

# 超临界机组设备故障预测与智能运维策略

王猛, 潘作为, 范景扬, 李静平, 姚虎冬

内蒙古鄂尔多斯市京能康巴什热电有限公司, 内蒙古 鄂尔多斯 017010

**摘要:** 本文针对超临界机组设备故障预测与智能运维策略进行了深入研究。首先, 介绍了超临界机组常见故障类型及其特征, 并对比分析了基于信号处理、机器学习、深度学习等故障诊断与预测方法。其次, 设计了智能运维策略, 包括数据采集与处理、故障诊断与预测、维护决策与优化等方面, 并提出了智能运维系统架构设计。最后, 探讨了基于大数据和物联网的智能运维策略, 为超临界机组设备的安全稳定运行提供理论支持和实践指导。

**关键词:** 超临界机组; 设备; 故障预测; 智能运维

## Equipment Fault Prediction and Intelligent Operation and Maintenance Strategy for Supercritical Units

Wang Meng, Pan Zuowei, Fan Jingyang, Li Jingping, Yao Hudong

Inner Mongolia Ordos City Jingneng Kangbashi Thermal power Co., Ltd. Ordos, Inner Mongolia 017010

**Abstract:** This paper focuses on the fault prediction and intelligent operation and maintenance strategy of supercritical units. Firstly, the common fault types and characteristics of supercritical units are introduced, and the fault diagnosis and prediction methods based on signal processing, machine learning and deep learning are compared and analyzed. Secondly, the intelligent operation and maintenance strategy is designed, including data collection and processing, fault diagnosis and prediction, maintenance decision and optimization, etc., and the intelligent operation and maintenance system architecture design is proposed. Finally, the intelligent operation and maintenance strategy based on big data and the Internet of Things is discussed to provide theoretical support and practical guidance for the safe and stable operation of the supercritical unit equipment.

**Keywords:** supercritical unit; equipment; fault prediction; intelligent operation and maintenance

## 引言

随着能源需求的不断增长, 超临界机组作为高效、环保的发电方式在电力行业中占据重要地位。然而, 其复杂的运行特性和高参数环境使得设备故障预测与运维管理面临着巨大挑战。为了确保超临界机组的安全、高效运行, 本文将探讨设备故障预测方法及智能运维策略, 以为电力行业提供技术支持。

## 一、超临界机组设备故障预测方法

### (一) 超临界机组故障类型及特征

#### 1. 常见故障类型

汽轮机叶片故障包括叶片裂纹、磨损、腐蚀、疲劳断裂等, 这些故障会导致叶片效率下降, 甚至引发机组振动加剧<sup>[1]</sup>。汽缸与阀门故障包括汽缸内部密封不良、阀门泄漏、阀门卡涩等, 这些故障会影响蒸汽的流动特性, 降低机组的热效率。由于燃料质量波动、燃烧器性能不佳或空气/燃料比例失衡, 可能导致燃烧不稳定, 影响锅炉的运行安全。水冷壁管泄漏、水垢累积、管子磨损等, 这些故障会导致热交换效率降低, 甚至发生锅炉爆炸事故。轴承磨损、润滑不足、轴承温度过高等, 这些故障可能导致轴系对中不良, 机组振动增大, 严重时会引起轴断<sup>[1]</sup>。传感器与控制系

统故障包括温度传感器、压力传感器、执行机构等部件的故障, 这些故障会影响机组控制系统的稳定性, 导致运行参数偏离正常范围。

#### 2. 故障特征分析

汽轮机叶片故障特征通常表现为叶片振动频率变化、叶片应力分布异常、高速旋转时产生的噪声和振动特性变化等。汽缸与阀门的故障特征包括汽缸内外温度差、压力波动、阀门开关位置的异常反馈等。燃料燃烧不稳定的特征可以通过火焰形状、燃烧温度、炉内压力波动等参数来识别。锅炉水冷壁故障的特征包括水冷壁管壁温度异常、炉水循环流量变化、锅炉蒸汽产量波动等<sup>[2]</sup>。轴承故障特征包括轴承温度升高、振动加速度增大、润滑油脂降解产生的气体分析数据异常等。传感器与控制系统故障的特征表现为控制系统响应迟钝、传感器信号丢失或数据不准确等。

