

文章编号:1674-7607(2021)06-0460-08

DOI:10.19805/j.cnki.jcspe.2021.06.005

基于 XGBoost 算法的汽轮机转子故障原因定位方法

王新伟¹, 钱虹^{1,2}, 冷述文³, 杨宝清⁴

(1. 上海电力大学 自动化工程学院, 上海 200090; 2. 上海市电站自动化技术重点实验室, 上海 200090;
3. 华能山东发电有限公司, 济南 250014; 4. 华能临沂发电公司, 山东临沂 276016)

摘要: 提出了基于 XGBoost 算法的汽轮机转子故障原因定位方法, 首先对由故障类型和相关参数组成的原始样本集进行特征分析, 评估各特征的重要度, 然后利用 XGBoost 算法构建汽轮机转子故障原因定位模型, 利用转子故障数据对模型进行训练和测试, 最后将具体的故障原因链接到故障知识库, 采取相应的故障修复措施。结果表明: 相比随机森林(RF)和梯度提升决策树(GBDT)模型, XGBoost 模型可有效识别汽轮机转子 3 种故障类型下的 9 种故障原因, 其分类准确率更高。

关键词: 汽轮机转子; XGBoost 算法; 故障类型; 运行参数; 故障原因定位; 故障知识库

中图分类号:TK267 文献标志码:A 学科分类号:470.30

Fault Location of Steam Turbine Rotor Based on XGBoost Algorithm

WANG Xinwei¹, QIAN Hong^{1,2}, LENG Shuwen³, YANG Baoqing⁴

(1. School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;
2. Shanghai Key Laboratory of Power Station Automation Technology, Shanghai 200090, China;
3. Huaneng Shandong Power Generation Co., Ltd., Jinan 250014, China; 4. Huaneng Linyi Power Generation Company, Linyi 276016, Shandong Province, China)

Abstract: A fault location method of steam turbine rotor was proposed based on XGBoost algorithm. Firstly, the characteristics of the original sample set composed of fault types and related parameters were analyzed to evaluate the importance of each feature. Then, the XGBoost algorithm was used to build fault location model of steam turbine rotor, so as to use rotor fault data to train and test the model. Finally, specific fault causes were linked to the fault knowledge base, based on which, corresponding fault repair measures were taken. Results show that compared with random forest (RF) and gradient boosting decision tree (GBDT) model, XGBoost model can identify 9 fault causes of turbine rotor under three types of faults effectively, which shows higher classification accuracy.

Key words: steam turbine rotor; XGBoost algorithm; fault type; operation parameters; fault location; fault knowledge base

汽轮机承担着能源转换的作用,是电站最重要的旋转设备。由于汽轮机结构和系统的复杂性,以

收稿日期:2020-08-10 修订日期:2020-12-31

基金项目:上海市 2019 年度“科技创新行动计划”高新技术领域资助项目(19511103700);上海市科委地方能力建设资助项目(18020500900)

作者简介:王新伟(1995—),男,山东临沂人,硕士研究生,研究方向为核电站汽轮机智能故障诊断技术。电话(Tel.):13122360121;
E-mail:2568076366@qq.com。

及运行环境的特殊性,导致其故障发生率较高^[1-2],因此在复杂环境下实现精准快速的故障识别和故障原因定位,从而采取有效措施及时修复故障对于保证汽轮机系统的安全稳定运行具有重要意义。

目前,汽轮机故障诊断技术在信号采集与分析^[3]、故障机理^[4-5]、故障特征提取^[6-9]和故障模式识别^[10-13]等方面取得较多进展。然而,关于如何准确快速地进行故障原因定位识别的研究较少。目前,在实际的故障诊断过程中,主要依靠经验进行故障原因分析。大量汽轮机故障案例表明,不同故障原因导致的不同类型故障发生时,会伴随运行参数的异常变化,诊断专家在进行故障原因分析时可通过这些异常来确定发生故障的具体原因^[14],然而这些具有较强区分性的运行参数故障特征却很少被用于建立智能诊断模型。因此,通过挖掘汽轮机运行参数的故障特征进行故障原因定位识别,具有现实的价值意义。然而,汽轮机运行参数很多,数据集样本较大,且各运行参数之间可能存在相互关联和相互耦合关系。因此,可使用机器学习算法处理和分析汽轮机运行参数的相关数据,提高故障原因定位模型的分类准确率。钟敏慧等^[15]将梯度提升决策树(GBDT)模型用于铁路事故类型的预测,并根据模型中的特征重要度排序实现了铁路事故成因分析。极端梯度提升(XGBoost)算法在GBDT模型的基础上对损失函数、正则化和并行处理等方面进行改进,具有更强的分类能力^[16]。XGBoost算法具有不易被噪声干扰、准确性高和运算速度快等优点,可对多维和多特征数据进行快速有效处理。在旋转机械故障预测^[17]和故障诊断^[18-19]等方面已有关于XGBoost算法的研究。

