结合记忆网络和注意力的电表检定线健康预测

沈 诚[1], 郭 鹏[1], 吴 骏[1], 金 鑫[2], 余 伟[2]
(1. 湖北华中电力科技开发有限责任公司,武汉 430072; 2. 武汉大学 计算机学院,武汉 430070)

摘 要:智能电表检定流水线的未来健康状况不仅与检定流水线当前时刻工作数据有关,也与过去一段时间内的工作数据密切相关,且不同时刻的历史工作数据对未来健康状况的影响程度不同。故采用深度学习技术,建立了结合记忆网络和注意力的电表检定线健康预测模型,通过检定线的日常工作数据和历史故障数据预测检定线的健康状况。实验结果表明:该模型在1 000条实际数据上的测试准确率达82.4%,超过5个高效的基线模型。因此,该模型可自动化预测智能电表检定线的未来健康状况,为提升运维效率并降低运维成本提供支撑。

关键词:检定线健康预测;记忆网络;注意力;日常工作数据;历史故障数据
DOI:10.15938/j.jhust.2026.03.010
中图分类号:TP278 **文献标志码**:A **文章编号**:1007-2683(2026)03-0097-10

Health Prediction of Electric Meter Calibration Lines by Combining Memory Networks and Attention

SHEN Cheng[1], GUO Peng[1], WU Jun[1], JIN Xin[2], YU Wei[2]
(1. Hubei Central China Technology Development of Electric Power Co., Ltd., Wuhan 430072, China;
2. School of Computer Science, Wuhan University, Wuhan 430070, China)

Abstract:The future health status of a smart meter calibration line depends not only on its current working data but also on its working data from the past period. Moreover, historical working data at different time points have varying impacts on future health status. Therefore, a health prediction model for the meter calibration line is established using deep learning techniques, combining a memory network with an attention mechanism. The model predicts the health status of the calibration line based on its daily working data and historical fault data. The experimental results show that the test accuracy of the model on 1 000 actual data reaches 82.4%, which exceeds 5 efficient baseline models. Therefore, the model can effectively realize the automatic prediction of the future health status of the smart meter verification line, providing support for improving operation and maintenance efficiency and reducing operation and maintenance costs.

Keywords:calibration line health prediction; memory network; attention; daily working data; historical fault data

0 引 言

随着我国经济的高质量发展,用电需求也在快速增长。为了更自动化地计量电量,智能电表应运而生,逐渐取代了传统电表[1]。与传统电表相比,智能电表具备了多样化的计量和通信模块,功能更复杂,结构更精密。在安装前,通常需要利用智能电表自动化检定流水线对智能电表进行计量检定,确保智能电表在电网中的正常运行[2]。因此,检定流水线在维护电网稳定运行、保障用户用电需求的过程中发挥了十分重要的作用[3]。然而,随着检定流

收稿日期:2024-05-17
基金项目:国家自然科学基金(62376200).
作者简介:沈 诚(1990—),男,高级工程师;
郭 鹏(1981—),男,中级工程师.
通信作者:金 鑫(1979—),男,博士,工程师,E-mail:14006938@qq.com.

水线数量的增多,相应的健康预测任务日渐繁重。健康预测旨在预判检定流水线的未来健康状况,提高运维效率,降低运维成本。传统的健康预测方法主要依赖于对检定流水线工作数据进行人工分析,但效率过低、成本过高,无法满足当前大规模、高效率的预测需求。

近年来,针对智能电表检定流水线研发出了更加自动化的健康监测手段。文[4]提出了自动化在线检测智能电表流水线表位异常的方法。利用统计方法将表位检测数据进行分布建模,通过分布数据的异常检测出表位状态的异常;然后再利用局部异常因子算法量化其中的异常程度;最后,标记存在异常的表位。文[5]提出了自动化在线监测电能表装置运行情况的方法。该方法利用高精确度的标准电能表(安装式),采用在线实时检测与核查的方式,对正在运行的自动化检测装置实现在线管理。文[6]首先采集了流水线的风险信息,然后对采集的信息进行量化评估,最后整合评估信息,并结合自动化检测系统实现监控分享和预警管理功能。文[7]推出在线监测方法,整合了高精度核查器,确保在线监测过程的高准确度及高稳定性。在流水线自动检定过程中,针对电能表故障特点,文[8]利用模糊推理构建了对应的故障专家诊断系统。文[9]提出了可检测流水线表位故障并定位报警的系统,通过连续不合格的表位信息,有效识别检定流水线表位的功能性故障。针对流水线自动化检定系统的特点,文[10]对流水线自动化系统的新型质量监控方法展开研究,对计量流水线自动化检定系统的运行状态进行全方位监视,提出了整合“离线动态”、“在线静态”和“质量抽查”的新质量监控方法。文[11]利用期间核查与检定验证2种方式对自动化检定流水线的质量监控进行了深入研究,监测了设备稳定性等因素对检定结果的影响,保障了检定结果的可信度。文[12]提出的数据驱动方法,可在不中断监测任务的情况下,通过创建评估参数、确定参考仪表、计算偏差、识别错误状态监测检定流水线的状态。文[13]针对复杂的多源监测异构采集数据,采用变分自动编码器构建特征提取模型,实现数据降维,同时保留样本信息。随后,为确保实体间的相互关联和影响,采用 Sperman 秩相关系数计算特征间的相关性。最后,利用图卷积构建故障预警模型,实现对检定线的监测。

尽管上述方法可对智能电表自动化检定流水线当前时刻的健康状况进行有效监测,但难以预测其未来健康状况。研究检定流水线的自动化健康预测方法存在2个难题。首先,检定流水线的未来健康状况不仅与检定流水线当前时刻的工作数据有关,也与其历史工作数据密切相关。因此,需要对历史运行数据建模,从日常检定任务关键设备(如滚筒线、机械手、功耗台、耐压台等)的电磁故障、压力故障、机械故障的发生频率和故障等级来获取时序数据。然而,如何从大量运行数据中准确提取健康状况信息并进行有效的利用,是一项极具挑战的任务。此外,不同时刻的历史工作数据对未来健康状况的影响各不相同。因此,在建模时,不仅需要全面地考虑历史工作数据,还需要识别和强调对未来健康状况影响最大的部分数据。所以,研究出可自动化地识别和强调关键性数据的机制尤为重要。

