 分类器相比 RF, K - NN, SVM 3 种分类器具有较好的识别率,与 TPOT 分类器效果相近,但 TPOT 分类器在模型训练中需要消耗大量时长。从特征提取因素分析,所提方法的识别率最高。其中,基于 EMD 与 VMD 分解的时域特征提取方法需对各分量分别计算所有时域特征参数,且难以反映系统蕴含模型的内部特征。而所提方法通过对 VMD 的分解结果进行 AR 建模,仅需一次求解即可得到所有分量的特征信息,同时能充分挖掘出系统内部的变化规律,取得更好的诊断精度。

4.4 分层模型的参数调优

根据表 3 ~ 表 6 中各个分类器的性能分析,本文采用贝叶斯优化算法对各层分类器进行超参数选择^[15]。具体步骤如下:

(1) 根据要优化的超参数,设置 n 个初始点 $X_n = [x_1, x_2, \dots, x_n]$,作为模型的初始化超参数,并带入 LightGBM 模型进行训练。超参数描述信息如表 7 所示。以准确率作为目标函数 f ,并计算 X_n 在目标函数上的响应值 $Y_n = [y_1, y_2, \dots, y_n]$,构建初始超参数数据集 $D = \{(x_1, y_1) \dots (x_n, y_n)\}$ 。

表 7 超参数描述

Tab. 7 Hyperparameter description

超参数	搜索范围	参数标签
模型最大深度	(2,35)	x_1
叶子节点树	(30,135)	x_2
下采样	(0.8,1.0)	x_3
随机特征选择	(0.6,1.0)	x_4
L1 正则化项的权重	(0.0,1.0)	x_5
L2 正则化项的权重	(0.0,1.0)	x_6

(2) 利用 D 数据集,建立高斯过程(Gaussian process, GP)。

(3) 基于 GP 模型,通过采集函数 $u(x)$ 进行采样点 x_{n+1} 的计算。

(4) 获得第 t 个观察点的数据 $(x_{t+1}, f(x_{t+1}))$ 。

(5) 将最有潜力评估点添加到数据集 D 。 $D \leftarrow D \cup (x_{t+1}, y_{t+1})$ 。

(6) 送入诊断 LightGBM 模型训练,并在测试集上判断模型是否满足精度要求,若满足则停止迭代,确定超参数为 X_{t+1} ;若不满足循环执行步骤(2) ~ (6)。

图 10 为 $n-f$ 层 LightGBM 模型参数随迭代次数的搜索演变过程。随着优化的进展,贝叶斯方法更关注有价值超参数值,即在交叉验证中得到的最优识别率的值。其在图 10 中用黑色星星表示。

通过上述方式分别对每层模型进行参数选择,并得到如表 8 所示的最优参数组合及评价指标。

表 8 最优参数组合

Tab. 8 Optimal parameter combination

诊断层	参数组	识别	特异	灵敏
		率/%	度/%	度/%
$n-f$ 层	[12,47,0.93,0.90,0.18,0.27]	95.65	95.27	95.03
元素层	[7,12,0.93,0.92,0.51,0.35]	94.98	95.67	94.45
元 1 层	[5,6,0.82,0.81,0.92,0.72]	95.27	96.38	95.41
元 2 层	[3,14,0.88,0.65,0.17,0.33]	95.51	95.83	94.91

4.5 模型评估

采用优化后的各层模型对原测试集进行诊断的精确性很高,为进一步对模型进行分析,构建新的测试集,将其输入模型并统计其分类结果,得到测试数

据的接受者操作特性(Receiver operating characteristic, ROC)曲线,如图 11 所示。ROC 曲线刻画了真正率和假正率之间的关系。一般来讲,曲线越往外凸,模型越好。曲线下面积(Area under the curve, AUC)可作为评估模型的指标。该值越接近 1 模型越好,该值小于 0.5 模型较差。

