

基于跨专业长时间序列的故障预测模型及应用研究

于思宁¹, 任朝旭², 韩惠婕², 潘国庆²

(1. 中国航天标准化研究所, 北京 100166; 2. 北京航天测控技术有限公司, 北京 100041)

摘要: 装备的故障预测与预防性维修在装备维修保障领域至关重要, 针对装备维修保障领域提出了一种基于跨专业长时间序列的设备故障预测模型, 对深度学习中的长短时记忆网络 (LSTM) 等模型进行了应用研究, 利用模型处理跨不同专业的长时间序列数据, 成功构建了能够有效处理和分析不同专业设备数据的高效预测模型; 通过对某型装备系统健康状态监测的运行数据进行试验分析, 验证了该模型的工程应用性能, 通过对传感器数据的精准分析, 模型实现对装备系统潜在故障的提前识别, 针对测试集的故障预测准确率达到 95%, 表现出较高的准确性和稳定性并能够提前识别潜在的设备故障为维修人员提供及时的维护建议; 在装备领域为设备故障预测提供了更为有效的创新技术方案, 为装备维修保障工作提供工程应用价值。

关键词: 跨专业; 长时间序列; LSTM; 故障预测

Fault Prediction Model and Application Based on Cross-Disciplinary Long-Term Time Series

YU Sining¹, REN Zhaoxu², HAN Huijie², PAN Guoqing²

(1. China Academy of Aerospace Standardization and Product Assurance, Beijing 100166, China;

2. Beijing Aerospace Measurement & Control Technology Co., Ltd., Beijing 100041, China)

Abstract: It is of great significance for the prediction of equipment faults and preventive maintenance in the field of equipment maintenance support. To address the issue, this paper proposes a cross-disciplinary long-term time series-based equipment fault prediction model, focusing on the application of long short-term memory (LSTM) networks in deep learning. By processing and analyzing long-term time series data across different disciplines, an efficient predictive model is successfully constructed. Through experimental analysis on the health status operation data of a certain equipment system, the performance of the model is verified. The identification of potential faults in equipment system is achieved early in the model by precise analysis of sensor data, the accuracy of faults on the test set reached up to 95%, demonstrating high accuracy and stability. It can identify potential equipment faults in advance, and provides timely maintenance recommendations for personnel. This innovative technical solution significantly enhances fault prediction in the field of equipment and offers valuable engineering applications for repairing and supporting equipment.

Keywords: cross-disciplinary; long-term time series; LSTM; fault prediction

0 引言

在装备维修保障领域, 复杂装备通常在多种工况及不同环境中运行, 因而不同专业领域的设备可能面临不同的物理、化学和工艺性质的多重因素影响, 对故障预测模型提出了更高的要求, 因此通用的、跨专业的模型能够更好地适应多元化环境从而提高不同专业设备的预测准确性。在装备维修保障领域, 跨专业长时间序列故

障预测模型扮演着至关重要的角色, 复杂装备运行生成的数据通常具有长时间序列特点, 包括周期性、趋势、季节性等。基于长时间序列分析可识别潜在设备故障模式, 发现并预测设备可能出现的问题, 同时建立有效故障预测模型, 在设备真正发生故障之前采取预防性维护措施避免意外停机和维修从而优化资源利用, 降低维修成本, 提高设备可用性和稳定性^[1-6]。

装备维修保障涉及多学科交叉领域, 涵盖了机械、

收稿日期: 2024-06-24; 修回日期: 2024-10-18。

作者简介: 于思宁 (1991-), 男, 硕士研究生, 工程师。

引用格式: 于思宁, 任朝旭, 韩惠婕, 等. 基于跨专业长时间序列的故障预测模型及应用研究[J]. 计算机测量与控制, 2025, 33(2): 88-94.

电气、信息技术等多个学科。跨专业故障预测模型能够整合不同领域专业知识信息促进跨学科团队协作工作,跨专业长时间序列设备故障预测模型可以实现对设备状态的实时监测,确保设备的安全性和稳定性。考虑设备生命周期的故障预测模型可设计更具可维护性的设备,通过对不同专业设备故障数据分析为设备设计提供经验教训。因此跨专业长时间序列设备故障预测模型研究与应用对提高装备维修保障的效率、降低成本、增强设备可靠性和安全性等方面具有重要意义^[7-10]。

