

# 工业4.0视角下的预测性维护

方亮亮, 吴旭, 陈祿

先进操作系统创新中心(天津)有限公司, 天津 300459

**摘要:** 在工业4.0时代, 预测性维护作为智能制造的重要组成部分, 通过集成物联网(IoT)、大数据、云计算、机器学习等先进技术, 实现了对生产设备状态的实时监控与精准预测, 从而有效减少非计划停机时间, 提升生产效率与设备寿命。然而, 当前预测性维护在实施过程中仍面临诸多挑战, 如数据量不足、数据质量低、建模难度大、维护决策复杂及投资回报率难以预估等。

本文将结合工业4.0的核心理念与技术优势, 探讨如何解决这些问题, 推动预测性维护的深入应用。

**关键词:** 工业4.0; 预测性维护; 预测建模

## Predictive Maintenance from the Perspective of Industry 4.0

Fang Liangliang, Wu Xu, Chen Lu

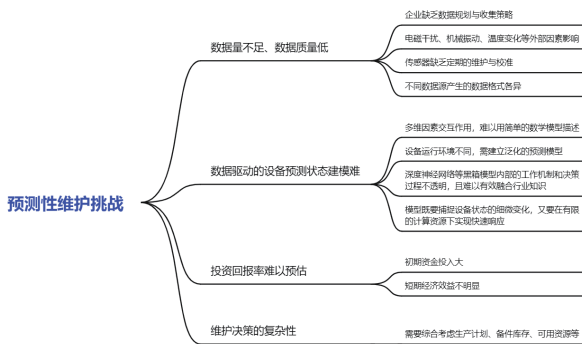
Advanced Operating System Innovation Center (Tianjin) Co., Ltd. Tianjin 300459

**Abstract:** In the era of Industry 4.0, predictive maintenance, as an important part of intelligent manufacturing, achieves real-time monitoring and accurate prediction of the status of production equipment by integrating advanced technologies such as the Internet of Things (IoT), big data, cloud computing, and machine learning., thereby effectively reducing unplanned downtime and improving production efficiency and equipment life. However, current predictive maintenance still faces many challenges in the implementation process, such as insufficient data volume, low data quality, difficulty in modeling, complex maintenance decisions, and difficulty in predicting the return on investment. This paper will combine the core concepts and technical advantages of Industry 4.0 to explore how to solve these problems and promote the in-depth application of predictive maintenance.

**Keywords:** Industry 4.0; predictive maintenance; predictive modeling

### 一、预测性维护存在的问题

预测性维护作为一种先进的设备管理策略, 虽然具有巨大的潜力, 但在实际工业场景应用中却面临着诸多挑战。



#### (一) 数据量不足、数据复杂多样且数据质量低

企业在引入生产过程管理之初, 往往缺乏全面的数据规划和收集策略, 导致关键数据未被及时采集或记录<sup>[7]</sup>。或因数据存储期限或物理容量限制, 未建立长期存储策略, 导致数据遗失和完整性不足。另外, 出于安全性考虑, 许多工业现场对设备或系统的开放性和访问权限进行了限制, 也会造成数据缺失, 安全隔离措施可能导致不同系统之间的数据无法有效共享, 造成数据孤岛现象<sup>[8]</sup>。

传感器往往部署在复杂的工业环境中, 可能受到电磁干扰、机械振动、温度变化等多种外部因素的影响。如果抗干扰措施不

足或不当, 如屏蔽层损坏、接地不良等, 会导致传感器采集到的数据含有噪声或异常值, 无法满足行业或应用标准<sup>[9]</sup>。长时间运行后, 数据采集设备和传感器可能会因为磨损、老化或环境影响而出现性能下降。

工业环境中, 数据不仅来源于设备本身(如振动、温度、压力传感器), 还包括通过各种无损检测技术(如红外、超声、射线检测)获取的图像、音频视频数据, 以及来自ERP、MES等管理系统的运营、物流、服务等多维度数据。不同数据源产生的数据格式各异, 包括结构化数据(如数据库中的记录)、半结构化数据(如JSON、XML文件)和非结构化数据(如图像、音频、视频文件、文本文档)。由于设备状态、传感器精度、数据传输过程中的干扰等因素, 数据质量参差不齐, 包括噪声、缺失值、异常值等。另外, 在预测性维护中, 健康状态下的数据远多于故障或退化状态的数据, 这种不平衡性会导致模型在训练过程中更关注于健康状态, 而忽略了对故障状态的识别能力。

#### (二) 数据驱动的设备状态预测建模难

多维因素(如运载负荷强度、温度、湿度、人为因素等)之间往往存在复杂的交互作用, 难以用简单的数学模型来准确描述。不同因素的数据来源、格式、精度和采样频率各不相同, 这种异构性和多样性增加了数据整合和处理的难度<sup>[11]</sup>。因此, 将多维监测信息合理的融合实现设备状态预测仍然非常具有挑战性。

