

基于机器学习集成模型的配电网预测性维护方法研究

尹红珊¹, 庞进¹, 李静¹, 刘安¹, 王景初¹, 刘孟奇¹, 许伟民²

¹国家电网有限公司信息通信中心, 网络与数据安全部, 北京

²杭州电子科技大学管理学院, 浙江 杭州

收稿日期: 2026年7月26日; 录用日期: 2026年8月17日; 发布日期: 2026年8月28日

摘要

针对智能配电网运行维护中多源运行数据利用不足、故障识别响应滞后及维护计划缺乏状态驱动依据等问题, 提出一种基于机器学习集成模型的配电网预测性维护方法。该方法首先采集传感器数据、智能电表数据、电力线路传感器数据、SCADA历史数据、实时监测数据、原始电力负荷数据、环境数据、设备工作状态数据和组件温度数据, 并对其进行缺失值填补、异常值处理、标准化及归一化处理; 随后提取与组件温度、设备状态和故障分类相关的特征, 采用主成分分析筛选关键特征; 在此基础上构建机器学习集成模型, 实现故障检测、故障分类、组件温度预测及异常告警。模型输出故障类型、温度偏差判断结果和维护建议, 并通过准确率、精确率、召回率和F1值评价预测性维护效果。算例验证结果表明, 所述方法能够有效识别设备潜在异常并降低误报、漏检风险, 为配电网维护调度和状态检修提供辅助决策依据。

关键词

配电网, 预测性维护, 机器学习集成模型, 组件温度预测

Research on Predictive Maintenance Method for Power Distribution Networks Based on Machine Learning Ensemble Model

Hongshan Yin¹, Jin Pang¹, Jing Li¹, An Liu¹, Jingchu Wang¹, Mengqi Liu¹, Weimin Xu²

¹Department of Cyberspace and Data Security, Information & Telecommunication Center-State Grid Corporation of China, Beijing

²School of Management, Hangzhou Dianzi University, Hangzhou Zhejiang

Received: July 26, 2026; accepted: August 17, 2026; published: August 28, 2026

文章引用: 尹红珊, 庞进, 李静, 刘安, 王景初, 刘孟奇, 许伟民. 基于机器学习集成模型的配电网预测性维护方法研究[J]. 智能电网, 2026, 16(4): 113-121. DOI: 10.12677/sg.2026.164014

Abstract

To address the problems of insufficient utilization of multi-source operational data, delayed fault response, and the lack of condition-driven maintenance scheduling in smart power distribution networks, a predictive maintenance method based on a machine learning ensemble model is proposed. The method first collects sensor data, smart meter data, power line sensor data, historical SCADA data, real-time monitoring data, raw electrical load data, environmental data, equipment operating-state data, and component temperature data, and then performs missing-value filling, outlier processing, standardization, and normalization. Features related to component temperature, equipment status, and fault classification are extracted, and principal component analysis is adopted to select key features. On this basis, a machine learning ensemble model is constructed to implement fault detection, fault classification, component temperature prediction, and abnormal warning. The model outputs fault types, temperature-deviation judgment results, and maintenance suggestions, and its performance is evaluated by accuracy, precision, recall, and F1-score. Case results show that the proposed method can identify potential equipment anomalies and reduce false alarms and missed detections, providing decision support for maintenance scheduling and condition-based maintenance of distribution networks.

Keywords

Power Distribution Network, Predictive Maintenance, Machine Learning Ensemble Model, Component Temperature Prediction

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着智能电网建设和配电网自动化水平的不断提高,配电网运行维护对象逐渐呈现出设备类型多样、运行状态复杂、数据来源分散和故障影响范围扩大的特点。传统依赖人工巡检、定期检修和事后维修的运维方式,难以及时感知设备状态变化和潜在故障风险,已不能充分满足配电网安全、可靠和高效运行的需求。已有研究表明,人工智能技术能够用于配网自动化运维决策支持,通过设备状态智能监控、故障预警和资源调度优化,提高运维效率和供电可靠性[1]。