针对上述难题,本文设计了基于双向长短时记忆(bidirectional long and short-term memory, Bi-LSTM)网络和自注意力(self-attention)机制的智能电表自动化检定流水线健康预测模型(Bi-LSTM + SA)。Bi-LSTM 可实现双向信息处理,且多门控设计使其学习到长期依赖关系。因此,它能够建模丰富的上下文信息,在处理各种时序数据时具有优秀的泛化能力。故本文利用 Bi-LSTM 网络对时序数据进行建模,有效捕获了不同时刻工作数据对检定流水线未来健康状况的影响。同时,自注意力机制可为不同时刻的数据赋予不同权重,加强对重要时刻的关注。因此,本文采用自注意力机制自动化地衡量不同时刻历史数据对未来健康状况的影响,为关键性数据赋予更高权重。由此,Bi-LSTM + SA 模型可以更全面、准确地反映检定流水线的健康状况。

实验表明:Bi-LSTM + SA 模型可有效地预测检定流水线的未来健康状况,实验准确率达 82.4%。因此,该模型具有广泛的应用前景,在保证预测精确性和可靠性的同时,显著提升了预测效率,降低预测成本,为智能电表自动化检定流水线的健康管理提供强大技术支持。

1 电表流水线健康预测方法

本节首先介绍智能电表检定流水线的日常运行数据和相关健康特征;然后,对健康特征进行数据预

处理及表示构建;最后,设计了基于自注意力机制与双向长短时记忆网络的智能电表自动化检定流水线健康预测模型,利用健康特征的表示对其未来健康状况进行自动化预测。

1.1　数据采集及健康特征构建

为精准预测智能电表检定流水线的未来健康状况,本节首先介绍了所采集的检定流水线工作数据,并基于这些工作数据构造了健康特征。

本文利用可编程逻辑控制器(programmable logic controller, PLC)采集检定流水线的工作数据。PLC 为具有微处理器的数字运算控制器,可将控制指令随时载入内存进行储存与执行,并进行数据采集。具体数据包括:设备开机时间(device start time, DST)、设备关机时间(device stop time, DTT)、任务开始时间(task start time, TST)、任务结束时间(task stop time, TTT)、故障发现时间(fault find time, FFT)、故障发生等级(fault severity level, FSL)、故障发生次数(fault occurrence count, FOC)和故障消除时间(fault clear time, FCT)。其中,设备开机时间为检定流水线开启时间点;设备关机时间为关闭时间点;任务开始时间为开始检定任务时间点;任务结束时间为结束检定任务时间点;故障发现时间为发现检定流水线出现故障的时间点;故障消除时间为检定流水线修复时间点;故障发生等级为发生的具体故障等级;故障发生次数为发生故障的具体次数。为验证模型性能,本文假定所有的数据在采集及传输过程中无误差,可以反映检定流水线的实际工作情况。

基于上述工作数据,构造了一些检定流水线的健康特征,包括:设备开机时长(device busy time, DBT)、设备检定时长(device verify time, DVT)、设备故障时长(device failure time, DFT)、设备工作时长(device work time, DWT)、设备故障频率(device failure frequency, DFF)和设备故障系数(device failure coefficient, DFC)。

各健康特征的详细计算公式如下:

1)设备开机时长 t_{DBT} 为设备关机时间 t_{DDT} 与设备开机时间 t_{DST} 之差:

$$t_{\mathrm{DBT}} = t_{\mathrm{DDT}} - t_{\mathrm{DST}} \tag{1}$$

2)设备检定时长 t_{DVT} 为任务结束时间 t_{TTT} 与任务开始时间 t_{TST} 之差:

$$t_{\mathrm{DVT}} = t_{\mathrm{TTT}} - t_{\mathrm{TST}} \tag{2}$$

3)设备故障停机时长 t_{DFT} 为当天所有故障的故障消除时间 t_{FCT} 与故障发现时间 t_{FFT} 之差的总和:

$$t_{\mathrm{DFT}} = \sum_{i=1}^{N_{\mathrm{FOC}}} (t_{\mathrm{FCT},i} - t_{\mathrm{FFT},i}) \tag{3}$$

式中:N_{FOC} 为故障发生次数。

4)设备工作时长 t_{DWT} 为设备检定时长 t_{DVT} 与设备故障停机时长 t_{DFT} 之差:

$$t_{\mathrm{DWT}} = t_{\mathrm{DVT}} - t_{\mathrm{DFT}} \tag{4}$$

5)设备故障频率 f_{DFF} 为设备故障停机时长 t_{DFT} 与设备开机时长 t_{DBT} 之比:

$$f_{\mathrm{DFF}} = \frac{t_{\mathrm{DFT}}}{t_{\mathrm{DBT}}} \tag{5}$$

6)设备故障系数 α_{DFC} 为当天所有故障等级之和:

$$\alpha_{\mathrm{DFC}} = \sum_{i=1}^{N_{\mathrm{FOC}}} L_{\mathrm{FSL},i} \tag{6}$$

式中:L_{FSL} 为故障发生等级。

以上 6 个特征为检定流水线的健康特征,用于预测检定流水线的健康状况。

1.2　数据预处理与表示构建

工作数据中可能包含不完整、不一致的脏数据[14],脏数据中的噪声不包含规律性的可建模特征,会影响健康特征的准确性和鲁棒性。对于脏数据的处理需求是:使用插入值法、值替换法、值删除法对脏数据进行适当修改,但要确保数据序列的原表达信息不会被影响。

由于工作数据是在不同时间点采集的,故所有健康特征对应的数据为时序数据。建模时间序列化信息时,对数据进行归一化处理,可统一数据,减少无关信息干扰。本文利用最常用的 Min-Max 归一化对所有数据进行处理:

$$f(x_i) = \frac{x_i - \min(x)}{\max(x) - \min(x)} \tag{7}$$

式中:x_i 为读数值;$\min(x)$ 为 x 序列中的最小值;$\max(x)$ 为序列中的最大值。

归一化操作后,所有健康特征落入[0, 1]区间内。为了进行高效的向量化表示,本文采用 One-hot 编码方式对各健康特征进行向量编码。在综合考虑数据分布特点和建模运算效率后,本文定义编码粒度为 0.1,其中具体的编码映射关系如表 1 所示。

