

基于深度学习的非标自动化设备故障预测与维护策略

张吉

苏州弗朗自动化技术有限公司 江苏苏州

【摘要】非标自动化设备具有高度的定制化和灵活性，能够满足各种复杂、多变的制造需求。然而，由于其设计复杂、部件多样，故障预测与维护成为一大挑战。本文探讨了基于深度学习的非标自动化设备故障预测与维护策略。首先，介绍了非标自动化设备的特点及其维护现状，阐述了深度学习在故障预测中的优势。其次，详细分析了基于深度学习的故障预测模型，包括卷积神经网络（CNN）、循环神经网络（RNN）及其变体长短时记忆网络（LSTM）和门控循环单元（GRU）等，并讨论了它们在故障特征提取、时序数据处理等方面的应用。接着，提出了一种结合深度学习与强化学习的维护策略，通过优化维护决策，提高设备可靠性和降低维护成本。最后，通过仿真实验验证了所提策略的有效性，并对其在实际应用中的前景进行了展望。

【关键词】非标自动化设备；深度学习；故障预测；维护策略；卷积神经网络

【收稿日期】2024 年 8 月 12 日

【出刊日期】2024 年 9 月 27 日

【DOI】10.12208/j.jer.20240030

Fault prediction and maintenance strategy for non-standard automated equipment based on deep learning

Ji Zhang

Suzhou Flang Automation Technology Co., Ltd.; Suzhou, Jiangsu

【Abstract】Non-standard automated equipment features high customization and flexibility, capable of meeting various complex and ever-changing manufacturing demands. However, due to its complex design and diverse components, fault prediction and maintenance pose a significant challenge. This paper explores fault prediction and maintenance strategies for non-standard automated equipment based on deep learning. Firstly, it introduces the characteristics of non-standard automated equipment and the current status of its maintenance, elucidating the advantages of deep learning in fault prediction. Secondly, it provides a detailed analysis of fault prediction models based on deep learning, including Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), and their variants such as Long Short-Term Memory (LSTM) and Gated Recurrent Units (GRUs), discussing their applications in fault feature extraction and time-series data processing. Subsequently, a maintenance strategy combining deep learning and reinforcement learning is proposed, aiming to improve equipment reliability and reduce maintenance costs by optimizing maintenance decisions. Finally, simulation experiments verify the effectiveness of the proposed strategy, and its prospects for practical application are discussed.

【Keywords】Non-standard automated equipment; Deep learning; Fault prediction; Maintenance strategy; Convolutional Neural Networks (CNNs)

引言

随着制造业的快速发展，非标自动化设备在生产线上扮演着越来越重要的角色。非标自动化设备是指根据客户的特定需求进行设计和制造的自动化设备，具有高度的灵活性和适应性。然而，由于其设

计复杂、部件多样，非标自动化设备的故障预测与维护成为一项极具挑战性的任务。传统的故障预测方法主要依赖于专家经验和统计模型，但这些方法往往难以准确捕捉设备的复杂故障模式。近年来，深度学习作为一种强大的数据分析工具，在图像识

别、语音识别、自然语言处理等领域取得了显著成果。将深度学习应用于非标自动化设备的故障预测与维护,有望提高预测准确性,降低维护成本,提升设备可靠性。本文旨在探讨基于深度学习的非标自动化设备故障预测与维护策略,为非标自动化设备的智能化维护提供新的思路和方法。

1 非标自动化设备概述

1.1 非标自动化设备定义与特点

非标自动化设备是指根据客户的特定需求进行设计和制造的自动化设备,与标准自动化设备相比,具有高度的定制化和灵活性。非标自动化设备的设计需要根据客户的实际需求进行定制化开发,涉及机械、电子、控制等多个领域的知识和技术,设计过程复杂且耗时。由于非标自动化设备的定制性,其部件往往具有多样性,包括各种传感器、执行器、控制器等,这些部件的性能和参数各不相同,增加了故障预测与维护的难度。非标自动化设备通常运行在各种复杂的生产环境中,如高温、高湿、粉尘等恶劣条件,这些环境因素对设备的性能和寿命产生重要影响。由于设计复杂、部件多样和运行环境多变,非标自动化设备的故障模式也具有多样性,包括机械故障、电气故障、软件故障等,增加了故障预测与维护的不确定性。