在配电网运行维护过程中,智能监测技术为设备状态感知和故障预警提供了重要数据基础。通过融合传感器、通信网络和数据分析平台,配电网线路运行状态能够被实时采集和分析,从而提高故障定位精度、缩短故障修复时间,并为预测性维护提供支撑[2]。同时,面向配电网故障预测与预防的研究表明,机器学习和深度学习模型可结合特征工程、数据训练与优化方法,提高故障预测准确性,并辅助形成更加主动的预防策略[3]。此外,人工智能异常检测与故障诊断系统通常包括数据采集、数据预处理、异常检测和故障诊断等模块,为配电网状态识别和故障诊断提供了较为清晰的系统实现思路[4]。

从维护策略发展角度看,复杂工程系统维护已由修复性维护、定时维护逐渐发展到视情维护和预测性维护。预测性维护强调利用实时状态信息和数据驱动方法对设备未来运行状态进行判断,并据此制定维护决策,具有降低维护成本、提高系统可靠性和减少非计划停机的优势[5]。机器学习算法能够处理高维、多变量和动态变化的运行数据,并从复杂数据中提取潜在关联关系,因此在设备预测性维护中具有较好的应

用前景[6]。工业人工智能相关研究也指出,人工智能技术在状态监测、故障诊断、寿命预测、优化决策和闭环维护等方面具有重要作用,可为设备预测性维护提供模型方法、数据方法和融合方法支撑[7]。

在配电网场景下,故障定位和预测性维护已成为提升供电可靠性的重要研究方向。有研究提出面向广域配电系统的自动故障定位与预测性维护方法,利用有限数量的监测装置实现故障分支识别,并为运维人员快速定位故障区域提供支持[8]。近年来,面向城市配电网的主动维护研究进一步考虑季节、环境和故障严重程度等因素,通过集成学习模型对高严重度故障进行预测,验证了由被动抢修向主动维护转变的可行性[9]。这些研究说明,结合多源运行数据、故障特征提取和智能预测模型,是提升配电网预测性维护能力的重要技术路径。

然而,现有研究仍存在一些不足:一方面,部分方法侧重单一故障检测或异常诊断,对传感器数据、智能电表数据、SCADA 历史数据、实时监测数据、负荷数据、环境数据和设备状态数据等多源信息的综合利用不足;另一方面,部分研究虽然引入人工智能模型,但对数据预处理、特征选择、故障分类、组件温度异常告警和维护决策输出之间的完整流程衔接不够清晰。针对上述问题,本文提出一种基于机器学习集成模型的配电网预测性维护方法。该方法首先采集配电网多源运行数据,并进行缺失值填补、异常值处理、标准化和归一化处理;然后通过特征提取和主成分分析筛选关键特征;进一步构建机器学习集成模型,实现故障检测、故障分类和组件温度异常告警;最后输出预测性维护结果,为配电网故障预警、维护计划制定和状态检修提供决策支持。

2. 方法总体框架




Figure 1. Overall framework of the predictive maintenance method

图 1. 配电网预测性维护方法总体框架

本文提出的配电网预测性维护方法以多源运行数据为基础，以特征提取和特征选择为中间环节，以机器学习集成模型为核心判断单元，最终输出故障类型、组件温度偏差判断结果及维护建议。整体流程如图 1 所示。

2.1. 数据采集与预处理

数据采集对象为目标配电网的运行数据，主要包括传感器数据、智能电表数据、电力线路传感器数据、SCADA 历史数据、实时智能电网监测数据、原始电力负荷数据、环境数据、设备工作状态数据和组件温度数据。通过多源数据采集，可以从负荷变化、设备状态、环境条件和组件温度等多个维度刻画配电网运行状态。各类数据的来源及其主要用途如表 1 所示。

预处理过程包括缺失值填补、异常值处理、标准化和归一化处理。缺失值填补用于避免模型输入缺失；异常值处理用于过滤明显超出采集系统允许范围或设备运行范围的数据；标准化和归一化用于消除不同物理量纲对模型训练的影响。处理后的数据被划分为训练集和测试集，分别用于模型训练与模型验证。

