

基于 Transformer-Bi-LSTM 模型的 武器装备剩余寿命预测方法

袁玉昕, 程跃兵, 熊敏艳, 高王升, 张昱彤

(上海机电工程研究所, 上海 201109)

摘要: 武器装备担负保卫国土安全的重要使命, 其保持稳定运行状态具有重大国防、政治意义; 因其装备运行状态不便中断、故障定位过程复杂, 使得传统维修方式效率较低; 装备使用数据具有连续性、长期性、不平稳性, 甚至一些深度学习模型无法处理其中的退化状态历史依赖与关联问题; 通过构建元器件层级的剩余寿命预测架构, 对特征工程、退化指标构建以及 Transformer-Bi-LSTM 模型开展研究, 采用距离编码技术, 实现针对深度学习模型的技术创新, 优化模型预测效果; 基于某型武器装备主要部件正常试样数据, 进行本方法分析验证, 在部件已运行时间达到 90% 设计试验寿命长度时能够进行有效且准确的剩余寿命预测, 所提方法满足武器装备部件寿命预警及更换提醒、保障装备战备完好性的应用需求。

关键词: 武器装备; 寿命预测; 健康管理; Transformer; Bi-LSTM; 退化指标; 距离编码

Method for Predicting the Residual Life of Weaponry based on Transformer Bi-LSTM Model

YUAN Yuxin, CHENG Yuebing, XIONG Minyan, GAO Wangsheng, ZHANG Yutong

(Shanghai Electro-Mechanical Engineering Institute, Shanghai 201109, China)

Abstract: Weaponry is responsible for the important mission of safeguarding national security, and its stable operation is of great national defense and political significance. Due to the inconvenient interruption of the equipment operation status and the complex fault location process, it results in lower efficiency of traditional maintenance methods. The equipment usage data has the characteristics of continuity, long-term, and instability, and some deep learning models cannot deal with the historical dependence and association of the degraded states. The remaining life prediction architecture at the component level is built to study the feature engineering, degradation index construction and Transformer bi-directional long short-term memory (Bi-LSTM) model. The distance coding is used to realize the technological innovation of the deep learning model and optimize the prediction effect of the model. Based on normal sample data of primary components of certain weapons and equipment, this method analyzes and validates the remaining life of the device, it can be effectively and accurately predicted in operation with 90% of the designed test life. The proposed method meets the application requirements of early warning and replacement for weaponry components, ensuring weaponry readiness.

Keywords: weaponry; residual life prediction; health management; Transformer; Bi-LSTM; degradation indicators; distance coding

0 引言

武器装备通常分为多个层级: 整机、分系统、单板(或元器件)。故障多发生于单板级, 由于武器装备耦合程度较高, 使用过程电磁环境复杂, 单板级故障产生的高能电流可能造成其他器件损坏, 使得分系统无法使用, 最终导致整机装备的性能降级或停用。针对单板级器材剩余使用寿命进行准确预测, 对及时发现、消除装备的安全隐患、提高运行的可靠性和保障装备实战化能力都有重要的现实意义。

随着武器装备技术不断发展, 武器装备结构复杂程度持续提升, 各组件设计向模块化、组合化方向发展, 且武

器装备不断向体系化作战发展^[1], 对装备战备完好性、装备故障检测以及故障排除提出了更高要求。传统的检修方式一般在装备发生故障后, 对其进行拆解、测试, 并定位装备发生故障的位置; 周期性更换的预防性维修在设备发生故障前, 设置固定的检测周期, 停用设备并检查各部件磨损情况。两种检修方式带来巨大成本浪费, 故障后的检修可能导致的设备故障扩散, 甚至会影响人身安全, 不满足装备实战化需求。现今, 工业生产中一般采用视情维修(CBM, condition-based monitoring), 通过装备加装的传感器或外部检测设备获得系统运行时的状态数据, 对这些状态数据进行综合评估, 根据异常状态采取对应的维护策

收稿日期: 2024-02-09; 修回日期: 2024-04-25。

作者简介: 袁玉昕(1998-), 男, 硕士研究生。

引用格式: 袁玉昕, 程跃兵, 熊敏艳, 等. 基于 Transformer-Bi-LSTM 模型的武器装备剩余寿命预测方法[J]. 计算机测量与控制, 2024, 32(7): 203-210.