## （二）故障诊断方法

### 1. 基于信号处理的方法

使用传感器收集设备的运行数据，如振动、温度、压力等信号。对原始信号进行滤波、去噪、归一化等处理，以提高信号质量。应用傅里叶变换（FFT）、小波变换（WT）等算法提取信号的时间域、频率域特征，如均值、方差、频率成分等。利用模式识别技术，如主成分分析（PCA）、支持向量机（SVM）等，将提取的特征与正常状态下的特征进行对比，识别故障类型和程度<sup>[2]</sup>。

### 2. 基于机器学习的方法

基于机器学习的故障诊断方法利用历史数据训练模型，实现对未知数据故障状态的预测。收集并整理历史故障数据，包括正常和异常状态下的数据。使用相关性分析、信息增益等技术选择与故障相关的特征。选择合适的机器学习算法，如随机森林（RF）、梯度提升决策树（GBDT）等，利用选定特征对模型进行训练。通过交叉验证、AUC、准确率等指标评估模型性能，并通过调整参数进行优化<sup>[3]</sup>。使用训练好的模型对实时数据进行预测，识别设备的故障状态。

### 3. 基于深度学习的方法

基于深度学习的故障诊断方法利用神经网络自动提取数据特征，进行故障识别。对原始数据进行标准化、归一化处理，以适应深度学习模型的需求。构建深度神经网络（DNN），如卷积神经网络（CNN）、循环神经网络（RNN）等，以适应数据的时序和空间特性。使用大量带标签的历史数据对网络进行训练，通过反向传播算法调整网络权重。在独立的测试集上验证模型性能，确保模型的泛化能力<sup>[4]</sup>。将实时采集的数据输入训练好的深度学习模型，进行故障状态的识别和预测。

## （三）故障预测方法

### 1. 基于时间序列预测的方法

基于时间序列预测的故障预测方法主要利用历史时间序列数据来预测未来的故障趋势。收集连续的时间序列数据，如设备运行参数、环境监测数据等。对时间序列数据进行平滑处理，去除异常值和噪声，确保数据的准确性。根据时间序列的统计特性构建特征向量，包括均值、方差、自相关系数等。选择适当的时间序列预测模型，如自回归移动平均（ARMA）、长短期记忆网络（LSTM）等。利用历史数据训练模型，通过参数优化来提高预测精度。使用训练好的模型对未来的数据进行预测，并通过均方误差（MSE）、预测误差等指标评估预测效果<sup>[5]</sup>。

### 2. 基于数据驱动的方法

基于数据驱动的故障预测方法不依赖于物理模型，而是直接从数据中学习故障模式。搜集设备的历史运行数据，包括正常和故障状态下的数据。进行数据清洗，去除不完整和错误的的数据，然后进行特征选择和降维。选择适当的数据驱动模型，如回归分析、支持向量回归（SVR）、神经网络（NN）等。使用历史数据对模型进行训练，通过最小化预测误差来优化模型参数<sup>[6]</sup>。应用训练好的模型对新的数据进行故障预测，并通过交叉验证等方法验证模型的准确性。

### 3. 基于模型驱动的方法

基于模型驱动的故障预测方法依赖于设备的物理模型和数学模型。根据设备的物理原理和运行特性，建立相应的数学模型，如偏微分方程、状态空间模型等。利用历史数据对模型参数进行估计，确保模型能够准确反映设备的实际运行状态。通过实验数据或实际运行数据对模型进行验证，调整模型以提高其准确性。将实时数据输入模型，通过模型计算预测设备未来的状态，识别潜在的故障趋势<sup>[6]</sup>。对预测结果进行分析，结合设备的运行经验和专家知识，对故障进行诊断和预测。

