

[运维作业]

电厂运维作业风险预控系统设计与实现

文/马清峰

山东纳鑫电力科技有限公司

运维作业风险预控系统可以有效识别运维过程中潜在风险，提高设备整体生产效率。首先构建系统的总体架构，明确技术框架，并提出风险评估模型，故障树分析用于识别主要故障模式及其因果关系，而回归模型则提供对故障发生概率的量化预测。在实验部分，研究的目的是通过实际数据验证所设计系统的有效性，实验步骤包括数据收集、模型选择等。实验结果表明，所构建风险预控系统能够有效识别运维作业中潜在风险，并为企业提供科学的决策支持。

电力需求不断增长，电厂运行面临日益复杂的挑战。电厂运维作业涉及设备管理、故障检修和人员操作等多个环节，各类潜在风险增加，建立有效的风险预控系统，对于保障电厂安全具有重要现实意义。传统运维管理依赖经验和定期检修，难以适应快速变化的复杂设备状态。随着信息技术发展，数据采集和分析能力提升，运用现代化风险管理方法对电厂运维进行风险预警，成为行业发展的必然趋势^[1]。风险预控系统不仅能够有效识别潜在风险，还能实时监控设备状态，通过数据分析为运维决策提供科学依据，提高电厂运维效率，降低事故发生率，为安全生产提供技术支持。通过建立风险预控机制对电厂运维全生命周期进行管理，促进设备数字化转型。

运维作业风险预控系统设计

1. 系统架构

运维作业风险预控系统中，系统整体架构可以划分为四个主要层级：数据采集层、数据处理层、决策层和用户界面层。每个层级都有其特定的功能和任务，确保系统能够有效地实施风险预控，系统

结构图如图1所示。




图1 风险预控系统架构图

数据采集层负责从不同来源获取原始数据，包括设备运行数据、故障记录、环境监测数据以及人员的操作日志，通过传感器和日志系统实时收集数据，为后续处理提供基础。

数据处理层进行数据清洗、缺失值处理和异常值检测，确保数据准确性，通过特征提取，将原始数据转化为适合建模形式。

决策层利用经过处理数据，系统应用多种风险评估模型进行风险评估，并生成决策支持信息。

用户界面层通过可视化的界面向用户展示风险评估结果、预警信息以及其他系统操作功能，便于

运维人员进行决策与响应^[2]。

2. 技术框架

技术框架直接影响系统稳定性，Python作为后端开发的主要语言，以简洁语法适合于快速开发，为数据处理提供支持。JavaScript应用前端开发中，JavaScript配合HTML和CSS，实现用户界面的交互性和可视化展示，使前端界面更加动态。

后端框架选择Flask作为Python后端框架，方便前后端分离的开发模式，这些API服务将支持数据的上传、处理。前端框架React支持构建用户友好交互界面，并能够与后端API无缝对接，MySQL作为数据库，提供数据存储能力，故障记录表见表1。

表1 故障记录表数据

字段名	数据类型	描述
incident_id	INT	故障ID，主键
device_id	INT	关联的设备ID
incident_type	VARCHAR	故障类型
resolution	TEXT	处理结果
incident_time	TIMESTAMP	故障发生时间
resolved_time	TIMESTAMP	故障解决时间

Pandas库提供DataFrame对象，使得数据清洗、处理和分析变得简单快捷，通过上述技术框架的选择，构建高效的运维作业风险预控系统。该系统能够实时监控和分析运维数据，预测潜在风险，并提供相应的预控措施，提高电厂安全管理水平^[3]。

3. 风险评估模型

(1) 故障树分析

故障树分析通过构建故障树图，将复杂故障事件分解为多个子事件，并识别潜在的故障原因。以下是FTA中使用的基本公式。

独立事件和的概率计算公式为

$$P(A \cap B) = P(A) + P(B) - P(A) P(B)$$
 (1)

独立事件积的概率计算公式为

$$P(A \cup B) = P(A) P(B)$$
 (2)

顶事件的发生概率计算公式为

$$P_{top} = \sum_{i=1}^k P(M_i)$$
 (3)

式中，k为最小割集数量；M_i为第i个最小割集。

(2) 回归模型

回归模型用于预测设备的剩余寿命或故障发生

的时间，线性回归模型预测故障发生时间的基本公式为

$$RUL = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$$
 (4)

式中，β为模型参数；X为特征变量。

回归树通过递归地将数据集分割成更小的子集来预测连续值，其分割公式可以表示为

$$Split(X) = \{x \in X | S < s\} \cup \{x \in X | S \geq s\}$$
 (5)