1 需求分析与研究概况

1.1 需求分析

根据装备的维修保障,深入分析装备维修保障领域中跨不同专业所面临的长时间序列设备故障预测的核心问题。复杂装备的维修保障数据面临数据异质性问题,不同专业设备产生的数据在结构、采样频率、单位等方面存在显著差异,尤其是型号装备中各种传感器(如振动、温度传感器等)产生的数据,需要通过数据跨专业整合确保模型能够有效利用异质性数据。其次,长时间序列分析问题关注于序列数据中可能存在的复杂模式,包括周期性、趋势、季节性以及异常行为,通过对设备在长时间序列数据中的运行状态变化进行分析,如季节性维护活动,挖掘出序列中潜在的设备故障模式。

跨专业的模型适应问题需要关注不同专业设备可能涉及的不同工作原理和故障模式。维修保障通用模型需能够适应这些差异,以不同型号的装备系统为例可能包含不同的技术、部件和故障特征。提高通用模型的适应能力能够确保其能够适应跨不同专业设备的特性,对于提高模型的泛化性能至关重要。同时,实时性和资源效率问题是实际维修场景中对设备故障及时响应的关键,识别装备系统潜在故障的能力将直接影响后续维修工作的效率。通过优化模型确保其能够适应实时环境并在有限的测试诊断资源下高效运行,能够有效提高维修响应速度和资源利用效率。

最后过程和结果的可解释性问题在维修保障中同样重要。维修人员需要理解模型的预测结果并对模型的决策产生信任。对于维修人员而言,理解模型判定设备可能发生故障的原因是提高模型解释性的重要目标。有助于促进决策过程的可理解性,从而增强维修人员对模型的信任,并最终实现装备维修保障领域的能力提升。

1.2 研究概况

本研究核心是在跨不同专业领域中开发高效的设备故障预测模型,通过分析长时间序列数据提高维修保障的效率和设备的可用性。通过采取以下步骤来实现这一目标。数据整合方法的开发:研究整合来自不同专业设备的长时间序列数据的方法,解决数据异质性和标准化

问题,确保数据集的一致性和可分析性。长时间序列分析方法的设计:为了挖掘数据中的潜在模式设计一种有效的长时间序列分析方法对周期性、趋势、季节性和异常行为等故障模式的识别。跨专业故障预测模型的建立:构建能够跨越不同专业领域的设备故障预测模型。通过选择和优化适当的机器学习算法及深度学习模型实现高准确度的故障预测并确保模型具有足够的泛化性,以适应各种设备环境。模型实时性和资源效率的优化:针对实际维修场景中对实时性的需求优化模型以确保其在动态环境中的快速适应能力并在资源受限的条件下保持高效运行。模型预测结果的可解释性增强:为增强维修人员对模型决策的信任和将模型的预测结果提供可解释性,包括对模型决策的详细解释、关键特征的可视化以及其他有助于协助用户识别及理解的手段。

2 故障预测模型与算法分析

2.1 数据整合方法

针对某型复杂设备的运行监测数据进行分析,数据来源于设备系统配备的多型传感器,包括温度传感器、湿度传感器、振动传感器、电流传感器等跨专业领域的长时间序列数据,通过多型传感器监测了设备系统的运行状态并获得了多种物理特性数据。如图1所示,数据整合基于上述数据进行的操作包括:数据预处理、数据同质化、基础特征工程、跨专业数据预整合、数据集构建等工作^[11-13]。

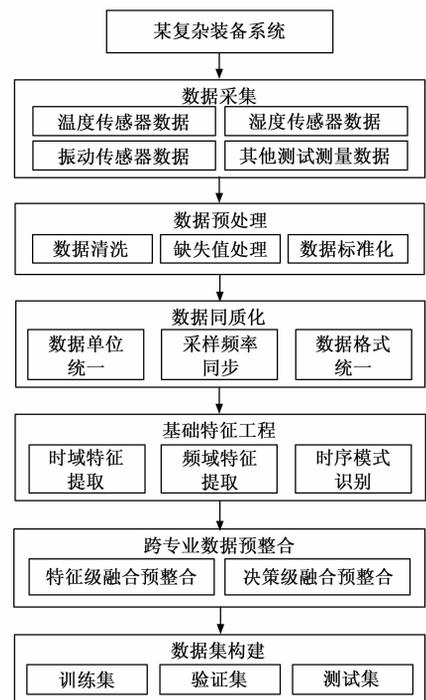


图1 数据整合方法

1) 数据预处理方法:数据整合之前首先进行数据

预处理以确保数据质量，其中数据清洗用于移除不完整或损坏的数据记录并处理异常值和噪声；缺失值处理针对缺失的数据采用插值或估计方法进行填补；将不同类型和量级的数据转换到统一标准消除差异。