设备的负载变化、运行模式切换、维护历史等内部因素也会

导致设备状态的动态变化。不同负载下设备的磨损速率、热应力分布等都会有所不同，从而影响设备的寿命和故障模式。天气、季节变化外部因素不仅直接影响设备的运行条件（如温度、湿度、风速等），还可能间接影响设备的性能参数和故障率。

黑箱模型如深度神经网络等，虽然能够在复杂数据中捕捉到隐藏的模式和关系，但其内部的工作机制和决策过程往往是不透明的。这导致当模型做出预测时，难以验证其是否符合工业领域的物理规律或专家知识<sup>[2]</sup>。由于黑箱模型的不可解释性，当预测结果不准确或不符合预期时，很难定位问题所在并进行有效的调试。工业领域积累了大量的专业知识和经验，这些知识和经验对于提高设备状态预测的准确性和可靠性至关重要。然而，黑箱模型很难有效地融合这些行业知识，因为它们通常依赖于数据驱动的方式进行学习，而不太考虑先验知识或规则。

工业设备状态监测和预测需要实时或近实时处理，确保在故障出现前及时预警，对计算资源和算法效率有较高要求。但复杂度过高的模型不仅难以解释和维护，还可能因计算资源不足而影响实时性。因此，模型复杂度需要适中，既能捕捉设备状态的细微变化，又能在有限的计算资源下实现快速响应。模型复杂度与实时性之间的平衡需求，增加了状态预测建模的难度。

### （三）基于预测信息的维护决策的复杂性

维护决策是一项复杂的任务，它不仅需要深入分析设备的故障预测结果，还要综合考虑生产计划、备件库存和维护资源等多重要素，以制定出最优化的维护策略<sup>[1]</sup>。这要求决策系统不仅要具备精密的决策逻辑，还要有处理大量数据的强大能力。

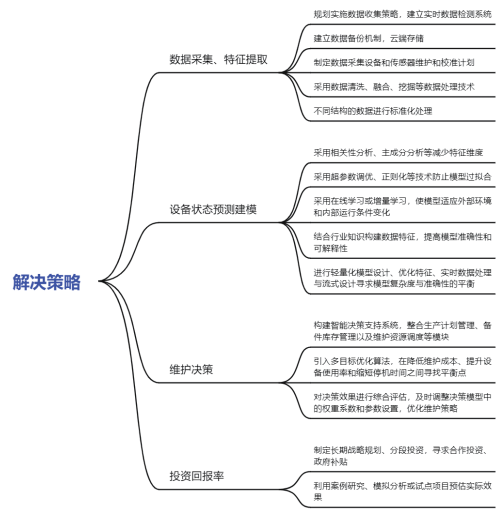
在制定维护决策时，通常面临多个目标的平衡问题，例如减少维护成本、提高设备的使用率和缩短停机时间。这些目标之间可能会相互冲突，需要通过精心设计来达到最佳平衡点。随着设备状态的不断变化和外部环境的动态演进，维护策略也必须灵活调整，以适应新的情况。这就要求决策系统不仅要有高度的灵活性，还要具备快速响应变化的能力。

### （四）投资回报率难以预估

预测性维护的实施是一项长期且复杂的任务，它要求不断的迭代与优化，短期内的经济效益并不明显，这一特性往往使企业对预测性维护的持续投资持审慎态度，甚至可能做出暂缓或终止项目的决策。鉴于投资回报周期的不确定性，企业在制定相关决策时，必须更为深入地评估项目的长远价值及其伴随的潜在风险，以确保决策的合理性与可持续性。另外，预测性维护技术的初期阶段伴随着高昂的资金需求，这些费用涵盖了从软硬件的研发升级与无缝集成，到传感器的精密部署，再到专业人员的系统培训，以及海量数据的存储与高效处理等多个方面。这些成本可能会超出企业的初步预算或财务承受能力，从而对项目的顺利推进构成挑战。

## 二、解决策略

本章将针对预测性维护在实际推进过程中遇到的挑战，提供相应的解决策略和改进措施，以期推动预测性维护技术在工业中的发展和应用。



### （一）提升数据量和数据质量

规划并实施全面的数据收集策略，确保能够捕获所有与设备状态、生产流程等相关的关键数据。建立实时数据监测系统，对关键设备和生产流程进行不间断的数据采集，避免数据遗漏。根据数据增长的速度和规模，定期评估和扩展数据存储设备的容量，确保有足够的空间来存储长期数据。建立定期的数据备份机制，将重要数据备份到不同的存储介质上，以防数据丢失或损坏。利用云存储的灵活性和可扩展性，将部分或全部数据存储在云端，减轻本地存储的压力，并确保数据的安全性和可访问性<sup>[9]</sup>。通过数据接口和网关技术，实现不同系统之间的数据互通和共享，提高数据的可用性。