经归一化和 One-hot 编码处理后,可得健康特征的嵌入向量。将所有嵌入向量依次拼接,可得检定流水线在某一时刻下的健康状态表示向量。该向

量蕴含了检定流水线当下的各种状态信息,为后续建模奠定基础。

表 1 One-hot 编码对照

Tab. 1 One-hot encoding reference

取值范围	One-hot 编码
$0 \leqslant x < 0.1$	0000000001
$0.1 \leqslant x < 0.2$	0000000010
$0.2 \leqslant x < 0.3$	0000000100
$0.3 \leqslant x < 0.4$	0000001000
$0.4 \leqslant x < 0.5$	0000010000
$0.5 \leqslant x < 0.6$	0000100000
$0.6 \leqslant x < 0.7$	0001000000
$0.7 \leqslant x < 0.8$	0010000000
$0.8 \leqslant x < 0.9$	0100000000
$0.9 \leqslant x \leqslant 1.0$	1000000000

1.3 自注意力机制整合双向长短时记忆网络模型

智能电表自动化检定流水线健康预测模型的主要思想为将自注意力机制整合至双向长短时记忆网络中。本节首先介绍长短时记忆网络,并介绍双向网络模型的特点;而后介绍自注意力机制;最后基于双向长短时记忆网络和自注意力机制构建面向智能电表自动化检定流水线的健康预测模型。

1.3.1 长短时记忆网络

循环神经网络(recurrent neural network, RNN)[15]是长短时记忆网络(long short-term memory, LSTM)[16-18]的前身。LSTM 相比于 RNN 网络具有更好的灵活性,LSTM 的设计使其能够更有效地确定序列信息中应该记住或忘记哪些特定信息。门控机制属于 LSTM 网络的关键特性,通过 3 种门控单元(输入门、遗忘门和输出门)对信息进行处理加工,可缓解训练中的梯度问题[19-20]。LSTM 在处理序列问题上已经得到了广泛的应用,包括自然语言处理、时序信息的异常检测等。

LSTM 单元结构的细节如图 1 所示。网络中的遗忘门决定哪些隐藏信息应该被遗忘或丢弃,利用 Sigmoid 函数判断哪些细节需要从记忆中删除:

$$\boldsymbol{f}_t = \mathrm{Sigmoid}(\boldsymbol{W}_f[\boldsymbol{H}_{t-1}, \boldsymbol{X}_t] + \boldsymbol{b}_f) \tag{8}$$

其中:$\boldsymbol{f}_t$ 为遗忘门特征输出;$\boldsymbol{W}_f$、$\boldsymbol{H}_{t-1}$、$\boldsymbol{X}_t$ 分别为可学习参数、前一个隐藏状态和当前输入;可学习参数 $\boldsymbol{b}_f$ 为偏移项。当前记忆中的信息内容由输入门选择性地添加到下一状态中:

$$\boldsymbol{i}_t = \mathrm{Sigmoid}(\boldsymbol{W}_i[\boldsymbol{H}_{t-1}, \boldsymbol{X}_t] + \boldsymbol{b}_i) \tag{9}$$

$$\hat{\boldsymbol{C}}_t = \tanh(\boldsymbol{W}_c[\boldsymbol{H}_{t-1}, \boldsymbol{X}_t] + \boldsymbol{b}_c) \tag{10}$$

$$\boldsymbol{C}_t = \boldsymbol{f}_t \odot \boldsymbol{C}_{t-1} + \boldsymbol{i}_t \odot \hat{\boldsymbol{C}}_t \tag{11}$$

其中:$\boldsymbol{W}_i$ 和 $\boldsymbol{W}_c$ 为可学习的权重矩阵;$\boldsymbol{b}_i$ 和 $\boldsymbol{b}_c$ 为可学习的偏置;$\boldsymbol{i}_t$ 为 LSTM 中的输入门;$\boldsymbol{C}_{t-1}$ 为旧的单元状态,由 Sigmoid 函数确定参数是否更新;tanh 函数会生成 1 个值 $\hat{\boldsymbol{C}}_t$,这个值将会被添加到新的单元状态中;$\boldsymbol{C}_t$ 为传递给下一步的新单元状态;⊙为哈达玛积。输出门负责生成新的隐藏状态以及时间步长的输出,结合输入和记忆来确定输出:

$$\boldsymbol{o}_t = \mathrm{Sigmoid}(\boldsymbol{W}_o[\boldsymbol{H}_{t-1}, \boldsymbol{X}_t] + \boldsymbol{b}_o) \tag{12}$$

$$\boldsymbol{H}_t = \boldsymbol{o}_t \odot \tanh(\boldsymbol{C}_t) \tag{13}$$

其中:$\boldsymbol{W}_o$ 为可学习的权重矩阵;$\boldsymbol{b}_o$ 为可学习的偏置;$\boldsymbol{o}_t$ 为 LSTM 中的输出门;$\boldsymbol{H}_t$ 为新的隐藏状态,蕴含了之前序列的重点记忆信息,是 LSTM 处理序列数据的关键。

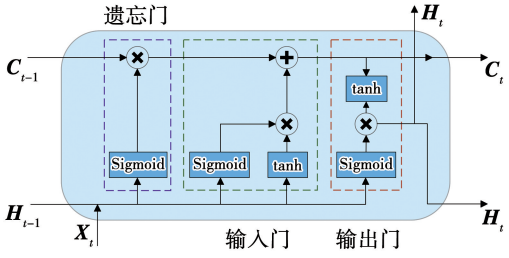

图 1 LSTM 单元结构

Fig. 1 LSTM cell structure

1.3.2 双向长短时记忆网络

双向长短时记忆网络[21-23]是经典的时序神经网络,属于特殊形式的循环神经网络,图 2 为 Bi-LSTM 框架。与传统的单向 LSTM 相比,Bi-LSTM 引入了双向结构,同时考虑了过去和未来的信息,在处理序列数据时更具优势。这是因为每个时间步的隐藏状态不仅取决于历史信息,还取决于未来信息,可提高模型对整个序列的建模能力。这种双向结构有助于更全面地捕捉序列中的模式和特征,能更好地进行信息编码。

$$\overrightarrow{\boldsymbol{h}_i} = \overrightarrow{\mathrm{LSTM}}(\boldsymbol{a}_{i,j}, \boldsymbol{h}_{i,j-1}), j = 1, 2, \cdots, m \tag{14}$$

$$\overleftarrow{\boldsymbol{h}_i} = \overleftarrow{\mathrm{LSTM}}(\boldsymbol{a}_{i,j}, \boldsymbol{h}_{i,j+1}), j = 1, 2, \cdots, m \tag{15}$$

$$\boldsymbol{h}_i = [\overrightarrow{\boldsymbol{h}_i}, \overleftarrow{\boldsymbol{h}_i}] \tag{16}$$