笔者首次基于XGBoost算法并结合运行参数对不同汽轮机故障类型进行多种故障原因定位,利用汽轮机转子故障类型和运行参数的异常变化特征,对多种故障原因进行定位识别。首先,对包含故障类型和汽轮机运行参数的原始数据集进行预处理,提升模型样本的适应性;将训练集样本送入XGBoost模型进行建模,采用网格搜索法优化模型参数,以提高分类准确率;通过测试集样本验证所提方法的有效性;最后,针对具体故障原因,根据对应的故障知识库提供故障修复措施,从而提高故障诊断和故障修复的效率。

1 XGBoost 算法

为实现精准快速的故障原因定位,使用XGBoost算法构建汽轮机转子故障原因定位模型。

XGBoost模型是基于树集成的学习模型,其基分类器是分类树和回归树(CART)^[20]。

首先,对采集的汽轮机转子故障原始数据集 $D = \{(\mathbf{X}_i, y_i)\}$ 进行预处理,其中 y_i 表示实际故障原因类别, \mathbf{X}_i 为第 i 个样本的特征参数矩阵, \mathbf{X}_i 由故障类型 $F_i (i=1, 2, \dots, p)$ 和运行参数矩阵 $\mathbf{x}_i (\mathbf{x}_i = [x_{1,i}, x_{2,i}, \dots, x_{l,i}])$ 2部分构成,即

$$\mathbf{X}_i = [F_i \quad x_{1,i} \quad x_{2,i} \quad \dots \quad x_{l,i}] \quad (1)$$

其中, p 为故障类型数量; l 为运行参数的数量。

将预处理后的数据集进行随机分类,得到含有 n 个样本和 m 个特征参数的训练集 $D' = \{(\mathbf{X}_i, y_i)\}$, $\mathbf{X}_i \in \mathbf{R}_m, y_i \in \mathbf{R}$,其中 \mathbf{R}_m 为含有 m 个特征参数的特征集。

将训练集代入到XGBoost模型中对其进行训练,可得到由多个决策树函数相加的集成模型。

$$\hat{y}_i = \sum_{k=1}^K f_k(\mathbf{X}_i), f_k \in \Gamma \quad (2)$$

式中: \hat{y}_i 为模型输出的故障原因类别; K 为棵数; Γ 为分类回归树CART的函数空间; f_k 为函数空间 Γ 中的某个函数。

模型目标函数 L 为:

$$L = \sum_{i=1}^n l_s(y_i, \hat{y}_i) + \sum_{i=1}^n \Omega(f_k) \quad (3)$$

式中: l_s 为损失函数项; Ω 为正则项。

设第 i 个样本在第 t 次迭代时的预测值 $\hat{y}_{i,t} = \hat{y}_{i,t-1} + f_t(\mathbf{X}_i)$,在每次迭代中添加新函数 f_t ,以最大程度地减小第 t 次迭代时的目标函数 L_t 。

$$L_t = \sum_{i=1}^n l_s[y_i, \hat{y}_{i,t-1} + f_t(\mathbf{X}_i)] + \Omega(f_t) \quad (4)$$

为快速优化目标,对式(4)进行泰勒级数展开,并移除常数项,得到第 t 步的简化目标函数 \tilde{L}_t 。

$$\tilde{L}_t \approx \sum_{i=1}^n \left[g_i f_t(\mathbf{X}_i) + \frac{1}{2} h_i f_t^2(\mathbf{X}_i) \right] + \Omega(f_t) \quad (5)$$

其中, $g_i = \frac{\partial l_s(y_i, \hat{y}_{i,t-1})}{\partial \hat{y}_{i,t-1}}$; $h_i = \frac{\partial^2 l_s(y_i, \hat{y}_{i,t-1})}{\partial \hat{y}_{i,t-1}^2}$ 。

定义 $I_j = \{i | q(\mathbf{X}_i) = j\}$ 为叶节点 j 的样本集,其中 $q(\mathbf{X}_i)$ 为树结构,将正则项 $\Omega(f_k)$ 展开为:

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (6)$$

式中: T 为叶节点的数量; ω_j 为叶节点 j 的权重; γ 和 λ 均为正则化系数。

将式(6)代入式(5),得:

$$\tilde{L}_t = \sum_{j=1}^T \left[\omega_j \sum_{i \in I_j} g_i + \frac{\omega_j^2}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) \right] + \gamma T \quad (7)$$

对于固定的树结构 $q(\mathbf{X}_i)$,叶节点 j 的最优化权重 ω_j^* 和对应的最优化目标函数 $\tilde{L}_t(q)$ 分别为:

$$\omega_j^* = \frac{-\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (8)$$

$$\tilde{L}_t(q) = -\frac{1}{2} \sum_{j=1}^T \left[\left(\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \right)^2 / \left(\frac{\sum_{i \in I_j} h_i}{\sum_{i \in I_j} h_i + \lambda} \right) \right] + \gamma T \quad (9)$$

式(9)为评价树结构 q 的评分函数, $\tilde{L}_t(q)$ 越小, 说明树结构越好。通常, 不可能完全枚举出所有可能的树结构, 故从 1 个叶节点开始反复添加分支。假设 I_L 和 I_R 分别为分裂后左、右子节点的实例集, 设 $I = I_L \cup I_R$, 则分裂后的结构损失 L_s 可用来确定是否分裂以及分裂候选点。

$$L_s = \frac{1}{2} \left[\frac{\left(\sum_{i \in I_L} g_i \right)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{\left(\sum_{i \in I_R} g_i \right)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{\left(\sum_{i \in I} g_i \right)^2}{\sum_{i \in I} h_i + \lambda} \right] - \gamma \quad (10)$$

叶节点的分裂是基于特征参数(即模型的输入变量)进行的, 某特征参数被应用于叶节点分裂的次数可认为是该特征参数的重要度得分, 反映了该特征参数与输出结果之间的相关性^[21]。因此, 可根据特征参数重要度得分来选择 XGBoost 模型的输入变量。XGBoost 模型的流程图见图 1。

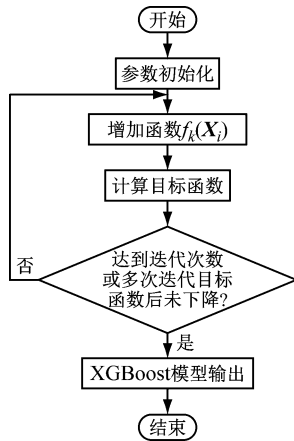


图 1 XGBoost 模型的流程图
Fig. 1 Flowchart of the XGBoost model

2 基于 XGBoost 算法的汽轮机转子故障原因定位

在已知故障类型的基础上, 基于 XGBoost 算法的汽轮机转子故障原因定位结合了故障类型和相关运行参数信息, 对多种故障原因进行定位识别, 其流程图见图 2。

汽轮机转子故障原因定位方法如下: 获取汽轮机转子故障类型和运行参数数据, 组成原始数据集; 对原始数据集进行数据预处理与特征工程构建; 将预处理后的数据集进行随机分类, 得到训练集样本

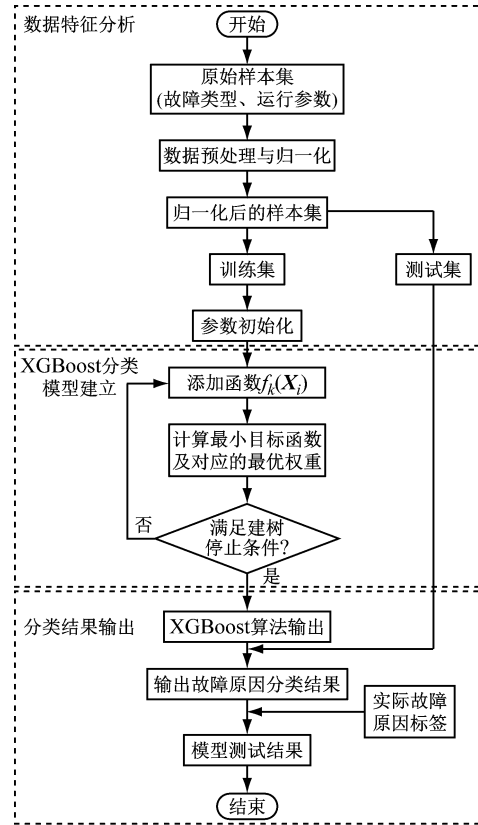


图 2 基于 XGBoost 算法的汽轮机转子故障原因定位流程图
Fig. 2 Flowchart of fault location of steam turbine rotor based on XGBoost algorithm