Table 1. Description of data for predictive maintenance of distribution networks

表 1. 配电网预测性维护数据描述

数据类别	数据来源	用途
传感器数据	环境传感器、设备传感器	反映环境条件、设备状态及局部运行变化
智能电表数据	智能电表系统	获取用电行为、负荷变化及电能计量信息
电力线路传感器数据	线路监测装置	反映线路运行状态及异常波动
SCADA 历史数据	SCADA 监测系统	为模型训练、历史行为建模和温度预测提供基础
实时监测数据	通信接口、智能电网控制中心	用于在线故障检测、分类和维护建议输出
组件温度数据	温度传感器、SCADA 系统	用于组件温度预测及异常偏差判别

2.2. 特征提取与特征选择

根据预处理后的标准化数据，提取与组件温度、设备状态和故障分类相关的特征。特征可包括当前温度、历史温度变化趋势、负荷变化率、运行状态量、环境影响量以及与故障标签相关的统计量。为了减少冗余特征和弱相关特征对模型训练结果的影响，本文采用主成分分析方法进行特征选择，得到用于故障检测和分类的关键特征集合。

特征选择的作用在于降低输入维度、提升模型训练效率和分类稳定性。经过筛选后的关键特征作为机器学习集成模型的输入，可以增强模型对不同负荷水平、环境条件和设备运行状态下异常模式的适应能力。

2.3. 机器学习集成模型训练与故障分类

在模型训练阶段，将关键特征数据作为模型输入，将正常状态或故障类型作为故障标签。模型利用训练集学习关键特征与故障类别之间的映射关系，并在测试集中输出预测故障类型。训练完成后，采用准确率、精确率、召回率和 F1 值对故障检测与分类效果进行评价。

在一种实现方式中，机器学习集成模型可由多个基础分类器或多个状态判断模块组成，各模块分别针对设备状态、运行风险和温度偏差进行判断，并将判断结果融合形成最终故障类别和维护建议。该方式能够避免单一模型对局部数据模式过度敏感，提高预测性维护结果的稳定性。

2.4. 组件温度预测与异常告警

组件温度预测用于发现设备在故障前的温度异常变化。其基本思想是利用正常运行条件下的历史 SCADA 数据建立组件温度回归预测模型，并基于实时监测数据预测组件温度，将预测值与实际测量值进行比较。若二者偏差超过设定阈值，则判定为异常并触发故障告警；若偏差未超过阈值，则系统继续正常运行。组件温度预测与异常告警流程如图 2 所示。




Figure 2. Process of component temperature prediction and abnormal warning
图 2. 组件温度预测与异常告警流程

3. 数学模型与评价指标

3.1. 总体运行目标与约束

配电网预测性维护的目标是在满足运行容量和故障率约束的前提下，降低维护成本、风险管理成本和安全运行成本。总体运行目标可表示为：

$$\min O = O_{mc} + O_{rc} + O_{cc} \quad (1)$$

其中， O_{mc} 表示维护成本， O_{rc} 表示风险管理成本， O_{cc} 表示安全成本；本文重点关注维护成本和停机影响对应的预测性维护环节。

设备预测故障率约束可表示为:

$$F(m) \leq M_{tr}, \quad \forall m \in [m_0, m_n] \quad (2)$$

式中, $F(m)$ 表示设备随时间 m 变化的预测故障率, M_{tr} 表示允许的故障率阈值, m_0 和 m_n 分别表示预测性维护分析的起始时刻和终止时刻。

运行容量约束可表示为:

$$P_l(m) \leq P_{ca} \quad (3)$$

式中, $P_l(m)$ 表示时间 m 的需求负荷, P_{ca} 表示最大配电容量。该约束说明预测性维护判断不能脱离配电网运行容量条件。

3.2. 决策输出模型

模型训练完成后, 维护或运行决策输出可以表示为多个状态量的函数:

$$D(n) = f(Q, M_v(n-1), Mq_{(w-1)(yz)}, J(n-1), K|m|^{r-(b-ser)}) \quad (4)$$

式中, $D(n)$ 表示时刻 n 的维护或运行决策输出, $f(\cdot)$ 表示综合多个状态量生成决策输出的函数; Q 表示有效配电网管理所需的最低预测准确度; $M_v(n-1)$ 表示前一时刻模型性能; $Mq_{(w-1)(yz)}$ 表示考虑维护因素和风险因素后的调整性能指标; $J(n-1)$ 表示前一时刻的模型性能; $K|m|^{r-(b-ser)}$ 表示维护效率和系统韧性因素的综合影响。