其中:LSTM 上的向右的箭头代表该 LSTM 是 Bi-LSTM 中的正向 LSTM;向左的箭头代表该 LSTM 是 Bi-LSTM 中的反向 LSTM;$\boldsymbol{a}_{i,j}$ 为事件 i 中的第 j 个属

性;$\boldsymbol{h}_i$ 总结了事件 i 的邻居事件,并关注事件 i 的本身特征,做到综合考量。

检定流水线日常运行数据通常包含复杂的动态模式和长期依赖关系,而 Bi-LSTM 的双向结构使其能够更全面地捕捉这些特征。通过同时考虑过去和未来信息,Bi-LSTM 可有效地建模检定流水线数据的变化趋势,捕捉潜在的周期性和季节性变化,对检定流水线的运行情况进行高效的特征提取。

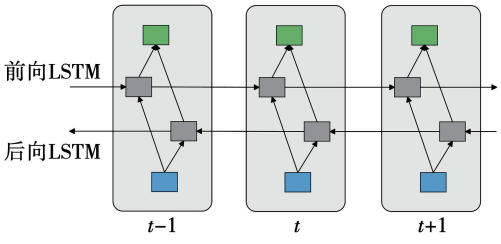

图 2　Bi-LSTM 框架

Fig. 2　Bi-LSTM framework

1.3.3　自注意力机制

注意力机制源于认知科学,指人类能快速判断与任务有关的重点目标区域,而忽视无关区域的过程[24-25]。自注意力机制可通过动态分配权重来筛选关键信息,从而有效忽略与当前任务无关的数据建模[26-28],自注意力机制的框架如图 3 所示。自注意力机制通过计算每个元素与其他元素之间的相似度来获取每个元素的权重,然后将所有元素加权求和得到最终的加权表示向量,用来表示当前位置输入与其他位置输入的关联性。自注意力机制的核心是给向量之间的关系分配适当的权重。自注意力机制 S_A 可被看作查询($\boldsymbol{Q}$)和键($\boldsymbol{K}$)-值($\boldsymbol{V}$)对之间的映射模型。可表示为

$$S_A(\boldsymbol{Y}) = \text{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_{\mathrm{K}}}}\right)\boldsymbol{V} \tag{17}$$

其中:$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 可通过线性变换得到:

$$\left.\begin{aligned}\boldsymbol{Q} &= \boldsymbol{W}_q\boldsymbol{Y}\\ \boldsymbol{K} &= \boldsymbol{W}_k\boldsymbol{Y}\\ \boldsymbol{V} &= \boldsymbol{W}_v\boldsymbol{Y}\end{aligned}\right\} \tag{18}$$

式中:d_{K} 为 $\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 的维度;$\boldsymbol{Y}$ 为输入序列的特征矩阵;$\boldsymbol{W}_q$、$\boldsymbol{W}_k$、$\boldsymbol{W}_v$ 为权重矩阵;$\boldsymbol{Q}$ 和 $\boldsymbol{K}^{\mathrm{T}}$ 相乘用来计算权重矩阵;Softmax 函数将权重归一化到[0,1]之间。同时,为了避免注意力矩阵的值过大,利用缩放点积模型来调整权重值。将点积结果除以 $\boldsymbol{K}$ 的特征维度 d_{K} 的平方根,其与 $\boldsymbol{V}$ 的乘积就是当前节点的新特征向量。

检定日常数据往往包含复杂的时间依赖关系和变化模式,而自注意力机制可有效捕捉序列中不同时间点间的重要关联。通过计算每个时间步的权重,自注意力机制能够动态地关注不同时间点的信息,从而更灵活地适应数据中的变化。自注意力机制有助于处理长期依赖关系,能够在考虑整个序列上下文的同时,更加重视与当前时间步相关的信息。这对于检定流水线数据中存在的潜在季节性、周期性和趋势性变化非常重要,因为检定流水线的故障往往出现在某个或几个特别的时间节点。

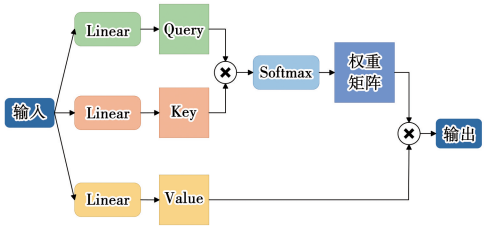

图 3　自注意力机制

Fig. 3　Self-attention mechanism

1.3.4　健康预测模型构建

为了充分建模检定流水线的时序变化特征,即检定流水线在一定周期内的运行状况,本文提出了结合自注意力机制与双向长短时记忆网络的智能电表自动化检定流水线健康预测模型,模型结构如图 4 所示。双向 LSTM 模型能够充分捕捉检定流水线正向和逆向时序中细微的变化,而自注意力机制可以帮助模型着重关注重要的时间点,即检定流水线可能出问题的时刻。

检定流水线 i 的时序表示为 $\boldsymbol{x}_i = (x_{i,1}, x_{i,2}, \cdots, x_{i,t})$,其中 $x_{i,t}$ 为检定流水线在 t 时刻的状态表示向量。将时序表示依次输入至 Bi-LSTM 模型中,可得检定流水线的双向表示向量,将正向和逆向的表示向量拼接可得完整的时序表示:

$$\overrightarrow{\boldsymbol{h}_i} = \overrightarrow{\text{LSTM}}(\boldsymbol{x}_i) \tag{19}$$

$$\overleftarrow{\boldsymbol{h}_i} = \overleftarrow{\text{LSTM}}(\boldsymbol{x}_i) \tag{20}$$

$$\boldsymbol{h}_i = [\overrightarrow{\boldsymbol{h}_i}, \overleftarrow{\boldsymbol{h}_i}] \tag{21}$$