略^[2]。故障预测与健康管理 (PHM, prognostics and health management) 技术则是基于 CBM 的升级发展, 通过系统内的采集数据, 经过数据处理及分析, 对系统的健康状态进行综合管理, 包括检测、预测等。当前, PHM 技术已广泛应用于航空航天等行业, 在工业生产中也得到广泛关注, 而剩余使用寿命预测则是 PHM 中的主要组成部分^[3-5]。

目前, PHM 已经在西方军事强国得到深度研究和开发, 被大量应用于军事国防、航空武器装备之中, 在降低维修保障成本, 提高装备的自主保障能力与战备完好性, 确保任务成功方面发挥着重要作用^[6]。PHM 技术一般依靠传感器技术, 在器材、设备中采集与其健康状态有直接或间接关系、能够反映其健康状态的信号 (如电压、电流、振动等), 定性或定量对设备退化状态进行评估, 预测装备未来健康状态和剩余使用寿命。

剩余寿命预测方法可以分为基于物理模型、基于数据驱动以及混合模型方法^[7-8]。基于物理模型的剩余寿命预测方法通过建立基于失效机理或磨损情况的数学模型来量化设备的健康状况。在实际应用中, 物理性质及失效因素难以完全掌握, 难以建立精准的数学模型模拟装备失效过程。而基于数据驱动的剩余寿命预测方法部署方式灵活, 能很好弥补基于物理模型的缺陷。其又可以分为基于统计模型、基于机器学习。近年来, 机器学习领域中基于深度学习的剩余寿命预测方法快速发展。例如, Li^[9]利用改进卷积神经网络 (CNN, convolutional neural network) 实现退化指标的自动提取, Zhao^[10]将 CNN 与 Bi-LSTM (Bi-directional Long Short-Term Memory) 结合用于剩余寿命预测, Zhu 等^[11]提出多尺度卷积神经网络进行剩余寿命预测的方法, 王者蓝等^[12]将卷积神经网络与滤波融合算法应用于惯导系统剩余寿命预测中。

然而, 现有的深度学习方法仅关注预测时间点附近的采样数据, 在处理寿命较长的装备数据集时, 忽视了退化状态历史依赖的问题, 导致预测效果不佳。针对此类问题, 采用 Transformer 模型提取退化信息的方法, 并利用 Bi-LSTM 进行寿命预测, 在两个模型之间加入中间层, 利用编辑距离方法实现退化信息拼接和整合, 最终完成对装备的剩余寿命预测。

1 方法架构

因武器装备实际工作态势中电磁环境复杂, 存在极端气候环境, 导致传感器受到干扰, 使得采样数据中包含较多的杂波或异常值。以往的深度学习方法直接将采样数据传输到剩余寿命预测模型, 应用在武器装备数据集时, 无效、干扰数据混杂在退化信息中, 使得模型受到干扰, 实际预测结果并不理想^[13]。因此模型设置数据预处理、退化指标构建、剩余寿命模型构建 3 个步骤, 实现数据的预先清洗, 构建能够反映装备退化过程的退化指标, 并根据退化指标设置能够处理退化信息历史依赖的剩余寿命预测模型。

1.1 数据预处理

数据的预处理一般包含如下工作: 数据清洗、数据集成、数据变换, 如图 1 所示。其中数据清洗主要负责去除数据中的重复数据、清除噪音数据、处理缺失值、处理异常值。数据集成主要用于处理多数据源合并时的实体识别问题和属性冗余问题。数据变换则是将数据进行规范化处理, 将数据转化至适用于数据挖掘或算法需求的形式。

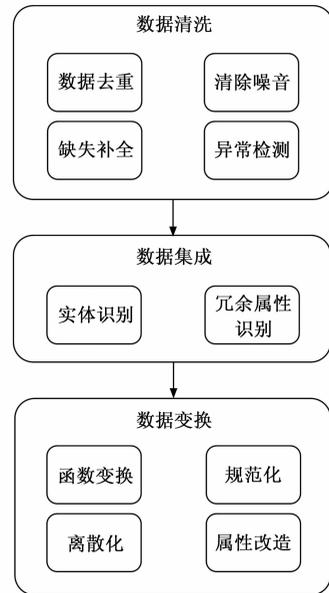


图 1 数据预处理

针对所用数据集, 数据预处理工作集中在清除噪音、缺失补全、异常检测、规范化 4 个方面^[14]。

因武器装备运行环境复杂, 使得传感器易受外部影响, 最终导致装备原始监测数据中通常存在高频噪声。高频噪声虽然不会对装备采样数据的退化趋势产生影响, 但当其输入预测模型后会对其预测准确度产生影响。小波降噪方法可以很好的去除高频噪声, 该方法指的是将数据进行小波分解, 将高频信号对应的系数设置为零, 并将小波信号逆向重构, 实现高频噪声的剔除。