2) 数据同质化方法：基于数据集具有异质性特征采取同质化措施，其中数据单位统一将所有传感器数据转换为标准单位，如将温度转换为摄氏度；采样频率同步调整不同传感器的采样频率以实现时间序列的对齐；数据格式统一将所有数据转换为统一配置与存储格式便于处理分析。

3) 基础特征工程方法：从原始数据中初步提取基础特征信息，其中时域特征提取包括最大值、最小值、均值、标准差等统计特征；频域特征提取通过傅里叶变换等方法提取频域特征；时序模式识别数据中的基础周期性、趋势和季节性模式。

4) 跨专业数据融合方法：实现跨专业数据融合以整合不同传感器的数据，其中特征级融合将不同传感器的特征组合成一个统一的特征向量；决策级融合基于模型预测结合不同传感器当前数据及原传感器数据应用运算结果进行加权融合为一套组合特征向量。

在特征级融合中将多型传感器特征整合以便于后续数据分析和模型训练，结合温度、湿度、振动电流四型传感器， X_t, X_h, X_p, X_e 分别代表从温度、湿度、压力和电流传感器中提取的特征向量，特征级融合的公式可以表示为：

$$X_{combined} = [X_t, X_h, X_p, X_e] \quad (1)$$

其中： $X_{combined}$ 是包含所有传感器特征的融合特征向量。

决策级融合则考虑 4 个独立模型的输出，每个模型基于其对应传感器的数据进行预测并与预测结果进行综合形成一个最终决策评估特征，设 O_t, O_h, O_p, O_e 分别代表基于温度、湿度、压力和电流数据的独立模型预测结果，决策级融合的公式可以表示为：

$$O_{final} = f(O_t, O_h, O_p, O_e) \quad (2)$$

决策函数 f 可以基于特定预测任务需求选择加权平均、最大投票或其他适用的集成策略，在使用加权平均作为决策函数的公式可以表示为：

$$[O_{final} = w_t O_t + w_h O_h + w_p O_p + w_e O_e] \quad (3)$$

其中： w_t, w_h, w_p, w_e 是对应于每个传感器数据的权重且和等于 1。

5) 数据集构建方法：构建用于模型训练和测试的数据集，通过训练集进行算法训练以识别数据中的模式和关系；验证集用于模型的调整和优化，使用验证集来评估模型的性能，并对模型参数进行调整；测试集用于评估模型的最终性能；在数据集的比例分配上采用 80% 训练集、10% 验证集、10% 测试集的数据分配方式。

2.2 长短时记忆网络算法

长时间序列分析方法主要采用 LSTM (Long Short-Term Memory) 长短时记忆网络算法，是一种特殊类型的循环神经 RNN 网络，尽管 RNN 能够有效地处理非线性时间序列，但是在工程应用过程中仍然存在一些问题，包括梯度消失和梯度爆炸，不能处理延迟过长的时间序列，以及需要预先确定延迟窗口长度，然而实际应用中很难自动地获取这一参数的最优值。LSTM 可以解决传统 RNN 在处理长序列数据时的长期依赖问题，如图 2 所示，算法通过门控机制设计遗忘门、输入门和输出门来控制信息的流动和更新从而维持一个细胞状态，该状态提供信息传输机制，携带跨时间步的信息，此结构使得 LSTM 能够有效捕捉时间序列数据中的长期模式，广泛应用于面向时间的大尺度时间序列预测。LSTM 训练过程包括前向传播和反向传播，使用梯度下降算法来优化网络参数^[14-20]。