经 Bi-LSTM 模型编码后的检定流水线时序表示为 $\boldsymbol{h}_i = (h_{i,1}, h_{i,2}, \cdots, h_{i,t})$。此时的表示向量蕴含了检定流水线在使用过程中的细微变化特征,而这种变化的时序特征正是衡量检定流水线使用状态的关键因素。但并非所有时刻的状态都是有效的判断节点,因为检定流水线大部分时间都处于正常的工

作状态。因此,本文引入自注意力机制,使模型可自动聚焦到影响检定流水线健康状态的时刻。

$$\boldsymbol{R}_i = \mathrm{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_{\mathrm{K}}}}\right)\boldsymbol{V} \tag{22}$$

$$\left.\begin{aligned}\boldsymbol{Q} &= \boldsymbol{W}_q\boldsymbol{h}_i\\ \boldsymbol{K} &= \boldsymbol{W}_k\boldsymbol{h}_i\\ \boldsymbol{V} &= \boldsymbol{W}_v\boldsymbol{h}_i\end{aligned}\right\} \tag{23}$$

经过自注意力机制处理后,需要重点关注的时刻会被给予较大的注意力权重,反之则缩小权重。表示矩阵与权重矩阵相乘后即可得到最终的矩阵表示 $\boldsymbol{R}_i$,对其中的向量进行拼接操作后,再输入至全连接层网络进行形状转换,最后再经 Softmax 函数处理即可得到最终的预测结果 $\hat{y}$。

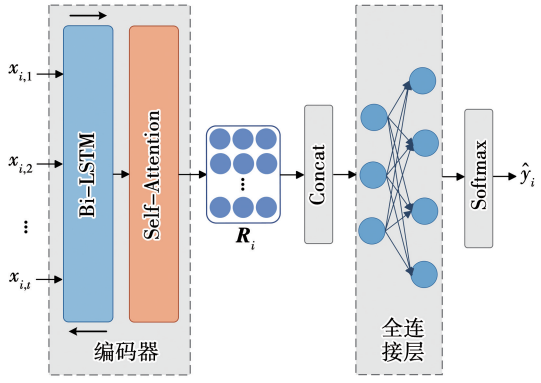

图 4 健康预测模型

Fig. 4 Health prediction model

在模型训练过程中,本文使用最常见的 Adam[29]算法优化目标函数,并采用交叉熵损失函数作为目标函数:

$$L = -\frac{1}{N}\sum_{i}\sum_{c=1}^{M} y_{ic}\log(p_{ic}) \tag{24}$$

其中:N 为样本总数;y_{ic} 为符号化函数(取值范围为布尔值),假如第 i 个样本的类别等于 c,其取值为真,即 1,否则其取值为假,即 0;p_{ic} 为模型将第 i 个样本预测为 c 类别的概率;M 为标签类别的数量。本文将检定流水线的未来健康状态分为 5 类,标签的具体含义如表 2 所示。

如果预测某一条智能电表检定流水线的未来健康状况为完全损坏或严重故障,则可提前维修该检定流水线,防止由于检定流水线故障导致的智能电表计量检定失误,避免影响电表检定的准确性和电表供应的及时性。最终,计算得到损失 L 后,利用梯度下降法迭代式地更新模型中的所有参数。

表 2 未来健康状态定义

Tab. 2 Future health status definition

标签取值	标签含义
0	检定流水线处于完全损坏状态
1	检定流水线处于严重故障状态
2	检定流水线处于轻微故障状态
3	检定流水线处于亚健康状态
4	检定流水线处于完全健康状态

2 仿真实验

为测试智能电表自动化检定流水线健康预测模型的性能,本文收集了5 000条数据,并随机划分出4 000条训练数据和1 000条测试数据。这些数据来自智能电表检定流水线中的辊道线单元、拆码垛机单元、机器人单元、耐压台单元、外观识别单元、功耗检定台、铅封单元、刻码单元、贴标单元。

在主对比实验中,本文利用过去 30 d 的历史工作时序数据进行建模,Bi-LSTM 设为 3 层,学习率设为0.000 5,训练轮次设为 64。此外,选取了支持向量机模型(support vector machine, SVM)[30]、循环神经网络模型(RNN)、门控循环单元模型(gated recurrent unit, GRU)[31]、长短时记忆网络模型(LSTM)、多层感知机模型(multilayer perceptron, MLP)[32-33]作为对比模型,并采用准确率作为衡量指标。准确率计算如下:

$$\alpha_{\mathrm{Acc}} = \frac{N_{\mathrm{cor}}}{N_{\mathrm{cor}} + N_{\mathrm{inc}}} \tag{25}$$

式中:N_{cor} 为模型的正确预测数;N_{inc} 为模型的错误预测数。正确预测数与总预测数的比值即为模型预测的准确率。

2.1 数据采集与存储过程

本文的样本训练数据主要来源于智能化检定线的日常运行数据,通过 Modbus 协议与线体的 PLC 设备进行通讯,获取关键设备(如滚筒线、拆码垛机、机械手、功耗台、耐压台等)数据。故障数据通常包括气管故障、电磁阀故障、通讯故障、过载故障等,将这些数据按照一定频率存储到数据中台,为数据分析与预测提供基础数据保障。数据采集与存储过程如图 5 所示。

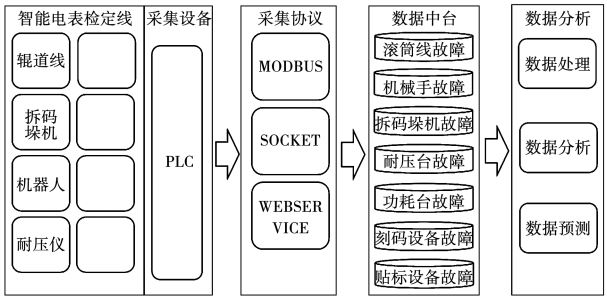

图 5　数据采集与存储过程

Fig. 5　Data acquisition and storage

2.2　主对比实验

表 3 为主对比实验(本文提出的 Bi-LSTM + SA 模型与其他模型的对比实验)结果。可见,本文提出的 Bi-LSTM + SA 模型的准确率达 82.4%,在所有对比模型中取得了最优性能。