数据采集过程中, 难免出现数据的缺失, 缺失值的处理一般采用线性插值、样条插值等方法, 线性插值根据缺失点附近数据生成线性关系, 对缺失值进行估计; 样条插值则是使用样条曲线来估计丢失的数据点。因所研究数据集缺失数据较少, 采用线性插值的方法。使用前后数据点之间的时间间隔来估计缺失值。

时序数据的异常检测只要针对的异常类型可分为 3 种: 单点异常、关联异常、集合异常以及多元异常^[15-16]。观察实际采样数据, 武器装备采样数据因环境影响主要为点异常, 可根据 3σ 置信区间法监测。异常数据根据高斯平滑的方法进行处理^[16], 能够有效降低异常值在数据中的显著程度。

数据规范化是进行数据挖掘的基础工作, 因装备采样

数据存在多种量纲, 不同中数据之间的差距存在较大差距, 为消除数据之间的量纲和取值范围等因素的影响, 需对数据进行标准化处理, 采用 Z-score 归一化方法, 其计算方法如式 (1) 所示:

$$x^* = \frac{x - \text{mean}(x)}{\sigma} \quad (1)$$

其中: x 为标准化处理后的数据, $\text{mean}(x)$ 表述数据 x 的均值, σ 表述数据的标准差。

1.2 退化指标构建

退化指标表示装备退化过程的数据指标, 是进行装备剩余寿命预测的重要工作, 恰当的退化指标能够简化模型, 获取更精确的预测结果。退化指标构架主要包括退化指标获取和退化指标评估。退化指标获取一般是将采样数据直接作为退化指标或将特征处理后的数据作为退化指标, 如表 1 所示。退化指标评估则是综合评估选取与退化趋势最相关的采样数据, 对退化指标的评估过程在大型复杂设备中却有重大意义^[17]。

表 1 特征处理

特征类型	特征名
时域特征	均值指标
	方根幅值
	质心
统计域特征	偏度 (Skewness)
	均方根 (Root Mean Square)
	标准差
频域特征	快速傅里叶变换
	小波包
	频谱最大频率

退化指标评估主要关注其单调性, 一致性。因装备及其部件退化过程为不可逆过程, 良好的退化指标应具有单调趋势。如式 (2) 所示:

$$M = \frac{\left| \text{No. of } \frac{d}{dx} > 0 - \text{No. of } \frac{d}{dx} < 0 \right|}{N - 1} \quad (2)$$

式中, N 为退化指标长度; d/dx 为退化指标的变化差异, 在实际计算时为退化指标中后一个数值减前一个数值; $\text{No. of } d/dx$ 为退化指标差异值大于 0 的个数, $M = 1$ 、 $M = 0$ 分别为退化指标的完全单调趋势和不单调趋势。

对应不同装备的同意退化指标, 其具有一致的退化模式, 则其应具有较小的分化指数方差应最小。其计算方法如式 (3) 所示。

$$\text{Con}(X) = \exp\left(\frac{-\text{std}(P_{\text{EOL}})}{\text{mean}(P_0 - P_{\text{EOL}})}\right) \quad (3)$$

其中: P_{EOL} 是退化指标在寿命结束时的数据所组向量, P_0 则是退化指标在装备初始阶段的数据所组向量。

装备退化指标的综合评分 $\text{Value}(HI)$, 如式 4 所示。其中, v_1 , v_2 为两个个评估标准分配的权重, 可通过权重调节变更退化指标选择标准, HI 为退化指标。进而, 根据所得综合评分可对退化指标进行排序及筛选。

$$\text{Value}(HI) = v_1 \text{Mon}(HI) + v_2 \text{Con}(HI) \quad (4)$$

选取一定比例获得较高评分的退化指标作为后续模型输入, 并舍弃其余退化指标。

1.3 预测模型构建

武器装备进行加速退化试验或日常监测数据会带来巨大成本, 导致其采样数据集较小, 且深度学习模型受最佳输入长度限制, 使其无法处理剩余寿命预测中存在的退化状态历史依赖与关联问题^[18-19]。由此, 通过样本空间拓展丰富样本集, 将退化指标样本集调整到合适长度, 并结合 Transformer 和 Bi-LSTM 网络, 构建剩余寿命预测模型。主要流程如图 2 所示。