## （四）预测方法比较与选择

基于时间序列预测的方法，如ARIMA模型，适用于具有明显时间依赖性和周期性的数据，能够捕捉短期内的趋势和模式，但可能无法处理复杂的非线性关系。而基于数据驱动的方法，如机器学习和深度学习模型，能够处理高度非线性和复杂的数据关系，但需要大量的数据支持，并且可能存在过拟合的风险。基于模型驱动的方法，如物理模型和状态空间模型，基于设备的内在物理规律，能够提供对故障机理的深入理解，但模型的建立往往需要深厚的专业知识，且难以处理模型未知或不确定的情况<sup>[7]</sup>。若数据量充足且质量高，数据驱动方法可能更为适用；若数据缺乏或质量参差不齐，则模型驱动方法可能更为合适。时间序列预测方法适用于短期预测，而数据驱动和模型驱动方法更适用于中期和长期预测。对于实时性要求高的场景，基于实时数据的时间序列预测可能更受青睐；而对于准确性要求高的场合，则可能需要结合数据驱动和模型驱动方法。深度学习方法可能需要更多的计算资源和时间，因此在资源受限的情况下可能需要考虑其他方法。

## 二、超临界机组智能运维策略

### （一）智能运维策略设计

#### 1. 数据采集与处理

通过部署传感器网络，实现对超临界机组运行参数的实时监测，包括温度、压力、振动、电流等关键参数。数据采集后，去除由于传感器误差或外部干扰导致的异常数据点。确保不同传感器采集的数据在时间上对齐，以消除时间延迟带来的影响。将数据标准化至同一尺度，以便于后续的特征提取和分析<sup>[7]</sup>。通过主成分分析（PCA）等方法降低数据维度，减少计算复杂度。利用时间序列分析、频谱分析等方法提取数据的特征向量，为后续的诊断和预测提供基础。

#### 2. 故障诊断与预测

利用机器学习算法，如支持向量机（SVM）、随机森林（RF）等，对采集到的数据进行训练，构建故障诊断模型，以识别设备当前的运行状态是否正常。通过深度学习模型，如卷积神经网络（CNN）、循环神经网络（RNN）等，对历史数据进行分析，学习设备故障的演变规律，实现对未来可能发生的故障的预测<sup>[8]</sup>。使用交叉验证、混淆矩阵等方法评估模型的准确性和泛化能力。将新的故障数据反馈至模型中，不断优化和更新模型，提高

诊断和预测的准确性。

### 3. 维护决策与优化

基于故障诊断和预测的结果，确定是否需要触发维护操作。根据设备的运行状态和故障预测结果，制定最优的维护计划，包括维护时间、维护类型和资源分配。通过实际维护后的设备性能数据，评估维护效果，反馈至维护策略中，实现策略的持续优化。结合维护成本和设备运行效率，进行成本效益分析，优化维护策略，实现成本最小化和效率最大化。

### (二) 智能运维系统架构设计

智能运维系统架构设计是一个多层次、模块化的体系结构，旨在实现超临界机组的高效、稳定运行。以下是详细的设计方法：

**感知层：**部署先进的传感器和监测设备，如振动传感器、温度传感器等，实现对机组运行状态的实时感知。感知层负责数据的初步采集和预处理，如信号滤波和初步的特征提取<sup>[9]</sup>。

**数据层：**构建数据存储和管理系统，采用大数据技术，如 Hadoop 和 Spark，进行数据的分布式存储和计算。数据层负责数据的清洗、整合和持久化，为上层分析提供数据支持。

**分析层：**采用数据挖掘和机器学习算法，如聚类、分类、回归等，对数据进行深入分析。分析层通过构建故障诊断和预测模型，提取数据中的有价值信息，为决策层提供依据。

**决策层：**利用优化算法和决策支持系统，如多目标优化、遗传算法等，制定维护策略和运维决策。决策层根据分析层的结果，生成运维指令，指导运维人员进行操作。

**应用层：**提供用户界面和应用程序，如 Web 应用、移动应用等，实现对运维人员的交互和运维流程的管理。应用层负责展示分析结果，提供运维决策支持和执行监控<sup>[9]</sup>。

**安全保障层：**确保系统数据和运行的安全，采用加密、认证、访问控制等安全措施，保护系统的数据和运行不被未经授权的访问和破坏。

在实施过程中，采用微服务架构，将系统拆分为多个独立的服务模块，实现模块间的松耦合，提高系统的扩展性和可维护性。同时，利用容器化技术，如 Docker 和 Kubernetes，实现服务的自动化部署和管理。