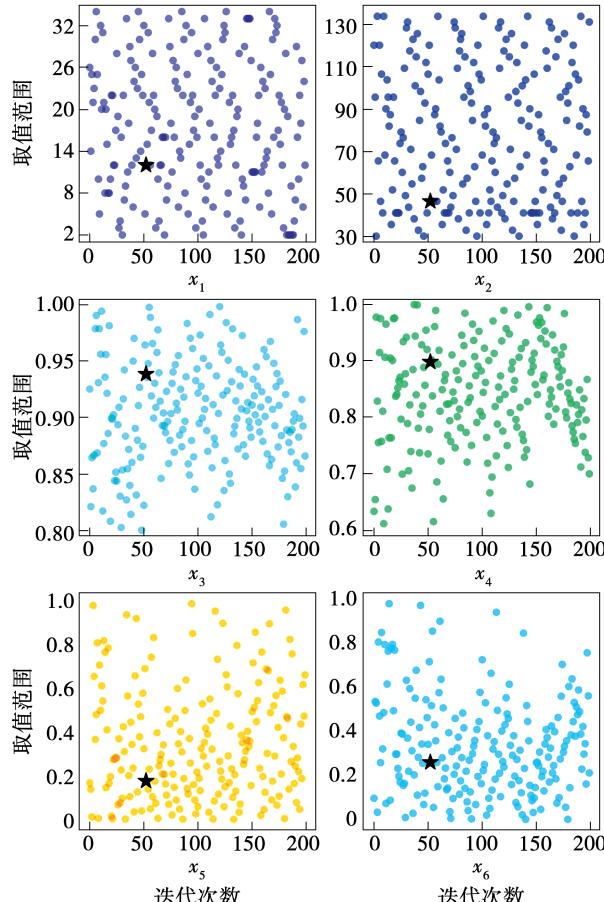


图 10 参数优化过程可视化

Fig. 10 Parameter optimization process visualization

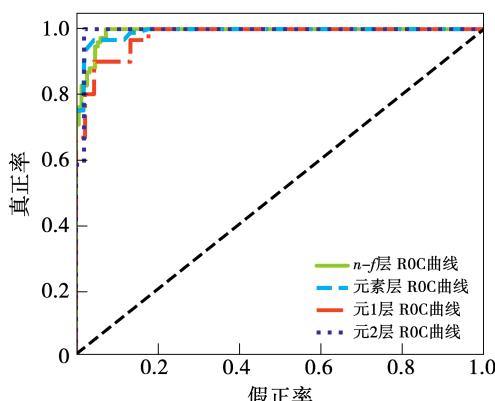


图 11 各层 ROC 曲线

Fig. 11 ROC curve of each layer

从图 11 中可以看出,各曲线更靠近左上角,可知,模型中各分类器具有较高灵敏度和识别率。同时,可以看出模型泛化能力较强,通过较少样本的学习即可得到整个原始信号的深层特征。

5 结 论

(1) 根据燃气轮机控制系统传感器及执行器常见故障类型的故障描述模拟故障,并对信号进行归一化处理,消除了信号幅值对后续特征提取造成的影响。

(2) 引入 VMD-AR 算法对故障特征进行提取,充分揭示了信号所蕴含的结构和参数上的变化规律。

(3) 通过多种机器学习算法对不同组合的特征提取方法进行分析,验证了所提方法的优越性。

(4) 针对 LightGBM 诊断性能受参数影响的问题,采用贝叶斯优化器对其超参数进行优化,使得模型故障识别率高达 95%。

参 考 文 献:

- [1] 王 瑶,孙 秦.一种解决混联系统组合爆炸问题的贝叶斯网络[J].系统工程理论与实践,2019,39(2):520–530.
WANG Yao, SUN Qin. A Bayesian network to solve the combinatorial explosion problem of hybrid systems[J]. Systems Engineering Theory and Practice, 2019, 39(2): 520–530.
- [2] 张文广,陆 瑶,王维建,等.重型燃气轮机 IGV 系统建模与故障仿真[J].自动化仪表,2022,43(2):38–43,50.
ZHANG Wen-guang, LU Yao, WANG Wei-jian, et al. Modeling and fault simulation of heavy-duty gas turbine IGV system[J]. Automation Instrumentation, 2022, 43(2): 38–43, 50.
- [3] 靳尧飞,应雨龙,李靖超,等.基于模型与数据混合驱动的燃气轮机气路故障诊断方法[J].热力发电,2021,50(9):66–71,93.
JIN Yao-fei, YING Yu-long, LI Jing-chao, et al. Gas turbine gas path fault diagnosis method based on model and data hybrid drive [J]. Thermal Power Generation, 2021, 50(9): 66–71, 93.
- [4] 王 磊.燃气轮机控制系统液压执行器故障诊断试验研究[D].北京:华北电力大学,2021.
WANG Lei. Research on fault diagnosis test of hydraulic actuator of gas turbine control system[D]. Beijing: North China Electric Power University, 2021.