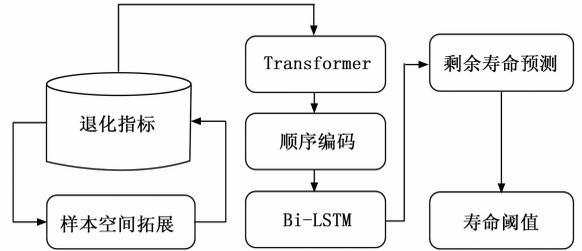


图 2 武器装备剩余寿命预测流程

1.3.1 样本空间拓展

通过自适应滑动窗口方法拓展样本空间, 设置固定长度的窗口, 截取时序数据片段并标记该时序片段对应已运行时间和剩余寿命时间, 根据设定步长移动窗口位置, 重复上述操作, 直到完整退化指标全部切分。具体过程如算法 1 所示。

算法 1: 样本空间拓展

输入: 退化指标 HI , 滑动步长 s_1, s_2 , 窗口宽度 l , 已运行时间 $time$, 剩余使用寿命 rul 。

输出: 分段序列集合 S

1) $S \leftarrow \varphi$; // 初始化分段集合库

2) $t \leftarrow 0$ // 起始端点

3) while HI not end: // 遍历退化指标

4) $S \leftarrow \text{seg}(HI, t, l, time, rul)$

// 通过 seg 函数截取退化指标样本, 样本包括退化指标片段、该片段对应的已运行时间 $time$ 、剩余使用寿命 rul 。

5) if HS changed do: // 如退化状态发生改变, // 设置不同滑动步长

6) $t \leftarrow t + s_2$

7) else:

8) $t \leftarrow t + s_1$

9) end if

10) end while

因退化指标存在不同程度的退化状态, 剧烈退化区间变化较快、退化信息复杂, 需要更多的样本信息。算法中采用变步长的方法, 当剩余寿命低于百分之三十, 退化状态发生变化进入剧烈退化区间设置较小滑动步长 s_2 , 其中 s_2 小于 s_1 。

1.3.2 基于 Bi-LSTM 的剩余寿命预测模型

长短期记忆网络 (LSTM, long short-term memory)

属于循环神经网络，能够处理 RNN 网络存在的梯度消失、梯度爆炸等问题，通过控制门导通状态，使得信息择通过，决定什么信息应该被保留，什么信息被遗忘。LSTM 网络结构如图 3 所示，其计算过程如公式 (5) ~ (10) 所示。

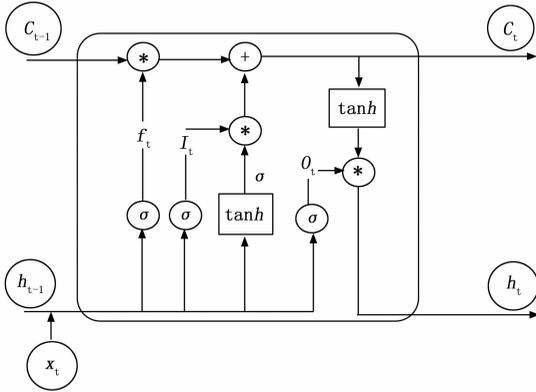


图 3 LSTM 网络结构

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma * (W_i * [h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t * \tanh(C_t) \quad (10)$$

i_t 为输入门， f_t 为遗忘门， o_t 为输出门， C_t 通过 i_t 和 f_t 控制更新，通过 o_t 来控制输出。

然而 LSTM 只能正向传播，忽视了时序数据前向关联关系。Bi-LSTM 可以通过双向传播弥补这个短板，其网络结构如图 4 所示，Bi-LSTM 双向的 LSTM 组合而成，包括前向和后向训练过程^[19]。