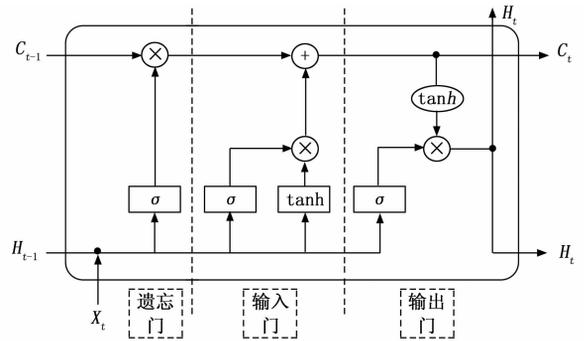


图 2 LSTM 模型方法结构图

LSTM 的核心门控机制包括：遗忘门 (Forget Gate) 决定哪些信息应该从细胞状态中被遗忘；输入门 (Input Gate) 决定哪些新的信息将被存储在当前的细胞状态中；输出门 (Output Gate)：基于当前的细胞状态决定下一个隐藏状态的输出；细胞状态可以通过时间步传播信息同时遗忘门可有选择地丢弃一些信息。LSTM 单元在每个时间步更新其细胞状态和隐藏状态时，会使用一组参数，在训练过程中通过反向传播算法进行学习和更新。LSTM 训练基于前向传播和反向传播，在前向传播中输入数据通过 LSTM 单元进行处理产生预测输出，在反向传播中计算损失函数关于网络参数的梯度，并更新参数以减少预测误差。

2.3 跨专业故障预测模型

跨专业故障预测模型以 LSTM 网络为核心针对跨专业领域的设备监测数据进行分析 and 预测，基于上述基础特征工程和跨专业数据融合过程中的特征向量构建 LSTM 网络模型，利用滑动窗口从时间序列数据中提取包含设备状态统计特征的固定长度的序列，通过网络多层结构识别时间序列数据中的复杂模式和长期依赖关系，通过调整 LSTM 网络的层数、单元数和学习率等

超参数优化模型的学习能力和预测精度。训练过程中采用序列填充来处理不同长度的数据序列确保模型输入一致性。模型训练完成后基于准确率、召回率、 F_1 分数、ROC-AUC 等评估指标全面评估模型的性能。

2.4 试验数据设计

采用某型设备运行监测数据作为具备跨专业长时间序列数据集, 该数据集源自 165 套该型设备的运行数据及故障记录, 涵盖了不同专业领域的数据, 包括振动、温度、湿度、电流等, 数据来源为设备配备的各种传感器, 用于监测设备的运行状态。数据具备异质性数据特征, 不同设备的传感器产生的数据具有异质性, 包括不同的单位、采样频率和数据格式。其中振动传感器数据可用于监测分析设备机械部分失衡或轴承故障; 温湿度传感器数据则提供环境条件对设备性能的影响分析; 电流传感器数据可以监测电机负载和效率。试验使用的原始数据有不同数据结构存储形式, 包括时间戳、模拟信号值、数字编码等, 通过归一化处理将不同来源或系统的原始数据进行数据转换到统一的度量标准, 以消除量纲的影响。

选取长时间序列数据记录跨足数月或数年捕捉设备运行的长时间模式, 以更好地分析设备的正常和异常行为。为了满足试验需要对数据集开展标注故障数据工作, 数据的标准根据系统已有的运行记录和故障记录进行时间对其与故障标注, 数据集中包含设备发生故障或需要维修时的标签用于监督学习问题。其中传感器数据的采集频率因设备而异存在在数秒到数分钟之间的差异化特征。该数据集形成一套涵盖不同专业设备的多模态、异质性长时间序列数据。数据集部分数据如表 1 所示。

基于数据集及数据整合后的特征向量, 在数据集的比例分配上采用 80% 训练集、10% 验证集、10% 测试集的数据分配方式, 在整个数据集基础上使用训练集和测试集, 将其中 80% 数据用于训练, 10% 数据用于测试, 通过划分过程中保持类别的平衡避免算法在训练过程中存在类别不平衡问题与识别模型不足问题。基于 Python 搭建运行环境, 通过试验运行采用混淆矩阵进行真实正常、真实故障情况预测, 结果包括预测正常和

预测故障场景, 试验过程计算算法的准确性、精确度、召回率和 F_1 分数, LSTM 模型 ROC 曲线如图 3 所示, 试验经过迭代运行最终算法模型是 AUC 值 (ROC 曲线下面积) 为 0.924 4, 表明模型性能参数运行效果较好, 具有较高的准确性和 AUC 值。