University, 2021.

- [5] 温广瑞,黄子灵,张平,等. D-S 证据理论及其在燃气轮机系统诊断中的应用研究[J]. 热能动力工程, 2021, 36(9): 228–236.

WEN Guang-rui, HUANG Zi-ling, ZHANG Ping, et al. Research on D-S evidence theory and its application in gas turbine system diagnosis[J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(9): 228–236.

- [6] 王仲,顾煜炯,韩旭东,等. 燃气轮机健康维护知识获取与表达推理的框架[J]. 中国机械工程, 2021, 32(2): 235–241.

WANG Zhong, GU Yu-jiong, HAN Xu-dong, et al. A framework for knowledge acquisition and expressive reasoning for gas turbine health maintenance[J]. China Mechanical Engineering, 2021, 32(2): 235–241.

- [7] 唐竞鹏,王红军,钟建琳,等. 基于 WDCNN-SVM 深度迁移学习的燃气轮机转子故障诊断方法[J]. 电子测量与仪器学报, 2021, 35(11): 115–123.

TANG Jing-peng, WANG Hong-jun, ZHONG Jian-lin, et al. Gas turbine rotor fault diagnosis method based on WDCNN-SVM deep transfer learning[J]. Journal of Electronic Measurement and Instrument, 2021, 35(11): 115–123.

- [8] 涂雷,茅大钧,李伯勋,等. 基于 CGABC-SVM 的燃气轮机气路故障诊断[J]. 汽轮机技术, 2020, 62(5): 377–380.

TU Lei, MAO Da-jun, LI Bo-xun, et al. Gas turbine gas path fault diagnosis based on CGABC-SVM[J]. Steam Turbine Technology, 2020, 62(5): 377–380.

- [9] 蒋龙陈,王红军,张顺利,等. 基于卷积神经网络的燃气轮机故障诊断研究[J]. 北京信息科技大学学报(自然科学版), 2020, 35(5): 25–29.

JIANG Long-chen, WANG Hong-jun, ZHANG Shun-li, et al. Research on gas turbine fault diagnosis based on convolutional neural network[J]. Journal of Beijing Information Science and Technology University (Natural Science Edition), 2020, 35(5): 25–29.

- [10] 尹峰. 电厂热控系统故障分析与可靠性控制[M]. 北京: 中国电力出版社, 2016.

YIN Feng. Fault analysis and reliability control of thermal control system of power plant [M]. Beijing: China Electric Power Press, 2016.

- [11] 肖洒,陈波,沈道贤,等. 改进 VMD 和阈值算法在局部放电去噪中的应用[J]. 电子测量与仪器学报, 2021, 35(11): 206–214.

XIAO Sa, CHEN Bo, SHEN Dao-xian, et al. Application of improved VMD and threshold algorithm in partial discharge denoising[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(11): 206–214.

- [12] 袁晓惠,周世权,王岳,等. 删失数据下自回归模型的贝叶斯变量选择[J]. 数理统计与管理, 2021, 40(5): 833–841.

YUAN Xiao-hui, ZHOU Shi-quan, WANG Yue, et al. Bayesian variable selection for autoregressive models under censored data [J]. Mathematical Statistics and Management, 2021, 40(5): 833–841.

- [13] 刁宁昆,马怀祥,刘锋. 一种改进 LeNet5 结合 LightGBM 的滚动轴承故障诊断方法[J]. 国外电子测量技术, 2022, 41(1): 140–145.

DIAO Ning-kun, MA Huai-xiang, LIU Feng. A fault diagnosis method for rolling bearings based on improved LeNet5 combined with LightGBM[J]. Foreign Electronic Measurement Technology, 2022, 41(1): 140–145.

- [14] WAN J, YU X, GUO Q. LPI radar waveform recognition based on CNN and TPOT[J]. Symmetry, 2019, 11(5): 725–739.

- [15] 石怀涛,尚亚俊,白晓天,等. 基于贝叶斯优化的 SWDAE-LSTM 滚动轴承早期故障预测方法研究[J]. 振动与冲击, 2021, 40(18): 286–297.

SHI Huai-tao, SHANG Ya-jun, BAI Xiao-tian, et al. Research on early failure prediction method of SWDAE-LSTM rolling bearing based on Bayesian optimization[J]. Vibration and Shock, 2021, 40(18): 286–297.

(姜雪梅 编辑)