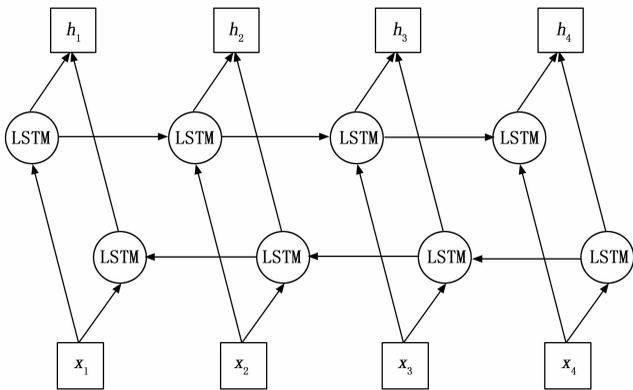


图 4 Bi-LSTM

1.3.3 基于 Transformer 的退化信息提取

由武器装备数据集所得退化指标长度范围一般超出 Bi-LSTM 处理长度，如使用单个 Bi-LSTM 网络覆盖完成退化指标进行剩余寿命预测需要对其进行延长，但网络输入的延长受性能的限制，因此 Bi-LSTM 网络无法满足武器装备剩余寿命预测的需求。

且仅基于待测时刻相邻退化指标信息，无法处理退化状态上下文关联问题。如不同趋势的退化指标存在相似的数据片段，则预测模型无法在当前时间片段辨别实际退化状态及趋势。部分研究针对此类问题提出不同处理方法：

- 1) 通过加长神经网络输入长度，在单次处理中输入更多的数据，该方法导致了训练时间增长、梯度消失；
- 2) 通过截取序列、随机采样等方法对数据进行筛选输入，压缩序列长度，此类方法导致了信息丢失；
- 3) 在退化指标与神经网络之间加入无监督自编码器，将时序数据进行编码，然后解码输出为所需长度序列作为网络输入。该方法能够在压缩数据长度过程中尽可能的减少信息损失，由此引入 Transformer 网络。

Transformer 是由编码器 (Encoder)、解码器 (Decoder) 两个部分组成，如图 5 所示^[20]，可通过调整编码器、解码器的层数改变 Transformer 的结构，其初始层数设置为 $N=6$ 。Transformer 是基于注意力机制的神经网络，已有大量研究应用在自然语言处理等领域并取得了良好的效果，基于其对时序数据强大的建模能力，也有研究将其应用于时序数据预测中^[21]。在 Transformer 的基础上构建时序预测能力可以突破以往的诸多限制，最明显的一个增益点是，面向时序数据的 Transformer 可以基于多头注意力结构具备同时建模长期和短期时序特征的能力^[22]。