对传感器周围环境进行细致的评估，确定潜在的干扰源，并采取相应的抗干扰措施。例如，使用更优质的屏蔽材料、优化接地设计、增加滤波器以减少电磁干扰<sup>[14]</sup>；采用减震装置来减少机械振动对传感器的影响；确保传感器处于适宜的温度范围内，或使用温度补偿技术来减少温度变化对测量精度的影响。制定详细的数据采集设备和传感器维护和校准计划，并严格执行。定期对设备进行清洁、润滑、紧固等操作，保持其良好的运行状态。利用数据清洗、数据融合、数据挖掘等先进的数据处理技术，对采集到的原始数据进行预处理和分析。通过去除噪声、填补缺失值、纠正异常值等操作，提高数据的准确性和可靠性。

采用 ETL (Extract, Transform, Load) 工具或数据流处理框架（如 Apache Kafka, Apache NiFi）来集成来自不同源的数据。建立统一的数据仓库或数据湖，以存储和管理这些数据。对于不平衡数据，可采用过采样、欠采样或合成少数类过采样技术 (SMOTE) 等方法进行平衡处理。对于不同量纲和尺度的数据，进行归一化或标准化处理，确保模型训练时各特征具有相同的权重。

### （二）设备状态预测建模策略

针对不同类型的数据，采用特征提取方法，提取出设备状态预测相关的特征。通过相关性分析、主成分分析 (PCA) 等方法，选择出对预测结果影响最大的特征，减少特征维度，提高模型训练效率。在特征提取后，将不同来源的特征进行融合，形成更全面的特征表示。分别训练多个子模型处理不同类型的数据或不同维度的特征，然后将各子模型的预测结果进行融合，如采用投票、加权平均等方法，提高整体预测精度。

结合多个机器学习器（如随机森林、梯度提升树、神经网络）的预测结果，通过集成策略提高模型的泛化能力和预测精度<sup>[9]</sup>。采用超参数调优、正则化、dropout等技术防止模型过拟合，提高模型的泛化能力。采用在线学习或增量学习算法，使模型能够随着新数据的到来不断更新和调整参数，以适应外部环境和内部运行条件的变化。引入时间序列分析技术（如ARIMA、LSTM等），捕捉设备状态随时间变化的趋势和周期性规律。利用机器学习或深度学习模型，分析外部环境因素（如天气、季节）与设备状态之间的关联关系<sup>[4]</sup>。

在建模时，优先考虑使用可解释性强的机器学习模型，如决策树、逻辑回归、支持向量机等<sup>[15]</sup>。在特征工程阶段，充分利用行业知识和经验来构建有意义的特征。这些特征应该能够反映设备的物理特性、运行条件和历史维护记录等关键信息。将多个可解释性强的模型进行融合或集成，以提高整体预测性能。例如，可以使用投票法、堆叠法或加权平均法等方法将多个模型的预测结果进行组合。建立持续监控和反馈机制，对模型的预测结果进行实时跟踪和评估。当预测结果不符合预期时，及时进行分析和调试，并根据反馈结果对模型进行优化和改进，提高模型的预测准确性和可靠性。

通过轻量化模型设计、优化特征、实时数据处理与流式计算等方法寻求复杂度与准确性的平衡。采用计算效率高的机器学习算法，如线性回归、决策树、随机森林等，这些算法通常具有较低的计算复杂度和较快的训练速度。对于使用深度学习等复杂模型的场景，通过剪枝、量化、蒸馏等技术对模型进行压缩，减少模型参数和计算量，提高实时性<sup>[6]</sup>。通过主成分分析（PCA）、线性判别分析（LDA）等方法对特征进行降维处理，减少模型计算量<sup>[10]</sup>。采用Apache Kafka、Flink等流处理框架，对设备数据进行实时采集、处理和分析，确保数据的新鲜度和实时性。模型应具备增量学习能力，能够在线接收新数据并更新模型参数，以适应设备状态的动态变化，同时避免重新训练整个模型带来的计算负担。

### （三）基于预测信息的维护决策的复杂性

构建智能决策支持系统，整合生产计划管理、备件库存管理以及维护资源调度等多个关键模块，实现对多方面因素的综合分析和优化决策。引入了多目标优化算法，如遗传算法和粒子群优化算法，以在降低维护成本、提升设备使用率和缩短停机时间等多个目标之间寻找到最佳的平衡点。通过为这些目标设定不同的权重系数，系统能够根据企业的具体需求和优先级，制定出切实可行的维护策略。