3.3. 温度偏差判别模型

组件温度异常可以通过预测温度与实际测量温度之间的偏差进行判断:

$$\Delta T_i(t) = |T_i^{\text{pred}}(t) - T_i^{\text{meas}}(t)| \quad (5)$$

式中, $T_i^{\text{pred}}(t)$ 表示第 i 个组件在 t 时刻的预测温度, $T_i^{\text{meas}}(t)$ 表示对应的实际测量温度, $\Delta T_i(t)$ 表示温度偏差。当 $\Delta T_i(t)$ 大于预设阈值时, 系统判定该组件存在异常状态并输出故障告警; 否则输出正常运行结果。

$$\text{Alarm}_i(t) = \begin{cases} 1, & \Delta T_i(t) > T_{th} \\ 0, & \Delta T_i(t) \leq T_{th} \end{cases} \quad (6)$$

3.4. 模型评价指标

为评价故障检测和分类结果, 采用准确率、精确率、召回率和 F1 值作为模型性能指标。其定义如下:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (8)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (9)$$

$$F_1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

其中, TP 表示真正例, TN 表示真负例, FP 表示假正例, FN 表示假负例。准确率反映总体判断正确程度, 精确率反映故障告警结果的可信度, 召回率反映潜在故障的检出能力, F1 值反映精确率与召回率之

间的综合平衡。

4. 实现流程

从系统实现角度看，所述方法可部署于配电网预测性维护系统或智能电网控制中心。系统通过通信网络接入传感器、智能电表、电力线路传感器和 SCADA 监测系统，形成数据采集层；通过数据清洗、标准化、归一化、特征提取和主成分分析形成数据处理层；通过机器学习集成模型、状态监测和维护调度形成预测性维护层；最终输出故障预警、维护计划和调度建议，如图 3 所示。




Figure 3. Layered architecture of the predictive maintenance system
图 3. 配电网预测性维护系统分层架构

在在线应用阶段，系统实时接收配电网运行数据，并按照与模型训练阶段一致的数据预处理、特征提取和特征选择流程生成关键特征。关键特征输入训练完成的模型后，模型输出故障类别、温度偏差判断结果和维护建议。对于存在异常的组件，系统输出故障告警和维护优先级；对于未出现异常的组件，系统输出正常运行结果。随着新增运行数据不断积累，系统可对模型进行持续验证和更新。

5. 算例验证与结果分析

5.1. 算例数据

为验证所述方法的有效性，可采用四节点参考星型网络的合成配电网稳定性数据进行模型训练与测试。初始数据集包括 10,000 条观测数据，经节点排列扩展后形成 60,000 条观测数据，并包含 12 个核心预测特征和 2 个因变量。模型设计与预测过程可采用 Python 语言，并结合 TensorFlow 和 scikit-learn 等工具实现。具体仿真环境及数据集参数如表 2 所示。

Table 2. Simulation environment and dataset parameters
表 2. 仿真环境及数据集参数

参数项目	参数内容
数据集类型	合成数据集
参考网络类型	四节点参考星型网络
初始观测数据量	10,000 条
扩展后观测数据量	60,000 条
核心预测特征数量	12 个
因变量数量	2 个
仿真周期	100 次
模型实现工具	Python, TensorFlow, scikit-learn

5.2. 验证结果

根据测试集预测结果计算模型评价指标，得到表 3 所示的预测性维护验证结果。

Table 3. Verification results of the predictive maintenance model
表 3. 预测性维护模型验证结果