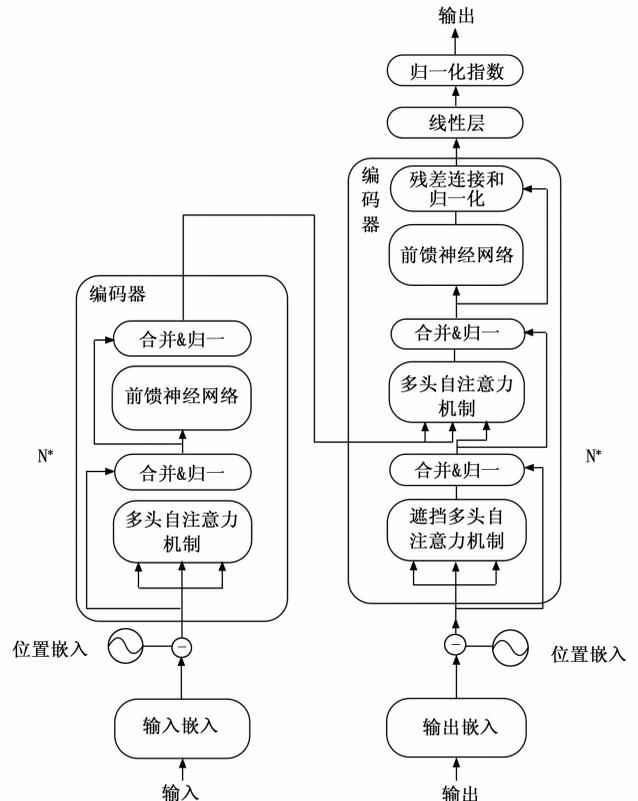


图 5 Transformer 结构

编码器负责将输入的退化指标进行编码，映射为包含退化信息的中间向量，其核心为自注意力机制，如图 6。

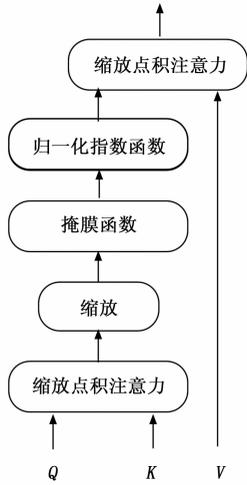


图 6 自注意力机制

自注意力机制是基于注意力机制的演变, 避免了传统注意力机制依赖外部信息的特性, 能够捕捉退化指标的內部相关性, 主要是通过计算特征向量间的相似度来表征相关性, 以此解决长距离依赖捕捉问题。在对装备进行剩余寿命预测时, 可利用自注意力机制从输入的退化指标中提取与退化信息相关的信息, 并使用权重代表信息的重要程度, 使得模型聚焦于重要退化信息上。自注意力机制计算过程如式 (11) ~ (14) 所示:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d}}\right)V \quad (11)$$

$$Q = X_j W^Q \quad (12)$$

$$K = X_j W^K \quad (13)$$

$$V = X_j W^V \quad (14)$$

式中, Q 为查询矩阵; K 为键矩阵; V 为值矩阵。这 3 个矩阵由输入矩阵 X_j 分别与对应的权重矩阵 W^Q 、 W^K 、 W^V 相乘得到, d 为 Q 、 K 、 V 的维数。

多头自注意力机制是基于多个自注意力机制的改进, 如图 7 所示将模型分为多个自注意力头, 形成多个子空间, 可以使模型能够去关注不同方面的信息。再将不同方面的信息进行拼接与线性变换, 得到最终的注意力值, 如式 (15) ~ (16) 所示:

$$MultiHead(Q, K, V) = Concat(h_1, h_2, h_3) \cdot W \quad (15)$$

$$h_k = Attention(XW_k^Q, XW_k^K, XW_k^V) \quad (16)$$

式中, W_k^Q 、 W_k^K 和 W_k^V 分别为第 k 个注意力头 Q 、 K 和 V 的权重矩阵; W 为多头注意力权重矩阵; m 为注意力头的数量; h_k 为第 k 个注意力头计算结果; 拼接函数表示用于拼接各个注意力头计算结果。

解码器用于将中间向量解码为输出序列, 考虑输入退化指标序列与实际剩余寿命数据之间的依赖关系, 在解码器中采用了编码-解码多头注意力机制。

将前述所构建退化指标样本限于用于 Transformer 训练中, 使得 Transformer 模型能够提取退化指标中的退化信

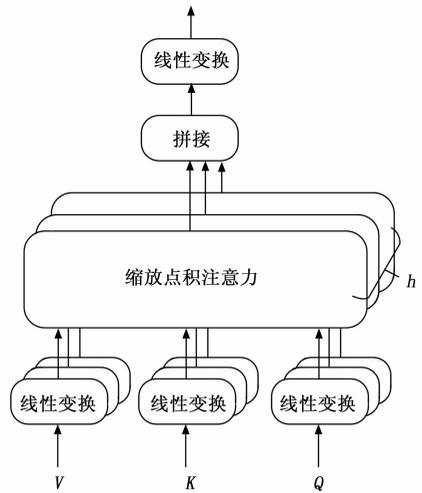


图 7 多头自注意力机制 (Masked Multi-Head Attention)

息^[21], 如图 8 所示。

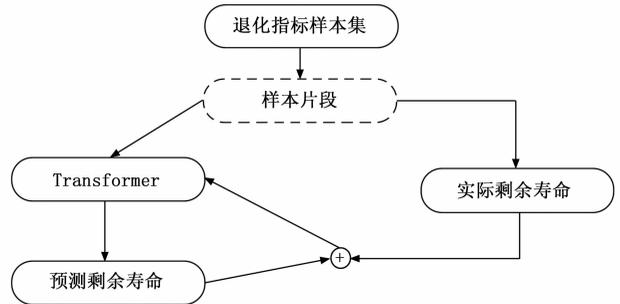


图 8 Transformer 退化信息提取训练

模型训练过程中将样本拓展所得样本片段作为查询向量和键向量, 值向量为该样本片段对应的剩余使用寿命。

将训练完成后的 Transformer 与 Bi-LSTM 组合成剩余寿命预测模型, 如图 9 所示。首先, Transformer 在武器装备数据集中提取退化新信息, 将退化信息进行顺序编码, 拼接合并后输入 Bi-LSTM 进行训练和剩余寿命预测。