式中，S为选择的特征；s为该特征的分割点。

表2是一个简化风险评估数据表示例，用于展示如何将机器学习模型应用于风险评估。

表2 简化风险评估数据

设备ID	故障历史	环境因素	预测故障概率	剩余寿命预测/h
001	2次	湿度高	0.65	1 200
002	1次	温度高	0.48	1 500
003	0次	正常	0.21	1 200

在表2中，“故障历史”和“环境因素”是特征变量，而“预测故障概率”和“剩余寿命预测”是通过机器学习模型计算得出的结果^[4]。

运维作业风险预控系统实验

1. 实验目的

实验旨在验证所设计的运维作业风险预控系统的有效性，通过构建机器学习模型，对设备故障进行预测，并评估其风险等级，从而采取相应的预防措施，降低设备故障带来的经济损失和安全隐患。

实验设备：计算机若干台用于运行风险预控系统软件，进行数据处理和模型训练，每台计算机需配备高性能CPU和GPU，支持大规模数据分析和机器学习模型训练。

数据集包含历史故障数据、设备状态数据和环境因素数据，示例数据采集5 000条记录，字段涵盖设备的各种状态和故障信息。故障树分析用于识别设备故障的根本原因，通过建立故障树模型分析故障原因之间的逻辑关系，分析设备故障可能导致的后果，评估事故发生的可能性。

2. 实验步骤

(1) 收集数据

从设备管理系统中收集过去一年内的设备历史故障数据，如电气故障、机械故障和软件故障等，故障发生的具体日期和时间，包括温度、

压力和运行时间等，如设备A温度（30℃）、压力（2.5 bar）、运行时间（500 h）；设备B温度（28℃）、压力（2.0 bar）、运行时间（320 h）。环境因素数据湿度（60%）、环境温度（25℃）。

对收集的数据进行清晰排除异常值，设备A在一年内发生故障12次，明显高于平均水平2次，因此记录将被排除。对缺失的温度数据采用中位数填补，如某设备在某天的温度缺失，使用过去七天的温度中位数填补），使用前向填充法处理时间序列数据中缺失的压力值。

对所有数值型特征，如温度、压力进行Z-score标准化处理，使得每个特征的平均值为0，标准差为1。

使用相关性分析识别与故障发生相关性较高的特征：温度与故障发生的相关性为0.75，压力相关性为0.65。基于现有数据构造新特征：计算设备过去7天的温度均值，计算过去7天的最大压力与最小压力之差。

（2）选择模型

选择回归模型用于故障类型的预测，线性回归用于故障发生时间的预测，将数据集分为训练集70%和测试集30%，训练集包含800条记录，测试集包含300条记录，使用交叉验证调整超参数防止模型过拟合，得到的数据见表3。

表3 评估数据

类型	评估指标	值
故障类型预测	准确率	85%
	精确度	80%
	召回率	75%
	F1-score	77%
故障发生时间预测	均方误差（MSE）	5.4
	均方根误差（RMSE）	2.3

结合预测模型评估指标，使用故障树分析识别主要故障模式，根据准确率（85%）、精确度（80%）和召回率（75%），认为预测模型在故障类型的识别上是较为可靠的，对主要故障模式进行识别。