表 3　实验性能对比

Tab. 3　Experimental performance comparison

模型	准确率
SVM	68.5%
MLP	73.8%
RNN	75.9%
GRU	75.3%
LSTM	77.8%
Bi-LSTM + SA	82.4%

相较于 SVM 模型,本文提出的 Bi-LSTM + SA 模型的准确率提升了 13.9 个百分点;相较于 MLP 模型,准确率提升了 8.6 个百分点;相较于 RNN,准确率提升了 6.5 个百分点;相较于 GRU,准确率提升了 7.1 个百分点;相较于 LSTM,准确率提升了 4.6 个百分点。由此可见,相较于其他模型,本文提出的 Bi-LSTM + SA 模型能够更好地对检定流水线的健康状况进行预测,为提升检定流水线运维效率和降低运维成本提供了有力支撑。

2.3　消融实验

为了探究 Bi-LSTM + SA 模型中不同部分对模型准确率的影响,本文有针对性地进行了几种变体消融实验,分别验证各模块的效果,消融实验结果如表 4 所示。将 Bi-LSTM + SA 模型的 SA 模块消融,可得变体模型 Bi-LSTM,其准确率下降了 2.6 个百分点;将 Bi-LSTM 替换为 RNN 的变体模型 RNN + SA 的准确率下降了 4.8 个百分点;将 Bi-LSTM 替换为 GRU 的变体模型 GRU + SA 的准确率下降了 5.2 个百分点;将 Bi-LSTM 替换为 LSTM 的变体模型 LSTM + SA 的准确率下降了 1.6 个百分点。可见,Bi-LSTM + SA 模型的不同部分均能有效提升模型准确率,为模型更精准地预测检定流水线健康状况产生积极作用。

表 4　消融实验结果

Tab. 4　Results of ablation experiments

模型	准确率
Bi-LSTM + SA	82.4%
Bi-LSTM	79.8%
RNN + SA	77.6%
GRU + SA	77.2%
LSTM + SA	80.8%

2.4　建模窗口调整分析实验

为探究所采集序列数据中历史工作数据天数对模型预测准确率的影响,本文以 5 天为间隔,分别采用不同时长的历史工作数据为输入,依次记录模型的预测结果,如图 6 所示。

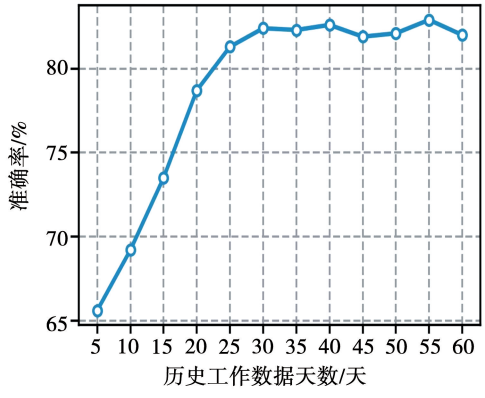

图 6　历史工作数据天数的影响

Fig. 6　The effect of historical work days

由图可知,在一定时间范围内,模型的准确率会随着历史工作数据天数的增加而增长。但当天数增加至 30 天左右时,不再出现明显增长。显然,历史数据能够帮助模型做出更准确的判断,更多的历史数据可以给模型提供更全面、更准确的判断依据。但是,随着历史工作数据天数的增加,模型可能已经学习到了序列中的长期依赖关系和模式,掌握了序列的重要特征,继续增加天数并不能提供更多有益的信息。

2.5 BI-LSTM 层数分析实验

为了探索 Bi-LSTM 层数对模型准确率的影响，本文依次增加模型的堆叠层数，并记录对应的实验结果，如图 7 所示。可见，模型的准确率先随着 Bi-LSTM 堆叠层数的增加而增长，当层数增加到 3 层时获得最佳表现，而后随着层数的增加而急剧下降。

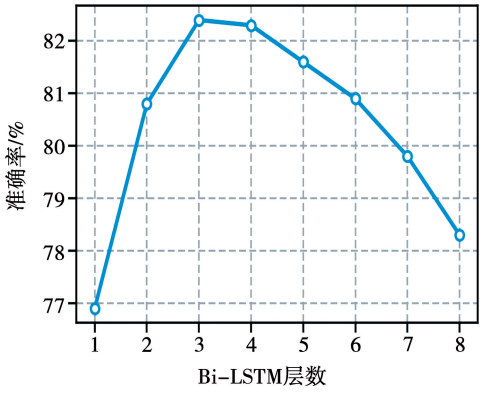

图 7 Bi-LSTM 层数的影响

Fig. 7 The effect of Bi-LSTM layer numbers

产生这种情况的原因可能是当模型堆叠层数过多时，反向传播中出现了梯度消失或梯度爆炸，使模型无法完成正常的训练。当层数过多时，一方面，梯度的传递可能变得十分艰难；另一方面，梯度也可能被过度放大，阻碍网络的有效训练。此外，随着层数的增加，模型的参数量也会增加，从而增加了过拟合风险。当出现过拟合问题时，模型在与训练集属于同一分布的数据上表现优异，而在不同分布的数据上的表现较差。

2.6 学习率调整分析实验

为了验证学习率大小对模型训练情况的影响，本文依次增加学习率的数量级大小，观察模型准确率的变化情况，结果如图 8 所示。

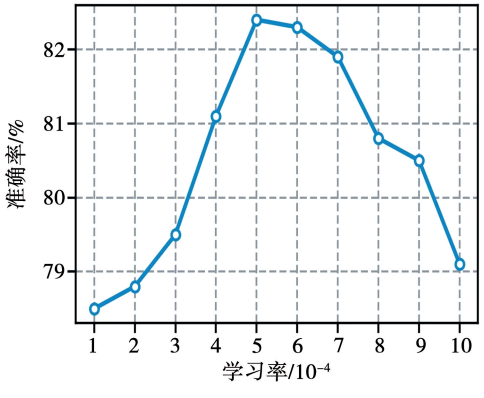

图 8 学习率的影响

Fig. 8 The effect of learning rate

由图可知，模型准确率首先随着学习率的增加而提升，达到一定程度后，越大的学习率反而会影响模型的表现。当学习率过小时，梯度更新进程会变得十分迟缓，模型需要更多的训练时间与更多的更新轮次才能实现最优解。此外，学习率过小还可能导致模型陷入局部最优，无法找到全局最优解。相反，如果学习率设置得太大，梯度更新可能会导致模型参数越过全局最优点，使模型训练失去收敛性，也可能使损失函数失效。过大的学习率还可能会使训练过程不稳定，导致模型在参数空间中跳动，难以收敛。