和测试集样本; 利用训练集样本构建 XGBoost 模型, 并优化模型参数, 提高模型分类的准确率; 利用测试集样本对 XGBoost 模型进行测试, 输出测试集分类结果, 结合原始数据集实际故障原因类别标签得到模型分类的准确率; 针对不同原因导致的故障, 链接到相应的故障知识库, 采取对应措施快速修复故障; 无法确定具体原因时, 通过总结故障案例列出可能的故障原因, 并按照原因导致故障发生的次数进行排序, 检修时优先检查次序靠前的故障原因。

3 实例分析

3.1 数据来源

以汽轮机高压转子动静碰摩故障(F1)、质量不平衡故障(F2)和自激振荡(包括油膜半速涡动和油膜振荡)故障(F3)为对象, 整理汇总电厂 330 MW 机组 3 种故障相关的运行参数数据^[13](450 组)进行实例验证。各故障原因和类别标签见表 1。

3.2 故障原因数据特征分析

特征分析的目标是最大限度地从原始数据中提取特征, 其有效性很大程度上决定了模型的准确率。特征处理是特征工程的核心部分, 包括数据预处理、特征选择和降维等操作^[17]。

表 1 故障原因和类别标签

Tab. 1 Fault causes and category labels

故障类型	原因	样本数量	类别标签
F1	汽缸变形	50	F11
	机组加负荷过快	50	F12
	低负荷停留时间过长	50	F13
	转子与油挡发生动静碰摩	50	F14
F2	轴承座刚度较差	50	F21
	转动部件断裂和脱落	50	F22
	其他原因	50	F23
F3	轴承稳定性较差	50	F31
	轴颈扰动过大	50	F32

3.2.1 特征参数选择

选取与 F1、F2 和 F3 相关性较高的 10 个运行参数,主要包括高压缸轴封蒸汽温度、高压缸汽缸膨胀值等,如表 2 所示。

表 2 汽轮机高压转子故障原因特征参数

Tab. 2 Characteristic parameters of fault causes on steam turbine high pressure rotor

特征参数	编号
高压缸轴封蒸汽温度/°C	HT1
高压缸上下缸温差/K	HT2
高压缸汽缸膨胀值/mm	HE1
机组负荷变化率/(MW·min ⁻¹)	HC1
高压缸缸温/°C	HT3
高压转子润滑油温/°C	HT4
高压转子 X 方向轴承轴振基频幅值/mm	X1
高压转子 Y 方向轴承轴振基频幅值/mm	Y1
高压转子 X 方向轴承座振基频幅值/mm	X2
高压转子 Y 方向轴承座振基频幅值/mm	Y2

3.2.2 数据预处理

数据预处理主要包括数据缺失值处理、数据无量纲化(包括中心化处理和缩放处理)、分类型特征处理(字符型数据转化为数字型)和连续型特征处理等。

(1) 缺失值处理。

针对数据的缺失值,采用均值填补法来处理数值型特征,采用众数填补法来处理字符型特征。

(2) 字符型特征编码。

在原始数据集中,分类特征中的故障类型(如 F1、F2 和 F3)以及故障原因类别标签(如 F11、F12 等)均不是以数字来表现的,为了让数据适应 XGBoost 模型,必须将数据进行编码,即将字符型数据转化为数字型。对于相互独立的故障类型(F1、F2 和 F3),采用独热编码将故障类型转变为哑变量形式;对于故障原因类别标签,将其直接转化为数字形式。

(3) 数据标准化。

将特征数据 x 按均值中心化后,再按标准差缩放,则处理后数据将服从标准正态分布,即 $x \sim N(\mu, \sigma^2)$ 。

$$x^* = \frac{x - \mu}{\sigma} \tag{11}$$

式中: μ 为均值; σ 为标准差; x^* 为标准化的特征数据。

经过预处理后的数据集如表 3 所示。主要特征重要度排序见表 4。

3.3 模型训练和参数优化

将预处理后的数据样本集进行随机分类,得到训练集样本和测试集样本。利用训练集样本对 XGBoost 模型进行训练,并优化模型参数,提高模型准确率。采用网格搜索法(GS)和 k 折交叉验证^[22]确定最优 XGBoost 模型参数。模型参数的评价标准采用误差函数,误差小的参数更优。