电气故障指设备电气系统或电气组件失效，导致设备无法正常运转，根据历史数据，电气故障的发生概率为80%，此故障直接导致设备停机，造成生产延误，影响整体效益。

机械故障指设备内部机械部件的磨损或损坏，

导致设备效率下降，此故障的发生概率为50%，设备效率下降导致生产速度减缓，进一步引发生产延误。

软件故障指设备控制或监测软件的崩溃或功能失效，此故障发生概率为20%，尽管影响较小，但系统崩溃可能导致数据丢失或错误，影响后续决策。

事件树分析探讨故障发生后的后果，以电气故障为例，构建以下事件树。

故障事件：电气故障。

后果1：设备停机；影响：生产延误，客户交期受到影响，可能导致经济损失。

后果2：维修成本增加；影响：停机设备需要额外的维修时间和人力，导致维护成本上升。

后果3：影响设备正常运行；影响：设备性能下降，导致整体生产效率降低。

根据故障模式的发生概率和影响程度，构建风险矩阵，风险矩阵分类不同类型的故障，为后续风险管理提供依据，见表4。

表4 故障风险矩阵

故障类型	发生概率（%）	影响程度	风险等级
电气故障	80	高	高风险
机械故障	50	中	中风险
软件故障	20	低	低风险

结合风险矩阵的构建，设备故障风险得到有效识别。

电气故障因其高发生概率和高影响程度，需重点监控和维护，建议定期进行电气系统的检查和维护，以降低故障发生率^[5]。

机械故障虽然发生概率较低，但影响程度中等，依然需要定期的维护和检测，特别是在设备运行达到一定小时数后，建议进行全面的机械检查。

软件故障的发生概率和影响程度较低，可以在设备运行监控中适当减少关注，但仍需在软件更新时保持警惕。

本实验验证运维作业风险预控系统的有效性，通过机器学习模型应用，提高设备故障预测的准确性，为运维管理提供了科学依据。实验结果显示：风险预控系统能够有效识别高风险设备，为运维团队提供有价值的决策支持，降低设备故障带来的经济损失。

（下转第49页）

式中, j 为配电网中安装SVG设备节点数量; Q_{Cj} 为 j 节点处SVG设备的容量。

2) 根据外点罚函数原理, 对无功优化模型进行转换, 得到无约束条件的求解问题。通过转换后的函数模型为

$$\min f(Q_C) + \lambda h(Q_C) \quad (18)$$

式中, λ 为惩罚因子。

3) 按照外点罚函数相同的方式设置初始点 $Q_C(0)$ 、 λ 、 c 、 ε 等参数, 并利用式(18)推导出各点的最小值。

4) 当 $k=0$ 时, 如果 $h(Q_C^{(k)}) < \varepsilon$, 表明得到最优SVG设备布置方案, 终止继续运算, 并将结果 $Q_C^{(k)}$ 导出; 反之跳转到步骤2) 重新计算。

结束语

综上所述设计出一种基于外点罚函数的配电网无功优化方法, 该方法将安装SVG设备后配电网产生的线损作为目标函数, 将SVG设备容量与节点电压作为约束条件, 通过外点罚函数的计算后, 即可计算出最优的SVG布置方案。在提升配电网无功调

控效果的同时, 控制配电网改造成本, 对现代分布式光伏并网后的配电网改造具有重要意义。EA

(收稿日期: 2025-01-08)

参考文献

- [1] 王博, 严洋, 夏展鹏, 等. 含分布式光伏的配电网无功电压控制策略研究[J]. 四川电力技术, 2024, 47(3): 1-5.
- [2] 王迪生, 祁艳君. 考虑瞬时无功功率的分布式光伏并网谐波检测方法[J]. 电工技术, 2024(2): 83-86, 136.
- [3] 胡乃红, 李健. 适应大规模分布式光伏并网的无功电压控制方法[J]. 重庆科技学院学报(自然科学版), 2023, 25(6): 92-99.
- [4] 蔡永翔, 杨安黔, 付宇, 等. 面向分布式光伏并网和电能替代的低压配电网自适应控制[J]. 可再生能源, 2023, 41(10): 1343-1351.
- [5] 谢浩辉. 并网型分布式光伏系统电量计量和无功补偿的研究分析[J]. 电工技术, 2022(2): 18-19, 22.

(上接第45页)

结束语

通过设计运维作业风险预控系统, 能够有效识别、管理潜在风险, 从而降低故障发生的概率, 提高设备整体生产效率, 在系统架构方面构建层次分明的结构, 确保风险管理能够覆盖运维作业的各个环节, 技术框架强调系统的灵活性, 使其能够适应不同类型运维需求。风险评估模型部分, 结合故障树分析和回归模型, 前者识别主要故障模式及其因果关系, 后者则为故障发生时间的预测提供量化支持, 这种综合运用方式, 使得风险评估更加精准, 为决策提供数据基础。EA

(收稿日期: 2024-12-26)

参考文献

- [1] 陈新, 王林, 曾历. 水电站作业人员管控和风

险预控系统研发与应用[J]. 电工技术, 2020, (22): 153-155.

- [2] 李旭明, 张冬生, 文华宇, 高志云, 候华东. 水电厂运行值班风险分析及其预控措施探讨[J]. 电子世界, 2014, (15): 53.
- [3] 吴楷, 王创. 电厂信息系统监控平台设计[J]. 科技视界, 2020(19): 236-237.
- [4] 杨启超. 火力发电厂集控运维中的人机协作与人因工程优化[J]. 大众标准化, 2024(7): 116-118.
- [5] 李兵, 姜清辉, 杨鹏, 等. 火电厂智能化系统架构及智能监盘模型研究[J]. 工业控制计算机, 2024, 37(6): 125-126, 129.