2.7 批量大小调整分析实验

批量大小是指训练过程中每次迭代输入到模型并用于一次参数更新的训练样本数量。为了分析批量大小对模型表现的影响，本文将批量大小以指数形式（2 的幂次）逐步增大，相应的模型准确率如图 9 所示。

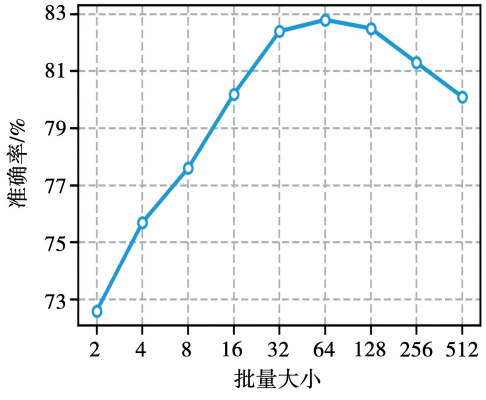

图 9 批量大小与准确率的关系

Fig. 9 Relationship between batch size and accuracy

由图可知，模型的准确率会先随着批量大小的增大而提高，但当批量增大到一定程度后开始下降。当批量大小较小（如 2、4、8）时，每次参数更新仅依据极少量样本估计梯度，梯度噪声较大，对小批量样本的随机性较为敏感，导致优化过程震荡、收敛方向不稳定，难以充分逼近较优解，准确率偏低。当批量大小过大（如 256、512）时，虽然梯度估计更为平滑、训练更稳定，但每个训练轮次内的参数更新次数减少，且大批量训练倾向于收敛到损失曲面中较尖锐的极小值点，这类解的泛化能力相对较弱，使得模型在测试集上的准确率有所回落。

3 结 语

为保障智能电表自动化检定流水线的稳健运行，对其健康状况进行实时监测与趋势预测，为运维备品

备件的精准筹备及整线高效运行提供重要支撑。本文提出了结合自注意力机制与双向长短时记忆网络的智能电表自动化检定流水线健康预测模型。该模型在自动分析检定流水线健康情况时,不仅建模了当前时刻的工作数据,同时也建模了历史工作数据。此外,该模型利用自注意力机制自动化地衡量不同历史时刻工作数据对未来健康状况的影响,为有重要影响的数据赋予更高的权重。最后,本文在实际数据上对模型进行测试,获得了良好的效果。

参 考 文 献:

[1] 杨继革,严俊,陈丽春,等. 基于智能电表的住宅短期电力负载预测[J]. 沈阳工业大学学报,2022, 44(3): 255.
YANG Jige, YAN Jun, CHEN Lichun, et al. Prediction of Short-term Electric Loads Based on Smart Meter[J]. Journal of Shenyang University of Technology, 2022, 44(3): 255.

[2] 刘洪源. 三相智能电表计量检定系统的设计与实现[D]. 沈阳: 沈阳农业大学,2022.

[3] 张贺然. 智能电表自动检定系统的设计与应用[D]. 沈阳: 沈阳农业大学,2020.

[4] 邢宇, 鲍志威, 孙艳玲, 等. 一种智能电能表自动化检定流水线表位在线异常检测方法[J]. 电测与仪表, 2020, 57(14): 106.
XING Yu, BAO Zhiwei, SUN Yanling, et al. Online Anomaly Detection Method for Meter Positions in Automatic Verification Assembly Line of Smart Meter[J]. Electrical Measurement & Instrumentation, 2020, 57(14): 106.

[5] 林聪, 纪新武, 何兆磊, 等. 电能表自动化检定装置运行质量监测方法研究[J]. 电测与仪表, 2023, 60(6): 194.
LIN Cong, JI Xinwu, HE Zhaolei, et al. Research on the Monitoring Method of the Operation Quality of the Automatic Verification Device for Electricity Meter[J]. Electrical Measurement & Instrumentation, 2023, 60(6): 194.

[6] 邵淮岭. 一种自动化检定流水线的风险预警和评估方法研究[J]. 电力与能源, 2016, 37(5): 561.
SHAO Huailing. Risk Early Warning and Evaluation Method for Automatic Calibration Line[J]. Power & Energy, 2016, 37(5): 561.

[7] 庄磊, 付真斌, 李玲, 等. 电能表自动检定系统计量特性的智能监测研究[J]. 仪器仪表标准化与计量, 2016(6): 38.
ZHUANG Lei, FU Zhenbin, LI Ling, et al. Research on Intelligent Monitoring of the Measurement Property in Electric Energy Meter Automatic Verification System[J]. Instrument Standardization & Metrology, 2016(6): 38.

[8] 杨东升,鲁观娜,丁恒春,等. 电能表自动检定流水线模糊故障诊断专家系统[J]. 电测与仪表,2017,54(7):94.
YANG Dongsheng, LU Guanna, DING Hengchun, et al. An Expert System for Fuzzy Fault Diagnosis of Auto-verification Line for Electric Energy Meters[J]. Electrical Measurement & Instrumentation,2017,54(7):94.

[9] 王立斌,高波,赵佩,等. 电能表自动化检定流水线表位故障定位及报警系统设计[J]. 河北电力技术,2018,37(1): 33.
WANG Libin, GAO Bo, ZHAO Pei, et al. Design of Meter Position Fault Location and Alarm System for Automatic Verification Pipeline of Electric Energy Meter[J]. Hebei Electric Power,2018,37(1): 33.

[10] 肖涛, 郑凡. 计量自动化流水线检定系统质量监控方法应用研究[J]. 电测与仪表, 2013, 50(5): 72.
XIAO Tao, ZHENG Fan. Application Research of Quality Monitoring Technique for Automatic Metrological Verification Pipeline System[J]. Electrical Measurement & Instrumentation, 2013, 50(5): 72.