对迭代次数进行设置。如图 3 所示,利用 5 折交叉验证得到训练集和测试集的迭代次数-误差学习曲线,对迭代次数进行估计,取迭代次数的范围为 25~75。从图 3 还可以看出,XGBoost 模型在训练集上的表现优于在测试集上的表现,即模型处于过拟合状态。为达到更理想的分类效果,需要对 XGBoost 模型的其他参数进行设定,以提高其泛化能力。

表 3 预处理后的数据集

Tab. 3 Preprocessed data sets

序号	HT1	HT2	HE1	...	F1	F2	F3	类别标签
1	-0.313 950	-1.069 800	-0.144 480	...	-0.894 427 190	1.414 213 562	-0.534 522 484	F23
2	-1.336 960	-0.979 080	-0.948 120	...	-0.894 427 190	-0.707 106 780	1.870 828 693	F31
3	-0.418 370	-1.614 090	-0.546 300	...	-0.894 427 190	-0.707 106 780	1.870 828 693	F32
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
449	1.058 430	1.440 195	0.900 258	...	1.118 033 989	-0.707 106 780	-0.534 522 484	F11
450	1.045 868	1.149 048	-0.385 570	...	1.118 033 989	-0.707 106 780	-0.534 522 484	F11

表 4 特征参数重要度排序
Tab. 4 Feature importance ranking

编号	得分
HT1	0.193
HE1	0.160
HC1	0.126
HT3	0.126
Y1	0.117
F1	0.106
F3	0.099
X2	0.086
HT4	0.080
HT2	0.080
X1	0.077
Y2	0.069
F2	0.052




图 3 迭代次数-误差学习曲线
Fig. 3 Error vs. iteration times

模型主要参数设定值见表 5, 优化后的模型迭代次数-误差学习曲线如图 4 所示。从图 4 可以看出, 模型的过拟合现象得到很大改善, 但模型的准确率略有下降。

表 5 XGBoost 模型主要参数设定
Tab. 5 Main parameters of the XGBoost model

参数	设定值
学习率(步长)	0.07
树的最大深度	3
复杂度的惩罚项	1
每次生成树时随机抽样特征的比例	1
每次生成树的 1 层时随机抽样特征的比例	0.5
权重的 L2 范数正则化项	5
权重的 L1 范数正则化项	1
最小叶节点权重和	1

3.4 XGBoost 模型的分类结果

利用测试集对构建好的 XGBoost 模型进行分类准确率验证, 如图 5 所示。结果表明, XGBoost

模型整体分类准确率为 95.56%。其中, 汽缸变形导致的动静碰摩故障分类准确率为 64.3%, 机组加负荷过快导致的动静碰摩故障分类准确率为 92.3%, 其他故障原因导致的动静碰摩故障、质量不平衡故障和自激振荡故障分类准确率均为 100%。整个诊断过程的计算时间为 0.5207 s。测试集的混淆矩阵见表 6。




图 4 优化后的迭代次数-误差学习曲线
Fig. 4 Error vs. iteration times after optimization




图 5 采用 XGBoost 模型时测试集的分类结果
Fig. 5 Classification results of test set using XGBoost model

表 6 XGBoost 测试集的混淆矩阵
Tab. 6 Confusion matrix of test set using XGBoost model

实际故障原因类别	模型输出的故障原因类别								
	F11	F12	F13	F14	F21	F22	F23	F31	F32
F11	10	5							
F12	1	14							
F13			15						
F14				15					
F21					15				
F22						15			
F23							15		
F31								15	
F32									15

3.5 对比分析

将 XGBoost 模型与决策树(DT)模型、支持向量机(SVM)、随机森林算法(RF)和梯度提升决策树算法的分类结果进行对比, 采用预处理后的数据集分别对各算法进行训练和测试。

采用 DT 模型时,首先画出树最大深度参数学习曲线,并测试出决策树最大深度最优取值为 5,使用网格搜索法确定其他参数的最优组合为: $\text{min_sample_leaf}=2$; $\text{min_sample_split}=1$; $\text{crition}=\text{entropy}$ 。DT 模型分类结果如图 6 所示。




图 6 采用 DT 模型时测试集的分类结果

Fig. 6 Classification results of test set using DT model

采用 SVM 模型时利用径向基核函数(RBF)进行训练。由于核参数和惩罚系数对训练结果的影响较大,所以采用网格搜索法对 2 个参数进行寻优,核参数和惩罚系数分别取 1.234 和 0.095。SVM 模型分类结果如图 7 所示。