在选定的间节点 T_n , 该时刻之前的退化指标样本片段 $[H_1, H_2, \dots, H_{n-1}]$, 输入 Transformer 抽取退化信息, 将退化信息进行顺序编码, 在获取的历史退化信息中加入序列顺序信息, 以实现历史退化信息的序列化继承, 如式 (17) 所示。

$$Info_{his} = \omega_1 info_1 + \omega_2 info_2 + \dots + \omega_{n-1} info_{n-1} \quad (17)$$

其中: ω 为退化指标提取的退化信息对应的顺序编码权重, n 为当前时间节点, $info_1$ 为 Transformer 在第 1 个退化指标样本中抽取的退化信息, 加号代表合并、拼接操作。

算法 2: 基于相对距离编码

输入: 退化信息集 INFO, 已运行时间 $time$

输出: 网络输入数据

1) $W \leftarrow 0$ // 权重

2) $length \leftarrow 0$ // 样本片段与预测时刻距离

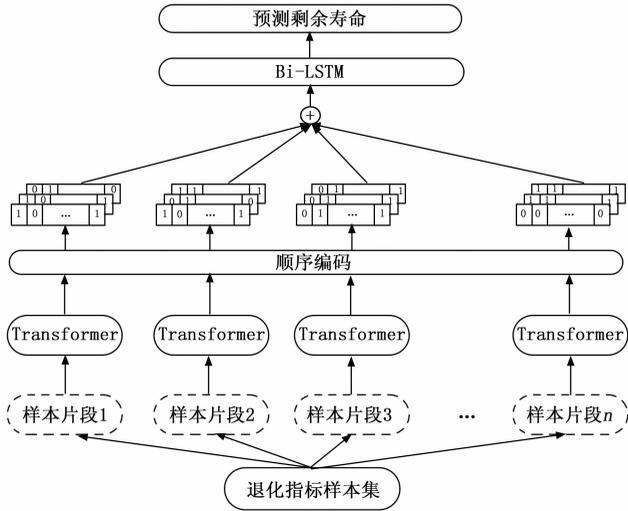


图 9 剩余寿命预测模型

```

3) S ← φ //编码信息初始化
4) for info in INFO: // 遍历退化信息
5) length ← Distance(info) // 获取距离
6) W = Exp(length, time) // 计算权重
7) S ← DistanceEncoding(W, info) //进行编码
8) end for
9) H ← Combine(S) // 对齐合并历史编码信息

```

Exp () 函数计算过程为 $W = e^{-\omega * i/100}$ ，通过调节权重参数 ω ，实现权重分配，权重越高表明更关注最新样本片段产生的影响。

2 实验结果分析

2.1 数据集介绍

为验证剩余寿命预测方法的有效性、准确性，使用武器装备中某型雷达器件采样数据集进行试验，实验数据均不涉及敏感数据。

实验过程中通过外接输入信号，模拟实际使用过程中的外部环境及使用频率等。通过针对该雷达器件加装监测传感器，进行采用数据的自动记录和传输，产生该器件生命周期内的采样数据集，其中数据采集频率设置为 $f=10$ Hz。此外，数据集中补充安装在历史使用过程中的周期性人工采样数据，确保数据集准确、全面。该数据集中记录了该型雷达器件多个状态参数从安装使用到完全损坏为止的完整生命周期内的每个时间序列的采样值，状态参数包括电压、电流、振动等。

根据数据规范化要求，在模型前期训练时将单个装备的寿命进行最大最小归一化处理，则装备总寿命 rul_{EOL} 为 1。所得预测剩余寿命 rul_{pre} 取值范围为 0 至 1。其中，1 代表当前时刻装备处于初始使用状态，即 $100\% rul_{EOL}$ 。0 则代表设备已损坏。预测剩余寿命时长 RUL_{pre} 如式 (18) 所示。

$$RUL_{pre} = t_{past} * \frac{rul_{pre}}{1 - rul_{pre}} \quad (18)$$

t_{past} 表示装备已运行时长， rul_{pre} 为当前时刻所得剩余寿

命预测值 (%)，其取值范围为 0 至 1。

2.2 评价指标

针对时序数据的预测需设置合适的评价指标，对预测结果进行评价时使用两个标准来评估模型性能，分别为：均方根误差 (RMSE)、平均评分函数 (MScore)。

2.2.1 均方根误差 (RMSE)