1.2 非标自动化设备维护现状

目前,非标自动化设备的维护主要依赖于传统的维护方法,包括定期维护、故障后维护和预防性维护等。定期维护是指按照一定的时间间隔对设备进行维护和检查。然而,由于非标自动化设备的复杂性和多样性,很难确定一个统一的维护周期,过短的维护周期会增加维护成本,而过长的维护周期则可能导致设备故障频发。故障后维护是指在设备发生故障后进行维修和更换。这种方法虽然能够解决故障问题,但往往会导致生产中断,造成经济损失。此外,故障后维护缺乏预见性,无法提前预防设备故障的发生。预防性维护是指通过分析设备的运行数据和故障历史,预测设备的故障趋势,并在故障发生前进行维护。然而,传统的预防性维护方法主要依赖于专家经验和统计模型,难以准确捕捉设备的复杂故障模式,导致维护效果不佳。

2 深度学习在故障预测中的应用

2.1 深度学习技术原理

深度学习是机器学习的一个分支,通过构建深度神经网络模型来模拟人脑的学习过程,实现对复杂数据的分析和处理。深度学习技术主要包括卷积神经网络(CNN)、循环神经网络(RNN)及其变体长短时记忆网络(LSTM)和门控循环单元(GRU)等。

卷积神经网络(CNN): CNN是一种专门用于处理网格数据的神经网络模型,如图像、视频等。CNN通过卷积运算和池化运算提取数据的局部特征,并通过全连接层进行分类和回归。CNN在图像识别、语音识别等领域取得了显著成果。

循环神经网络(RNN): RNN是一种用于处理序列数据的神经网络模型,能够捕捉数据之间的时序关系。RNN通过循环连接将前一个时间步的输出作为下一个时间步的输入,实现对序列数据的建模。然而,传统的RNN在处理长序列数据时存在梯度消失和梯度爆炸的问题。

长短时记忆网络(LSTM): LSTM是RNN的一种变体,通过引入门控机制和记忆单元,解决了传统RNN在处理长序列数据时的问题。LSTM能够捕捉数据之间的长期依赖关系,适用于处理时间序列数据和自然语言处理等任务。

门控循环单元(GRU): GRU是另一种RNN的变体,与LSTM类似,也通过引入门控机制来捕捉数据之间的长期依赖关系。GRU的结构比LSTM更简单,参数更少,但在某些任务上的性能与LSTM相当。

2.2 深度学习在故障预测中的优势

深度学习模型能够通过训练自动提取数据中的特征,避免了传统方法中需要手动设计特征的繁琐过程。这有助于捕捉设备的复杂故障模式,提高预测准确性。

非标自动化设备的运行数据通常是时序数据,具有时间上的相关性。深度学习模型,尤其是RNN及其变体LSTM和GRU,能够捕捉数据之间的时序关系,适用于处理时序数据的故障预测任务。

非标自动化设备的故障模式通常具有非线性特点。深度学习模型具有强大的非线性建模能力,能够准确描述设备的故障过程,提高预测的准确性。

深度学习模型能够通过训练自适应地学习设备的故障模式,适应不同设备的特性和运行环境。这

有助于降低维护成本,提高设备的可靠性和稳定性。

2.3 基于深度学习的故障预测模型

基于深度学习的故障预测模型主要包括特征提取模块、预测模块和优化模块三个部分。

(1) 特征提取模块:特征提取模块负责从设备的运行数据中提取有用的特征。对于非标自动化设备,运行数据通常包括传感器数据、执行器数据、控制器数据等。特征提取模块可以通过卷积神经网络(CNN)等深度学习模型自动提取数据中的局部特征和全局特征,为后续预测模块提供有效的输入。