评价指标	本方法结果
预测性维护准确率	98.5%
总体准确率	98.9%
精确率	97.1%
召回率	96.5%
F1 值	97.4%

由表 3 可以看出，本文方法在预测性维护准确率、总体准确率、精确率、召回率和 F1 值等指标上均取得较高结果，说明该方法能够基于配电网运行数据较准确地完成设备状态识别、故障类型判断和异常状态检测。较高的预测性维护准确率和总体准确率表明，所述方法能够提升潜在故障预测的可靠性；较高的精确率表明模型输出的故障判断结果具有较高可信度，能够减少误告警；较高的召回率表明该方法能够有效发现潜在故障，降低漏检风险；较高的 F1 值表明该方法在故障识别准确性和故障覆盖能力之间具有良好平衡。

因此，所述方法能够提高配电网预测性维护的智能化水平，提前发现设备异常和运行风险，降低非计划停机概率，减少人工巡检和事后维修成本，并为运维人员制定维护计划提供可靠依据。

6. 结语

本文围绕配电网预测性维护需求，提出一种基于机器学习集成模型的预测性维护方法。该方法通过采集传感器数据、智能电表数据、电力线路传感器数据、SCADA 历史数据、实时监测数据、负荷数据、环境数据、设备工作状态数据和组件温度数据，构建多源运行数据基础；通过缺失值填补、异常值处理、标准化和归一化处理提高数据可用性；通过特征提取和主成分分析筛选关键特征；通过机器学习集成模型实现故障检测、分类和组件温度异常告警。

算例验证结果表明，该方法具有较高的预测性维护准确率、总体准确率、精确率、召回率和 F1 值，

能够有效识别配电网设备潜在故障和运行异常状态，为故障预警、维护计划制定和状态检修提供决策支持。与依赖人工经验或定期巡检的传统维护方式相比，所提方法能够充分利用多源运行数据中的状态变化信息，实现由事后维修和定期维护向状态感知、故障预警和主动维护转变，有助于降低设备故障漏检率和误告警率，减少非计划停电风险，提高配电网运行的安全性、可靠性和维护效率。

后续研究可进一步结合真实配电网长期运行数据、不同区域负荷特性和多类型设备运行机理，对模型的泛化能力、在线更新机制和工程部署效果进行深入验证。同时，可进一步研究模型在边缘计算终端、智能电网控制中心和运维决策支持系统中的协同部署方式，提升预测性维护结果的实时性、可解释性和工程可用性。

参考文献

- [1] 邓儒斌. 基于人工智能的配网自动化运维决策支持系统研究[C]//江西省汽车工程学会. 工程技术创新发展学术研讨会论文集(第一册). 2026: 198-200.
- [2] 郭秋可, 周健, 刘德远. 智能监测技术在配电网运行维护中的应用[J]. 灯与照明, 2026, 50(3): 173-175.
- [3] 高策. 基于人工智能的配电网故障预测与预防策略研究[J]. 智能建筑与智慧城市, 2025(S2): 96-98.
- [4] 陈笙. 基于人工智能的电网异常检测与故障诊断系统设计[J]. 集成电路应用, 2025, 42(11): 704-705.
- [5] 陆宁云, 陈闯, 姜斌, 等. 复杂系统维护策略最新研究进展: 从视情维护到预测性维护[J]. 自动化学报, 2021, 47(1): 1-17.
- [6] 李杰其, 胡良兵. 基于机器学习的设备预测性维护方法综述[J]. 计算机工程与应用, 2020, 56(21): 11-19.
- [7] 袁烨, 张永, 丁汉. 工业人工智能的关键技术及其在预测性维护中的应用现状[J]. 自动化学报, 2020, 46(10): 2013-2030.
- [8] Tan, C.K. and Ramachandaramurthy, V.K. (2012) Novel Wide-Area Fault Location and Predictive Maintenance Technique for Distribution System. *IEEJ Transactions on Electrical and Electronic Engineering*, 7, 152-160.
<https://doi.org/10.1002/tee.21710>
- [9] Yang, X., Xiang, Y. and Wang, Q. (2026) Seasonally Adaptive Fault Forecasting for Proactive and Resilient Maintenance in Urban Power Distribution Networks. *Signal, Image and Video Processing*, 20, 458-458.
<https://doi.org/10.1007/s11760-026-05520-1>