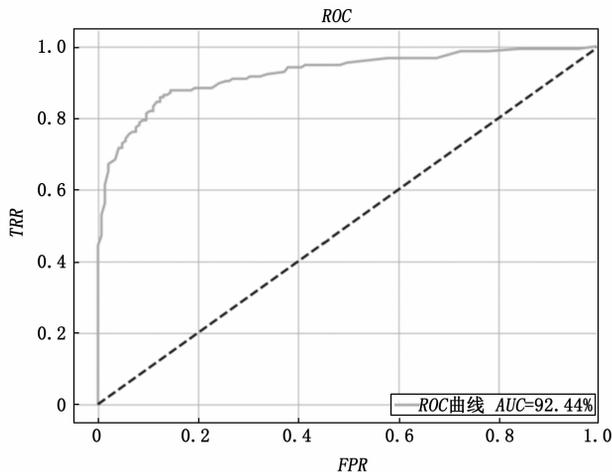


图 3 LSTM 模型 ROC 曲线

3 应用场景验证

3.1 场景描述

某型复杂装备系统由多种设备组成, 其中存在多型旋转设备、环境敏感设备、电机设备等, 为了确保装备系统的稳定运行, 系统的配套组件均已配备先进的传感器和自动控制系统, 控制系统将实时监控传感器监测的关键参数, 包括振动数据、温度数据、湿度数据、电流数据等, 同时控制系统可以根据实时数据调节系统的运行状态。通过控制系统获取的跨专业实时监测数据可对复杂装备系统开展健康状态监测, 其中故障预测模型的应用最为重要, 该模型通过分析装备系统监测系统收集的长时间序列数据, 预测系统可能出现的故障, 根据监测系统参数的分析预测, 系统可提前识别装备系统可能出现的故障以便采取及时的维修和保养措施确保在需要时装备系统能够可靠地工作。

在装备的维修保障背景下, 故障预测模型与算法的适应性场景应用可以实现更为具体和专业化的装备维修

表 1 数据集部分数据示意

序号	日期	时间	温度/°C	湿度/%	振动幅值/mm	电流/A	故障标签
1	2022-01-01	12:00:00	30.5	44.7	0.013	13.3	0
2	2022-01-01	12:00:01	30.6	44.7	0.015	13.4	0
3	2022-01-01	12:00:02	30.5	44.7	0.019	13.2	0
4	2022-01-01	12:00:03	30.8	44.7	0.023	13.5	1
5	2022-01-01	12:00:04	30.9	44.7	0.025	13.4	1
6	2022-01-01	12:00:05	30.9	44.8	0.034	13.3	1
...
N	2022-12-31	23:59:00	31.2	56.2	0.012	12.8	0

保障应用，包括：1) 装备系统健康状态监测：模型可用于监测装备系统健康状态，通过分析传感器数据提前识别潜在故障，并及时采取维修和保养措施，以确保装备系统的可靠性和性能；2) 备件库存预测：基于历史维修数据和库存信息模型可以预测备件和装备配件的使用寿命，协助用户合理开展备件储备规划；3) 装备系统故障预测：针对装备系统模型通过分析装备任务前的检测数据预测装备系统可能出现的故障提高装备任务的成功率；4) 装备平台寿命管理：模型用于预测装备平台寿命提前识别关键部件的退化趋势，以便进行定期维护和更新确保装备平台的长期可用性；5) 实时维修决策：在维修活动中模型提供实时的维修建议，帮助维修人员在任务中做出决策，确保装备的战备状态；6) 装备系统数据整合：考虑到装备系统可能涉及多个子系统和传感器，模型整合来自不同系统和传感器的异质性数据以全面理解装备系统的状态。

3.2 应用系统开发

针对复杂装备系统，开发基于故障预测模型与算法的装备系统健康状态监测软件平台，通过训练的模型基于分析传感器数据实现预测装备系统的健康状态和可能的故障，软件平台主要实现包括数据采集、数据处理、数据存储、模型训练与预测、后端服务、用户界面等功能，从数据流的角度看系统数据从传感器网络通过现场数据采集系统进入系统，经过 Kafka 消息队列到达数据处理层进行预处理和特征工程同时存储在数据存储层。故障预测模型软件功能架构如图 4 所示，用户通过 UI

层与系统交互，获取数据可视化和故障预测结果。平台基于模块化设计设计分层解耦的多层架构，每个层次所属模块均具有明确功能分工便于后续维护和扩展。信息交互上使用消息队列和模块化设计可以灵活地扩展新的监测对象、数据源、处理算法及用户界面；同时通过消息队列和实时数据缓存软件怕滚筒能够快速响应数据变化和用户请求。平台后端服务层支持系统的运行维护，确保系统的稳定运行和性能优化。通过平台系统架构设计满足复杂装备系统模型算法应用数据处理的实时性、可扩展性和用户交互，适用于装备系统故障预测场景。