### (三) 基于大数据的智能运维策略

采用数据仓库技术，如 Amazon Redshift 或 Google BigQuery，

实现不同数据源（包括历史运维数据、实时监控数据、外部环境数据等）的集成和统一管理。运用 ETL（提取、转换、加载）工具对原始数据进行清洗、转换和标准化，以提高数据质量和可用性。利用数据质量分析工具，如 Trifacta，进行数据质量评估和优化。运用特征工程技术，如主成分分析（PCA）、自动特征选择（Autoencoder）等，从原始数据中提取对故障预测有显著贡献的特征<sup>[10]</sup>。采用分布式机器学习平台，如 Apache Spark MLlib，训练基于大数据的故障预测模型。使用交叉验证、AUC、召回率等指标对模型性能进行评估和优化。部署实时数据流处理框架，如 Apache Kafka 和 Apache Flink，对实时监控数据进行实时分析和处理，实现故障的实时检测和预警。结合历史数据和实时数据，运用预测分析算法，如时间序列分析、回归分析、分类算法等，对设备未来的故障趋势进行预测，并生成运维决策建议。使用数据可视化工具，如 Tableau 或 PowerBI，将分析结果以图形化方式展示，生成易于理解的报告，为运维团队提供直观的决策支持。

### (四) 基于物联网的智能运维策略

利用物联网技术，将超临界机组的各种设备连接至统一的网络平台，实现设备的远程监控和数据交互。在关键设备上安装高精度的智能传感器，实时采集温度、压力、振动等运行参数，并通过无线通信技术传输至集中管理平台。建立数据中心，采用云计算和边缘计算技术，对收集到的数据进行实时处理和分析，确保数据的快速响应和存储。应用机器学习和深度学习算法，对传感器数据进行实时分析，识别异常模式和潜在故障，实现故障的提前预警<sup>[10]</sup>。通过物联网平台，实现对设备的远程维护和控制，如远程重启、参数调整等，减少现场维护的工作量。实施严格的数据加密和安全协议，确保传输和存储的数据安全，遵守相关隐私保护法规。开发用户友好的界面，提供实时监控数据、历史分析报告和运维建议，方便运维人员做出快速决策。

## 三、结语

本文通过对超临界机组设备故障预测方法的研究，以及智能运维策略的探讨，为提高机组运行效率和安全性提供了理论依据和技术支持。随着人工智能技术的不断发展，我们有理由相信，智能运维将在未来电力行业发挥更加重要的作用，为构建更加智能、高效的能源体系贡献力量。

## 参考文献

- [1] 蒲倩. 基于机器学习的超超临界 CFB 锅炉屏式过热器故障诊断研究 [D]. 贵州大学, 2023.
- [2] 阙子俊. 基于时序特征机器学习的火力发电机组故障预测 [D]. 浙江大学, 2022.
- [3] 邱英强, 吴京龙, 陈俊, 陈伟, 施德明. 基于机器学习算法的风电机组故障预测系统设计 [J]. 自动化与仪器仪表, 2021, (09): 190-193.
- [4] 张艳霞, 卢静怡, 张富贺, 毕安露. 基于临界故障时刻的换相失败预测方法 [J]. 电网技术, 2021, 45(10): 4066-4075.
- [5] 卢静怡. 基于临界故障时刻的高压直流输电系统换相失败预测方法研究 [D]. 天津大学, 2020.
- [6] 李灿. 大型发电机组励磁系统故障诊断及预测技术研究 [D]. 南京师范大学, 2020.
- [7] 郭裕清, 王言, 郭洪斌, 戈建新. 超临界汽轮机脱硫增压风机振动故障诊断 [J]. 电力安全技术, 2022, 24(08): 16-20.
- [8] 李勇. 某 1000MW 超超临界机组给水泵汽轮机振动故障分析与处理 [J]. 河南电力, 2022, (S1): 114-116.
- [9] 郑镇晖. 1000MW 超超临界机组集控技术的研究与应用 [J]. 电子测试, 2022, 36(10): 84-86+76.
- [10] 贺强, 姚虎冬, 赛家新, 高飞, 赵杰. 350MW 超临界汽轮机轴承振动故障分析及处理 [J]. 河北电力技术, 2021, 40(05): 55-58.