分别对随机森林和梯度提升决策树模型的参数进行寻优。表 7 给出 5 种模型故障分类结果的对比情况。

由表 7 可知,XGBoost 模型比其他模型具有更高的分类准确率,而 DT 模型和 RF 模型训练耗时较 XGBoost 模型更短。这是因为 DT 模型复杂度低,RF 模型和 GBDT 模型均是基于 DT 模型的算法,其准确率均略差于 XGBoost 模型,由此验证了 XGBoost 模型用于汽轮机转子故障原因定位的有




图 7 采用 SVM 模型时测试集的分类结果

Fig. 7 Classification results of test set using SVM model

表 7 不同模型的故障分类结果

Tab. 7 Fault classification results of different models

模型	训练耗时/s	准确率/%
DT	0.139 8	91.85
SVM	0.624 0	84.44
RF	0.218 3	93.33
GBDT	0.534 9	92.59
XGBoost	0.520 7	95.56

效性。

3.6 故障知识库

针对不同故障原因导致的汽轮机转子动静碰摩、质量不平衡和自激振荡 3 种故障,其相应的故障知识库见表 8。汽轮机高压转子故障知识库给出了故障原因定位算法中涉及的相关运行参数、故障类型和故障原因等信息,并针对具体故障原因给出相应故障解决措施,为故障修复提供建议,从而提高故障诊断与修复的效率。

表 8 汽轮机高压转子故障知识库

Tab. 8 Fault knowledge base of steam turbine high pressure rotor

故障类型	类别标签	措施编号	故障措施
F1	F11	M11	合理调整立销间隙以及推力轴承间隙、紧固汽门螺杆的螺栓等
	F12	M12	降低加负荷的速率
	F13	M13	减少低负荷下停留时间、尽快加负荷
	F14	M14	合理调整动静间隙和合理控制启动运行中的热力参数等
F2	F21	M21	通过转子动平衡降低转子激振力
	F22	M22	对挡风板进行处理或更换高质量的内六方螺栓等
	F23	M23	现场实施一阶或二阶动平衡
F3	F31	M31	采用可倾瓦、椭圆瓦等稳定性较好的轴承;增大轴承比压,如减小轴承长度、合理调整轴承标高;提高润滑油温、降低润滑油的黏度;减小固定瓦轴承的顶隙、提高轴承预载荷
	F32	M32	降低转轴振动、减小轴颈扰动力

4 结 语

(1) XGBoost 模型能对多维和多特征数据进行快速有效处理,可以对多种故障原因进行快速准确分类。

(2) XGBoost 模型可有效识别出汽轮机转子 3 种故障类型下的 9 种故障原因,分类准确率可达 95.56%。相较于 DT、SVM、RF 和 GBDT 模型, XGBoost 模型具有更好的分类准确率。

参考文献:

- [1] 田松峰,魏言,郁建雄,等. 基于变分模态分解云模型和优化 LSSVM 的汽轮机振动故障诊断[J]. 动力工程学报, 2019, 39(10): 818-825.
TIAN Songfeng, WEI Yan, YU Jianxiong, et al. Vibration fault diagnosis of steam turbines based on VMD and optimized LSSVM[J]. *Journal of Chinese Society of Power Engineering*, 2019, 39(10): 818-825.
- [2] 石志标,陈斐,曹丽华. 基于排列熵与 IFOA-RVM 的汽轮机转子故障诊断[J]. 振动与冲击, 2018, 37(5): 79-84, 113.
SHI Zhibiao, CHEN Fei, CAO Lihua. Fault diagnosis of steam turbine rotor based on permutation entropy and IFOA-RVM[J]. *Journal of Vibration and Shock*, 2018, 37(5): 79-84, 113.
- [3] MADRIGAL-ESPINOSA G, OSORIO-GORDILLO G L, ASTORGA-ZARAGOZA C M, et al. Fault detection and isolation system for boiler-turbine unit of a thermal power plant[J]. *Electric Power Systems Research*, 2017, 148: 237-244.
- [4] 孙文涛,刘涤尘,赵洁,等. 大型压水堆核电机组失磁动态特性及机理研究[J]. 中国电机工程学报, 2014, 34(10): 1538-1545.
SUN Wentao, LIU Dichen, ZHAO Jie, et al. Study on dynamic characteristics and mechanism of the loss of excitation of large-scale pressurized water reactor nuclear power plant[J]. *Proceedings of the CSEE*, 2014, 34(10): 1538-1545.
- [5] 赵利华. 旋转机械故障机理与轴心轨迹识别方法研究[D]. 大连: 大连理工大学, 2010.
- [6] 严可国,柳亦兵,徐鸿,等. 基于双谱分析的大型汽轮机振动故障特性提取[J]. 中国电机工程学报, 2010, 30(2): 98-103.
YAN Keguo, LIU Yibing, XU Hong, et al. Fault feature extraction of large steam turbine based on bispectra analysis of vibration signal[J]. *Proceedings of the CSEE*, 2010, 30(2): 98-103.
- [7] 顾煜炯,杨楠,刘璐,等. 基于序列数据异常趋势识别的故障诊断方法[J]. 电力系统自动化, 2019, 43(15): 146-151.
GU Yujiong, YANG Nan, LIU Lu, et al. Fault diagnosis method based on abnormal trend identification of sequential data[J]. *Automation of Electric Power Systems*, 2019, 43(15): 146-151.
- [8] 张栋良,黄昕宇,李帅位. 基于变分模态分解和改进模糊支持向量机的汽轮机故障诊断方法[J]. 济南大学学报(自然科学版), 2019, 33(2): 142-149.
ZHANG Dongliang, HUANG Xinyu, LI Shuaiwei. Turbine fault diagnosis based on variable mode decomposition and improved fuzzy support vector machine[J]. *Journal of University of Jinan (Science and Technology)*, 2019, 33(2): 142-149.
- [9] 夏飞,郝硕涛,张浩,等. 改进粒子滤波和小波包在汽轮机振动诊断中的应用[J]. 系统仿真学报, 2016, 28(11): 2823-2831.
XIA Fei, HAO Shuotao, ZHANG Hao, et al. Application of improved particle filter and wavelet packet in turbine vibration diagnosis[J]. *Journal of System Simulation*, 2016, 28(11): 2823-2831.
- [10] 陈长河,石志标,曹丽华. 基于云粒子群优化 SVM 的汽轮机转子故障诊断[J]. 汽轮机技术, 2018, 60(3): 201-204, 207.
CHEN Changhe, SHI Zhibiao, CAO Lihua. Fault diagnosis of steam turbine rotor based on CPSO-SVM[J]. *Turbine Technology*, 2018, 60(3): 201-204, 207.
- [11] MORADI M, CHAIBAKHSH A, RAMEZ A. An intelligent hybrid technique for fault detection and condition monitoring of a thermal power plant[J]. *Applied Mathematical Modelling*, 2018, 60: 34-47.
- [12] 蔡文方,陆颂元,吴文健,等. ICA 在汽轮机组动静碰磨故障诊断中的应用研究[J]. 汽轮机技术, 2017, 59(6): 451-455.
CAI Wenfang, LU Songyuan, WU Wenjian, et al. Research on ICA for rotor-to-stator rubbing diagnosis of turbo-generator units[J]. *Turbine Technology*, 2017, 59(6): 451-455.
- [13] 石志标,苗莹. 基于 FOA-SVM 的汽轮机振动故障诊断[J]. 振动与冲击, 2014, 33(22): 111-114.
SHI Zhibiao, MIAO Ying. Vibration fault diagnosis for steam turbine by using support vector machine based on fruit fly optimization algorithm[J]. *Journal of Vibration and Shock*, 2014, 33(22): 111-114.
- [14] 张学延,张卫军,何国安. 火电厂旋转机械振动诊断及治理技术[M]. 北京: 中国电力出版社, 2019.
- [15] 钟敏慧,张婉露,李有儒,等. 基于 GBDT 的铁路事