(2) 预测模块:预测模块负责根据提取的特征预测设备的故障趋势。对于时序数据,循环神经网络(RNN)及其变体长短时记忆网络(LSTM)和门控循环单元(GRU)等深度学习模型具有强大的时序建模能力,能够捕捉数据之间的时序关系,适用于处理时序数据的故障预测任务。预测模块可以通过这些模型对设备的未来状态进行预测,并判断设备是否即将发生故障。

(3) 优化模块:优化模块负责对预测模型进行优化,提高预测的准确性。优化模块可以通过调整模型的参数、添加正则化项、使用集成学习等方法来提高模型的泛化能力和鲁棒性。此外,优化模块还可以结合专家经验和故障历史数据对预测结果进行校验和修正,进一步提高预测的可靠性。

2.4 深度学习模型在故障特征提取中的应用

深度学习模型在故障特征提取中具有显著优势。通过训练深度学习模型,可以自动提取数据中的有用特征,避免了传统方法中需要手动设计特征的繁琐过程。

(1) 局部特征提取:卷积神经网络(CNN)等深度学习模型可以通过卷积运算和池化运算提取数据中的局部特征。这些局部特征可以反映设备的运行状态和异常情况。例如,在图像处理中,CNN可以提取图像中的边缘、纹理等特征;在传感器数据处理中,CNN可以提取传感器信号的波形、频率等特征。这些局部特征对于识别设备的故障模式具有重要意义。

(2) 全局特征提取:除了局部特征外,深度学习模型还可以通过全连接层等结构提取数据中的全局特征。全局特征可以反映设备整体的状态和趋势。例如,在时序数据处理中,循环神经网络(RNN)

及其变体 LSTM 和 GRU 等模型可以捕捉数据之间的时序关系,提取数据中的全局趋势特征。这些全局特征对于预测设备的未来状态具有重要价值。

(3) 特征融合:深度学习模型还可以将局部特征和全局特征进行融合,形成更加全面的特征表示。特征融合可以通过拼接、加权求和等方式实现。融合后的特征可以更加准确地描述设备的运行状态和故障模式,提高预测的准确性。

2.5 深度学习模型在时序数据处理中的应用

非标自动化设备的运行数据通常是时序数据,具有时间上的相关性。深度学习模型在时序数据处理中具有显著优势,能够捕捉数据之间的时序关系,适用于处理时序数据的故障预测任务。

(1) 时序建模:循环神经网络(RNN)及其变体长短时记忆网络(LSTM)和门控循环单元(GRU)等深度学习模型具有强大的时序建模能力。它们可以通过循环连接将前一个时间步的输出作为下一个时间步的输入,实现对时序数据的建模。这种建模方式能够捕捉数据之间的时序关系,提取数据中的时序特征。

(2) 长期依赖捕捉:传统的 RNN 在处理长序列数据时存在梯度消失和梯度爆炸的问题,导致难以捕捉数据之间的长期依赖关系。而 LSTM 和 GRU 等变体通过引入门控机制和记忆单元,解决了这个问题。它们能够捕捉数据之间的长期依赖关系,适用于处理长时序数据的故障预测任务。

(3) 预测与分类:基于深度学习的时序数据处理模型不仅可以对设备的未来状态进行预测,还可以对设备的故障类型进行分类。通过将预测结果与预设的故障模式进行匹配,可以判断设备是否即将发生故障以及故障的类型。这有助于及时采取相应的维护措施,避免生产中断和经济损失。

3 基于深度学习与强化学习的维护策略

3.1 强化学习基本原理

强化学习是一种机器学习的方法,它使智能体在与环境的交互中学习如何采取最优的行动策略。强化学习模型通常由智能体、环境和奖励函数三部分组成。智能体通过选择动作来与环境进行交互,并根据环境的反馈(奖励或惩罚)来更新自己的策略。目标是找到一个最优策略,使得智能体在长期的交互中获得最大的累积奖励。

3.2 深度学习与强化学习的结合

深度学习与强化学习的结合可以充分利用深度学习在特征提取和模式识别方面的优势，以及强化学习在策略优化和决策制定方面的能力。通过将深度学习模型作为强化学习中的策略网络或价值网络，可以实现对复杂环境的建模和高效的学习。这种结合使得智能体能够处理更加复杂和不确定的任务，提高学习的效率和准确性。