数据采集层通过构建传感器网络实现对复杂装备系统各种参数后状态监测点的构建，负责从设备运行现场收集原始数据，现场数据采集系统负责收集来自传感器的数据并转换为原始采集数据并将数据传送到平台的数据流处理层。数据流处理层通过 Kafka 组件构建消息队列系统，接收来自数据采集系统的原始数据并将其放入消息队列中，支持数据的缓冲和异步处理，可提高数据传输的弹性和可扩展性确保数据在高并发环境下的可靠传输。

数据处理层的数据预处理模块通过 Kafka 组件构建的消息队列获取原始数据对数据进行初步处理，包括数据格式转换和基础预处理。数据处理模块根据数据的类型、量纲等内容进行操作，数据标准化和特征工程通过将数据转换为统一的标准格式并构造基础特征向量参数和融合特征向量参数提取和构造有助于模型训练的特征。数据存储层通过数据库存储处理后数据、模型参

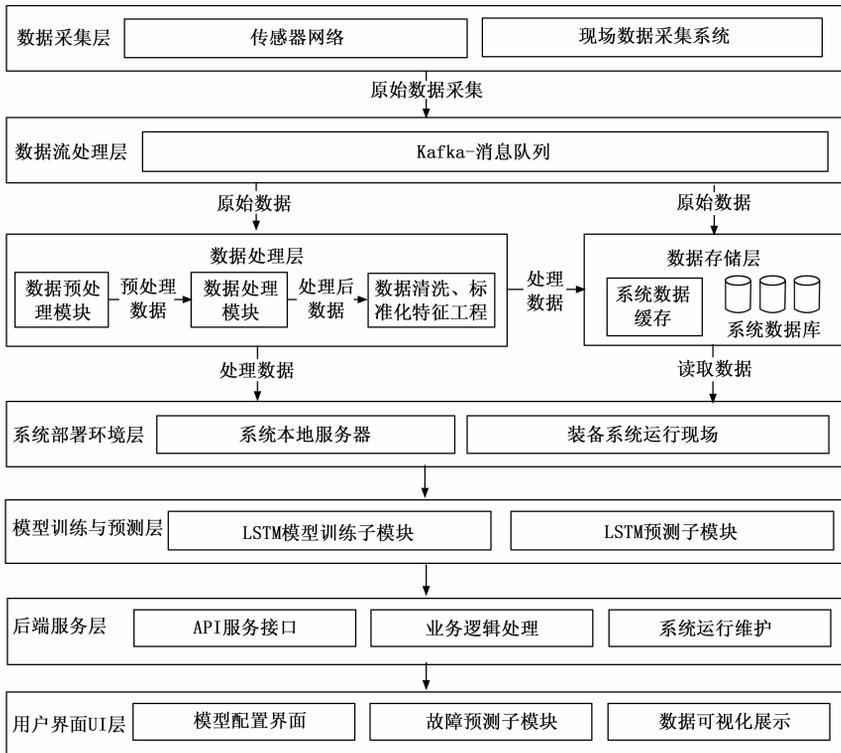


图 4 故障预测模型软件功能架构图

数、用户配置和部分需要保存的原始数据。数据缓存用于临时存储数据以减少数据库访问提高系统响应速度, 数据库和缓存与数据处理模块及模型训练模块进行数据读写操作。

数据处理过程中特别针对基础特征向量参数和融合特征向量参数设计向量参数配置文件, 平台软件可以通过读取配置文件进行特征向量的解析, 方便特征向量后续的更新调整迭代。其中基础特征向量配置实例如表 2 所示。

表 2 基础特征向量配置实例

序号	配置模块	参数名称	参数值
1	DataFusion	Type	Feature Level
2	Sensors	Sensor 1	Temperature
3		Sensor 2	Humidity
4		Sensor 3	Pressure
5	DecisionCombiner	Type	Concat
6		Normal Enabled	TRUE
7		Scaling Type	Standard
8	Preprocessing	Step Type	Filter Noise
9	DataFusion	Type	Feature Level

融合特征向量配置实例如表 3 所示。

表 3 融合特征向量配置实例

序号	配置模块	参数名称	参数值
1	DataFusion	Type	Decision Level
2	Models	Sensor	Temperature
3		Model Type	RandomForest
4		Parameter Name	n
5		Parameter Value	100
6	DecisionCombiner	Type	Voting
7		Method	Soft
8	Postprocessing	Step Type	Thresholding
9		Threshold Value	0.5