[11] 高博, 张祯铭, 宋洪武, 等. 三相智能电能表自动检定流水线质量监控方法应用研究[J]. 吉林电力, 2019, 47(4): 37.
GAO Bo, ZHANG Zhenming, SONG Hongwu, et al. Application Research on Quality Monitoring Method of Automatic Verification Production Line of Three-phase Intelligent Watt-hour Meter[J]. Jilin Electric Power, 2019, 47(4): 37.

[12] JIAO Y, LI H, HU C, et al. Data-driven Evaluation for Error States of Standard Electricity Meters on Automatic Verification Assembly Line[J]. IEEE Transactions on Industrial Informatics, 2019, 15(9): 4999.

[13] LI Y, JIN X, ZHANG X, et al. Fault Monitoring Method of Electric Energy Meter Verification Assembly Line Based on Deep Learning[J]. Forest Chemicals Review, 2022,2022(7): 2270.

[14] 高正男, 杨帆, 胡姝博. 面向新能源电力系统状态估计的伪波动数据清洗[J]. 高电压技术, 2022, 48(6): 2366.
GAO Zhengnan, YANG Fan, HU Shubo. Pseudo-fluctuation Data Cleaning for State Estimation of New Energy Power System[J]. High Voltage Engineering, 2022, 48(6): 2366.

[15] MEDSKER L, JAIN L C. Recurrent Neural Networks: Design and Applications[M]. Boca Raton: CRC Press, 1999.

[16] HOCHREITER S, SCHMIDHUBER J. Long Short-term Memory[J]. Neural Computation, 1997, 9(8): 1735.

[17] 王喜莲,秦嘉翼,耿民. 基于 d-q 变换及 WOA-LSTM 的异步电机定子匝间短路故障诊断方法[J]. 电机与控制学报,2024,28(6):56.
WANG Xilian, QIN Jiayi, GENG Min. Asynchronous Motor Stator Turn-to-turn Short Circuit Fault Diagnosis Based on d-q Transform and WOA-LSTM[J]. Electric Machines and Control,2024,28(6):56.

[18] 张鹏,束小曼,厉雪衣,等. 基于 LSTM 的交流电机系统故障诊断方法研究[J]. 电机与控制学报,2022,26(3):109.
ZHANG Peng, SHU Xiaoman, LI Xueyi, et al. LSTM-based Fault Diagnosis of AC Electric Machine System [J]. Electric Machines and Control,2022,26(3):109.

[19] 郑鑫,陈海龙,马玉群,等. 融合依存句法和 LSTM 的神经机器翻译模型[J]. 哈尔滨理工大学学报,2023,28(3):20.
ZHENG Xin, CHEN Hailong, MA Yuqun, et al. Neural Machine Translation Model Combining Dependency Syntax and LSTM[J]. Journal of Harbin University of Science and Technology,2023,28(3):20.

[20] 张春祥,逄淑阳,高雪瑶,等. 一种融合 ACNN 和 Bi-LSTM 半监督缩略语消歧方法[J]. 哈尔滨理工大学学报,2022,27(5):30.
ZHANG Chunxiang, PANG Shuyang, GAO Xueyao. A Semi-Supervised Abbreviation Disambiguation Method Based on ACNN and Bi-LSTM[J]. Journal of Harbin University of Science and Technology,2022,27(5):30.

[21] ZHANG S, ZHENG D, HU X, et al. Bidirectional Long Short-term Memory Networks for Relation Classification [C]//Proceedings of the 29th Pacific Asia conference on language, information and computation, 2015: 73.

[22] BIN Y, YANG Y, SHEN F, et al. Bidirectional Long-short Term Memory for Video Description[C]//Proceedings of the 24th ACM International Conference on Multimedia, 2016: 436.

[23] HE L, JIANG D, YANG L, et al. Multimodal Affective Dimension Prediction Using Deep Bidirectional Long Short-term Memory Recurrent Neural Networks[C]//Proceedings of the 5th International Workshop on Audio/Visual Emotion Challenge, 2015: 73.

[24] 戴天虹,杨晓云,宋洁绮,等. 基于注意力机制的视觉位置识别方法[J]. 哈尔滨理工大学学报,2022,27(2):63.
DAI Tianhong, YANG Xiaoyun, SONG Jieqi. Visual Place Recognition Method Based on Attention Mechanism[J]. Journal of Harbin University of Science and Technology, 2022,27(2):63.

[25] 娄蕴祎, 张冬妍, 葛奕麟, 等. 基于改进双向注意力映射的单板图像修复[J]. 森林工程, 2023, 39(2): 132.
LOU Yunyi, ZHANG Dongyan, GE Yilin, et al. Image Inpainting of Veneer with Improved Learnable Bidirectional Attention Maps[J]. Forest Engineering, 2023, 39(2): 132.

[26] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 6000.

[27] YANG B, LI J, WONG D F, et al. Context-aware Self-attention Networks[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 387.

[28] YANG B, WANG L, WONG D F, et al. Convolutional self-attention networks [C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics,2019: 4040.

[29] KINGMA D P, BA J. Adam: A Method for Stochastic Optimization[J]. arXiv Preprint arXiv:14126980, 2014.

[30] HEARST M A, DUMAIS S T, OSUNA E, et al. Support Vector Machines[J]. IEEE Intelligent Systems and Their Applications, 1998, 13(4): 18.

[31] CHO K, VAN M B, GULCEHRE C, et al. Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, 2014: 1724.

[32] POPESCU M C, BALAS V E, PERESCU P L, et al. Multilayer Perceptron and Neural Networks[J]. WSEAS Transactions on Circuits and Systems, 2009, 8(7): 579.

[33] 朱欢欢, 李厚佳, 张梦梦, 等. 基于 BP 神经网络的外圆磨削颤振在线识别和监测方法[J]. 金刚石与磨料磨具工程, 2022, 42(1): 104.
ZHU Huanhuan, LI Houjia, ZHANG Mengmeng, et al. Online Identification and Monitoring Method for External Grinding Flutter Based on BP Neural Network[J]. Diamond & Abrasives Engineering, 2022, 42(1): 104.

(编辑:温泽宇)