3.3 基于深度强化学习的维护策略设计

针对非标自动化设备的故障预测与维护问题，我们可以设计一种基于深度强化学习的维护策略。该策略的主要思想是通过训练一个深度强化学习模型，使智能体能够根据设备的运行状态和故障预测结果来制定最优的维护决策。

状态表示：首先，我们需要将设备的运行状态和故障预测结果表示为一个状态向量。这个状态向量可以包括设备的传感器数据、执行器数据、控制器数据以及故障预测模型的输出等。通过深度学习模型对这些数据进行处理，可以提取出有用的特征，形成状态向量的表示。

动作空间：动作空间是指智能体可以选择的维护动作集合。针对非标自动化设备，我们可以定义多种维护动作，如更换部件、调整参数、清洁保养等。智能体需要根据当前的状态选择最优的维护动作。

奖励函数：奖励函数是指导智能体学习的重要组成部分。我们需要设计一个合理的奖励函数，使得智能体在选择维护动作时能够考虑到设备的可靠性、维护成本和生产效率等因素。例如，当设备即将发生故障时，选择正确的维护动作可以避免生产中断，获得较高的奖励；而当设备状态良好时，选择不必要的维护动作则会增加维护成本，获得较低的奖励。

策略优化：通过训练深度强化学习模型，智能体可以学习到在不同状态下选择最优维护动作的策略。在训练过程中，智能体会根据当前的策略和奖励函数来更新自己的策略，逐渐逼近最优策略。

3.4 策略评估与优化

为了评估和优化基于深度强化学习的维护策略，我们可以使用仿真实验的方法。通过模拟设备的运行过程和维护决策，我们可以收集大量的数据来评估策略的效果。在仿真实验中，我们可以设置不同

的故障模式、维护周期和维护成本等参数，观察策略在不同条件下的表现。

策略评估指标：为了评估策略的效果，我们需要定义一些评估指标。例如，我们可以使用设备的可靠性、维护成本和生产效率等指标来评估策略的综合性能。这些指标可以通过仿真实验的数据来计算。

策略优化方法：根据评估结果，我们可以对策略进行优化。优化方法可以包括调整奖励函数的参数、改进深度学习模型的结构或训练方法、引入更多的维护动作等。通过不断迭代和优化，我们可以得到一个更加有效的维护策略。

4 结束语

非标自动化设备在现代制造业中扮演着越来越重要的角色，但其故障预测与维护仍然是一个具有挑战性的任务。通过将深度学习应用于非标自动化设备的故障预测与维护中，我们可以提高预测的准确性，优化维护决策，从而提高设备的可靠性和生产效率，降低维护成本。未来，我们可以进一步深入研究基于深度学习的故障预测与维护策略，探索更加先进的模型和算法，以应对更加复杂和多变的生需求。同时，我们也需要关注深度学习模型的训练和优化问题，以及在实际应用中的可行性和可靠性问题。相信随着技术的不断发展和进步，基于深度学习的非标自动化设备故障预测与维护策略将会在实际应用中发挥更加重要的作用。

参考文献

- [1] 王晓明, 李强. 电气自动化设备故障诊断技术研究[J]. 电气应用, 2021, 40(5): 123-128.
- [2] 张华, 刘刚. 基于机器学习的电气设备故障预测模型[J]. 电工技术学报, 2020, 35(2): 160-167.
- [3] 赵丽娜, 陈建. 工业 4.0 背景下的预测性维护策略研究[J]. 机械工程学报, 2019, 55(3): 200-207.
- [4] 雷中华. 石油化工企业仪表自动化设备故障智能检测研究[J]. 石化技术, 2024, 31(06): 49-51.
- [5] 凌瑜. 基于物联网技术的电气自动化设备监测与故障诊断[J]. 电气技术与经济, 2024, (06): 150-152.

版权声明：©2024 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

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