模型训练与预测层中模型训练子模块负责开展 LSTM 模型训练操作, 接收处理后的数据进行模型训练, 根据不同的数据来源开展不同对象的针对性训练, 训练完毕后可进行模型的对应发布。预测子模块负责利用训练发布后的对应 LSTM 模型进行预测并生成预测结果。后端服务层的业务逻辑处理组件实现系统的业务逻辑实现数据处理和操作, 同时提供 API 服务接口处理前端或外部的接口请求, 用户界面和外部系统进行交互。

用户界面 (UI) 层包括模型配置界面、数据可视化展示和故障预测子模块, 模型配置界面允许用户设置和调整模型参数, 数据可视化展示提供实时数据和预测结果的图形化展示, 故障预测子模块展示预测结果和维护建议。

3.3 系统应用

系统应用实施故障预测模型, 首先基于系统对装备

系统传感器数据的全面收集, 包括正常运行和历史故障时期的数据。通过数据采集层的传感器网络, 实时监测关键参数, 并将数据统一整合到系统数据平台, 在数据流处理层使用 Kafka 消息队列技术对数据进行缓冲和异步传输以支持后续的大规模数据处理需求。

在数据处理层, 对原始传感器数据进行深度清洗和标准化处理, 去除噪声和异常值、填补缺失数据, 并通过特征工程提取关键的时间序列特征, 包括振动频率、温度变化趋势等, 基于上述特征用于训练长短时记忆网络 (LSTM) 模型, 在模型训练与预测层中进行正常和故障状态的模式分类学习训练, 系统根据不同的监测对象可以设置不同的训练实例并生成具备不同参数的模型。

训练完毕的 LSTM 模型被部署到后端服务层并通过 API 服务接口与用户界面 (UI) 层和数据存储层实现集成。部署的模型能够实时监测装备系统、分析传感器数据流并预测系统的健康状况。当模型实时分析发现潜在的故障迹象时, 通过用户界面 (UI) 层及时发出警报通知系统用户和维护人员, 提示采取进一步的检查和维修措施。

为了确保模型的持续准确性和可靠性, 系统可定期对模型进行维护和优化, 根据模型预测结果和用户反馈调整模型参数。用户界面 (UI) 层提供运行记录和维护日志的功能, 收集反馈并持续改进模型, 通过系统部署环境层的本地服务器和装备系统运行现场收集实际应用数据, 对模型性能进行验证和评估。

3.4 系统试验结果与分析

现场部署运行后, 系统选取了 2022 年度整年数据进行了数据集构建分析处理与验证工作, 经过系统运行与测试验证, 故障预测模型与算法显示出较高的准确性, 模型预测精度统计如表 4 所示。

表 4 模型预测精度统计表

故障类型	样本数/次	正确预测数/次	准确率/%
轴承磨损	143	141	98.60
齿轮磨损	37	33	89.19
支承松动	49	48	97.96
负荷过载	114	108	94.74
滑油污染	12	11	91.67
多部件耦合	19	15	78.95
总计	374	356	95.19

通过与实际数据记录中发生的故障进行对比分析, 在测试集的模型预测的准确率平均达到 95% 以上, 能够有效地识别出系统运行过程中潜在的故障模式并为设备提供故障的早期预警, 针对轴承磨损、齿轮磨损、支承松动、负荷过载、滑油污染以及复杂多部件的耦合故障能够有效地进行识别和预测。

4 结束语

本研究针对装备故障预测与预防性维修在复杂装备系统维修保障领域的需求提出了一种创新的基于跨专业长时间序列的设备故障预测模型,采用深度学习中的长短时记忆网络(LSTM)作为核心算法,有效地处理和分析了来自不同专业领域的长时间序列数据。通过对某型装备系统健康状态监测的运行数据进行深入的试验分析验证所提出模型的工程应用性能。模型通过对传感器数据进行精准分析实现对装备系统潜在故障的提前识别,表现出较高的准确性和稳定性,能够提前识别潜在的设备故障,并为维修人员提供及时的维护建议从而显著提高装备系统的可靠性和维修保障工作的效率。在装备综合保障领域本研究提出的故障预测模型可提供更为有效的技术方案,通过深度机器学习中 LSTM 网络构建一种能够适应跨不同专业领域的长时间序列数据的预测工具,模型专注于装备维修保障针对该领域的实际需求可以进行定制和专业化设计,满足装备系统健康状态监测在真实场景中的应用需求。