为了确保维护策略的持续有效性，定期对决策效果进行综合评估，分析各个目标的达成情况及其相互影响。根据这些评估结果，及时调整决策模型中的权重系数和参数设置，以优化维护策略并适应不断变化的生产环境<sup>[13]</sup>。实时监测设备状态和外部环境变化，建立有效的反馈机制，将最新的监测数据及时传递给决策支持系统，动态调整维护策略，确保维护工作的及时性和准确性。

### （四）投资回报率难以预估

企业应制定清晰的长期战略规划，明确预测性维护在整体运营优化中的角色与预期目标。深入进行成本效益的剖析，量化预测性维护带来的诸如停机时间锐减、维修成本压缩等显性效益，并评估其对生产效率提升、产品质量优化等的影响。针对投资回报周期的

不确定性，企业可以采取分阶段投资的方式，根据项目实施效果和资金状况灵活调整投资规模。探索创新的融资模式，如合作投资、政府补贴或第三方服务提供商的参与，以分担初期投入成本等。

## 三、总结

本文深入探讨了工业4.0背景下预测性维护的应用及其面临的挑战与解决方案。预测性维护通过集成物联网、大数据、云计算及机器学习技术，实现了对生产设备的实时监控与精准预测，提升了生产效率和设备寿命。然而，实施过程中仍面临数据量不足、数据质量低、建模难度大、维护决策复杂及投资回报率难以预估等问题。

为解决这些挑战，论文提出了一系列策略：在数据层面，建议规划全面的数据收集策略，提升数据质量与数量，并采用ETL工具实现数据整合；在建模方面，推荐结合行业知识与可解释性强的机器学习模型，提高模型精度与可靠性；在决策上，构建智能决策支持系统，实现多目标优化；最后，通过制定长期战略规划与分阶段投资，确保预测性维护项目的可持续性与经济效益。

本文为预测性维护技术在工业领域的深入应用提供了系统性指导，有助于企业更好地应对设备维护的复杂性，实现生产过程的智能化与高效化。

## 参考文献

- [1] 周东华, 魏慕恒, 司小胜. 工业过程异常检测、寿命预测与维修决策的研究进展[J]. 自动化学报, 2013, 39(06): 711-722.
- [2] 袁峰, 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. DOI: 10.16383/j.aas.c200333.
- [3] Achouch, Mounia & Dimitrova, Mariya & Ziane, Khaled & Sattarpanah Karganroudi, Sasan & Dhoubib, Rizck & Ibrahim, H. & Adda, Mehdi. (2022). On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. Applied Sciences. 12. 8081. 10.3390/app12168081.
- [4] 王凯, 李元辉. 迁移学习在机械设备预测性维护领域的应用综述[J]. 中国仪器仪表, 2019, (12): 64-68.
- [5] 郑晓雨, 樊重俊. 基于全局搜索策略WOA优化ELM的RUL预测性维护[J]. 智能计算机与应用, 2024, 14(02): 144-149.
- [6] 毛凯, 吴锋, 薛红波等. 基于数据的预测性维护方法创新[J]. 设备管理与维修, 2023, (15): 32-34. DOI: 10.16621/j.cnki.issn1001-0599.2023.08.14.
- [7] 骆健恒. 数字化运维与预测性维护工厂安全生产的重要一环[J]. 中国安防, 2023, (05): 98-100.
- [8] 张建雄, 吴晓丽, 杨震等. 基于工业物联网的工业数据采集技术研究与应用[J]. 电信科学, 2018, 34(10): 124-129.
- [9] 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.
- [10] 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(01): 1-17. DOI: 10.16383/j.aas.c200227.
- [11] 祝旭. 故障诊断及预测性维护在智能制造中的应用[J]. 自动化仪表, 2019, 40(07): 66-69. DOI: 10.16086/j.cnki.issn1000-0380.2019030334.
- [12] 禹鑫, 施甜峰, 唐权瑞等. 面向预测性维护的工业设备管理系统[J]. 计算机科学, 2020, 47(S2): 667-672+677.
- [13] 戴义明, 杨明波. 工业互联网条件下智能维修的预测性维护策略[J]. 设备管理与维修, 2017, (19): 62-63. DOI: 10.16621/j.cnki.issn1001-0599.2017.12D.34.
- [14] 常宏, 朱艳梅, 徐小成等. 物联网技术在设备预测性维护中的应用[J]. 物流工程与管理, 2018, 40(09): 79-80+63.
- [15] 彭壮林, 肖宏, 肖逸军, 等. 基于决策树的设备预测性维护[J]. 数字通信世界, 2018, (08): 68-69.