- 故类型预测及成因分析[J]. 自动化学报, 2020, 45(x): 1-9.
- ZHONG Minhui, ZHANG Wanlu, LI Youru, et al. GBDT based railway accident type prediction and cause analysis[J]. *Acta Automatica Sinica*, 2020, 45(x): 1-9.
- [16] NIELSEN D. Tree boosting with XGBoost—why does XGBoost win "every" machine learning competition[D]. Trondheim, Norway; Norwegian University of Science and Technology, 2016.
- [17] 王桂兰, 赵洪山, 米增强. XGBoost 算法在风机主轴轴承故障预测中的应用[J]. 电力自动化设备, 2019, 39(1): 73-77, 83.
- WANG Guilun, ZHAO Hongshan, MI Zengqiang. Application of XGBoost algorithm in prediction of wind motor main bearing fault[J]. *Electric Power Automation Equipment*, 2019, 39(1): 73-77, 83.
- [18] 张钰, 陈珺, 王晓峰, 等. Xgboost 在滚动轴承故障诊断中的应用[J]. 噪声与振动控制, 2017, 37(4): 166-170, 179.
- ZHANG Yu, CHEN Jun, WANG Xiaofeng, et al. Application of Xgboost to fault diagnosis of rolling bearings[J]. *Noise and Vibration Control*, 2017, 37(4): 166-170, 179.
- [19] 赵洪山, 闫西慧, 王桂兰, 等. 应用深度自编码网络
 (上接第 438 页)
- [7] LUCKOS A, SHAIK M N, van DYK J C. Gasification and pyrolysis of coal[J]. *Handbook of Combustion; Online*, 2010; 325-364.
- [8] LIU Jiaxun, JIANG Xiumin, SHEN Jun, et al. Pyrolysis of superfine pulverized coal. Part 1. Mechanisms of methane formation[J]. *Energy Conversion and Management*, 2014, 87: 1027-1038.
- [9] PORADA S. The reactions of formation of selected gas products during coal pyrolysis[J]. *Fuel*, 2004, 83(9): 1191-1196.
- [10] GLARBORG P, JENSEN A D, JOHNSON J E. Fuel nitrogen conversion in solid fuel fired systems[J]. *Progress in Energy and Combustion Science*, 2003, 29(2): 89-113.
- [11] 黄慧君. 褐煤热解过程中氧的迁移规律[D]. 太原: 太原理工大学, 2016.
- [12] LIU Jiaxun, JIANG Xiumin, SHEN Jun, et al. Pyrolysis of superfine pulverized coal. Part 2. Mechanisms of carbon monoxide formation[J]. *Energy Conversion and Management*, 2014, 87: 1039-1049.
- [13] 韦杰. 生物质气化气中焦油的催化裂解研究[D]. 北京: 华北电力大学, 2007.
- [14] 王兴龙. 白音华褐煤热解过程研究及热解煤焦油分析[D]. 大连: 大连理工大学, 2013.
- [15] WEI Ling, TAN Yisheng, HAN Yizhuo, et al. Hydrogen production by methane cracking over different coal chars[J]. *Fuel*, 2011, 90(11): 3473-3479.
- [16] WANG Zhihua, LI Qian, LIN Zhenmin, et al. Transformation of nitrogen and sulphur impurities during hydrothermal upgrading of low quality coals[J]. *Fuel*, 2016, 164: 254-261.
- [17] IBARRA J V, CERVERO I, GARCÍA M, et al. Influence of cross-linking on tar formation during pyrolysis of low-rank coals[J]. *Fuel Processing Technology*, 1990, 24: 19-25.
- [18] 季杰强, 程乐鸣, 刘炎泉, 等. 准东煤中钠高温形态的化学动力学模拟[J]. 动力工程学报, 2017, 37(10): 780-787.
- JI Jieqiang, CHENG Leming, LIU Yanquan, et al. Chemical kinetics simulation on high-temperature morphology of alkali sodium in Zhundong coal[J]. *Journal of Chinese Society of Power Engineering*, 2017, 37(10): 780-787.
- 和 XGBoost 的风电机组发电机故障诊断[J]. 电力系统自动化, 2019, 43(1): 81-86.
- ZHAO Hongshan, YAN Xihui, WANG Guilun, et al. Fault diagnosis of wind turbine generator based on deep autoencoder network and XGBoost[J]. *Automation of Electric Power Systems*, 2019, 43(1): 81-86.
- [20] CHEN Tianqi, GUESTRIN C. XGBoost: a scalable tree boosting system [C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco, USA: Association for Computing Machinery, 2016: 785-794.
- [21] 刘波, 秦川, 鞠平, 等. 基于 XGBoost 与 Stacking 模型融合的短期母线负荷预测[J]. 电力自动化设备, 2020, 40(3): 147-153.
- LIU Bo, QIN Chuan, JU Ping, et al. Short-term bus load forecasting based on XGBoost and stacking model fusion[J]. *Electric Power Automation Equipment*, 2020, 40(3): 147-153.
- [22] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn: machine learning in Python [J]. *The Journal of Machine Learning Research*, 2011, 12: 2825-2830.