在系统的实际应用过程中,开发了对应的软件平台,集成数据采集、处理、模型训练、预测和可视化等多个模块,为用户提供一站式故障预测解决方案,软件平台采用模块化设计,各个组件负责不同的数据处理任务,易于维护和升级。用户界面直观友好可配置,允许用户轻松配置模型参数,查看实时数据和预测结果,以及接收故障警报。平台能够处理来自不同传感器和数据源的异构数据,实现了数据的高效集成和同步;同时提供模型训练、保存、加载和管理的功能,支持用户根据需要选择和优化模型。在监测到故障后提供警报功能,预测到潜在故障时平台会自动触发警报系统及时通知用户采取行动。通过软件平台及模型算法,为故障预测及维修保障提供了高可信度的预测结果,帮助维修人员和决策者快速决策,降低维护成本并增强系统设备可靠性,有效提高装备的任务完成率。

在后续工作上,将进一步通过模型改进、异质数据处理等方式进一步优化模型的性能,引入更复杂的深度学习架构、集成学习方法、注意力机制等手段以提高模型对复杂关系的学习能力;针对不同专业设备的异质数据,研究更有效的数据预处理和整合方法,确保模型能够适应更多领域的的数据特点,推动跨专业长时间序列设备故障预测模型具备更高的工程化实用性和适用性。

参考文献:

- [1] 吴立金,夏冉,詹红燕,等.基于深度学习的故障预测技术研究[J].计算机测量与控制,2018,26(2):9-12.
- [2] 郭一帆,唐家银.基于机器学习算法的寿命预测与故障诊

- 断技术的发展综述[J].计算机测量与控制,2019,27(3):7-13.
- [3] 吕琛,马剑,王自力.PHM技术国内外发展情况综述[J].计算机测量与控制,2016,24(9):1-4.
- [4] 胡泽文,肖明清.基于时间序列模型的故障预测研究[J].计算机测量与控制,2013,21(6):1421-1423.
- [5] 郭阳明,蔡小斌,张宝珍,等.故障预测与健康状态管理技术综述[J].计算机测量与控制,2008,16(9):1213-1216.
- [6] 郭一帆,唐家银.基于机器学习算法的寿命预测与故障诊断技术的发展综述[J].计算机测量与控制,2019,27(3):7-13.
- [7] 张驰,郭媛,黎明.神经网络模型发展及应用综述[J].计算机工程与应用,2021,57(11):57-69.
- [8] 邱立军.武器装备故障预测与健康管理系统的关键技术[J].舰船电子工程,2012,32(5):17-18.
- [9] 闻化,胡志伟.装备故障预测与健康管理能力验证评估技术[J].计算机测量与控制,2019,27(11):260-264.
- [10] 雷亚国,贾峰,孔德同,等.大数据下机械智能故障诊断的机遇与挑战[J].机械工程学报,2018,54(5):94-104.
- [11] 钱白云,吕朝阳,张维宁,等.基于多传感器信息融合与混合感受野残差卷积神经网络的调相机转子故障诊断[J].计算机测量与控制,2023,31(9):29-35.
- [12] 马永军,薛永浩,刘洋,等.一种基于深度学习模型的数据融合处理算法[J].天津科技大学学报,2017,32(4):71-74.
- [13] 张志敏.不等精度数据融合的最优权值与参数估计方法[J].计算机测量与控制,2018,26(9):301-307.
- [14] 朱丹宸,张永祥,潘洋洋,等.基于多传感器信号和卷积神经网络的滚动轴承故障诊断[J].振动与冲击,2020,39(4):172-178.
- [15] 王鑫,吴际,刘超,等.基于LSTM循环神经网络的故障时间序列预测[J].北京航空航天大学学报,2018,44(4):772-784.
- [16] 陆继翔,张琪培,杨志宏,等.基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J].电力系统自动化,2019,43(8):131-137.
- [17] 石怀涛,尚亚俊,白晓天,等.基于贝叶斯优化的SW-DAE-LSTM滚动轴承早期故障预测方法研究[J].振动与冲击,2021,40(18):286-297.
- [18] 查云龙,茅玉龙,卜宇,等.基于BasicNet-LSTM的短期电力负荷预测模型构建[J].中国设备工程,2024(11):139-141.
- [19] 樊家伟,郭瑜,伍星,等.基于LSTM神经网络和故障特征增强的行星齿轮箱故障诊断[J].振动与冲击,2021,40(20):271-277.
- [20] 李卓,叶林,戴斌华,等.基于IDSCNN-AM-LSTM组合神经网络超短期风电功率预测方法[J].高电压技术,2022,48(6):2117-2127.