均方根误差反映预测值与真实值之间的误差，其计算方法如式 (19) ~ (20) 所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \Delta RUL_i^2} \quad (19)$$

$$\Delta RUL = RUL_{pre} - RUL_{true} \quad (20)$$

其中： ΔRUL_i 表示第 i 个测试样本所得剩余寿命预测误差。

2.2.2 平均评分函数 (MScore)

装备剩余寿命预测中存在超前预测和滞后预测，超前预测指的是装备预测剩余寿命真实值，反之为滞后预测。在装备剩余寿命预测中，超前预测意味着系统合适使用时长内停止工作，导致资源浪费。然而，滞后预测意味着系统在已发生故障的情况下将继续运行，可能导致严重后果。平均评分函数能够对两种状态进行区分，它对滞后预测惩罚更多。

对于样本数为 n 的数据集，平均评分函数计算公式如式 (21) 所示。

$$Score = \sum_{i=1}^n S_i \quad (21)$$

$$S_i = \begin{cases} e^{-\Delta RUL_i/a_1} - 1, & \Delta RUL_i \leq 0 \\ e^{\Delta RUL_i/a_2} - 1, & \Delta RUL_i > 0 \end{cases} \quad (22)$$

$$MScore = \frac{1}{n} Score \quad (23)$$

a_1 和 a_2 分别为超前预测和滞后预测的惩罚系数，设置为： $a_1=13$ ， $a_2=10$ 。

2.2.3 预测准确率

对照平均评分函数，针对装备剩余寿命的预测结果也可分为准确预测、超前预测和滞后预测。设置剩余寿命预测误差区间 $[T_1, T_2]$ 为准确预测区间，剩余寿命预测误差小于 T_1 视为超前预测，剩余使用寿命误差大于 T_2 视为滞后预测。

根据预测结果所在区间数量，计算预测正确率、超前率、滞后率，如式 (24) ~ (27) 所示。

$$P_{correct} = \frac{n_{correct}}{n} \quad (24)$$

$$P_{early} = \frac{n_{early}}{n} \quad (25)$$

$$P_{late} = \frac{n_{late}}{n} \quad (26)$$

$$abs(T_1 - 0) > abs(T_2 - 0) \quad (27)$$

2.3 模型结果

为验证模型的有效性，测试模型实际预测效果。如图 10 所示，已运行时间和剩余寿命均以在实际完整生命周期

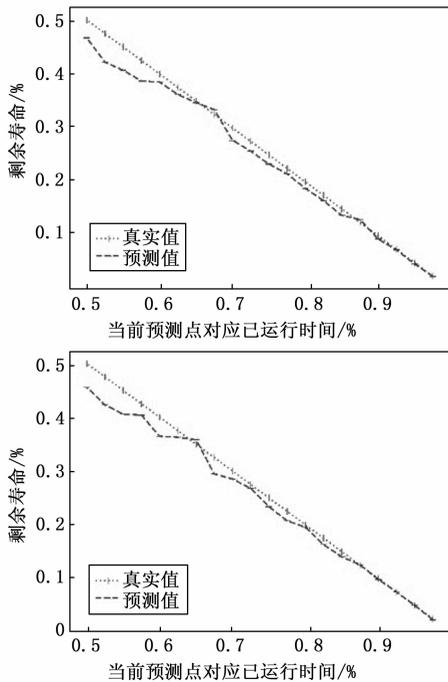


图 10 剩余寿命预测结果

的占比表示, 在两个测试集上, 预测剩余寿命与实际剩余寿命有着整体一致的退化趋势, 当剩余使用寿命较长时, 存在较大误差, 当剩余使用寿命小于 0.2 时剩余寿命预测方法方法表现出较高的准确度。

前述提到基于 Transformer-Bi-LSTM 的剩余寿命预测模型相比于循环神经、长短记忆神经网络更具优势, 为此在使用退化指标的基础上, 采用了长短记忆网络、双向长短记忆网络、卷积神经网络等作为预测模型进行对比实验。

为验证模型在处理长距离继承的准确度, 在上述方法中进行验证, 图 11 展示不同方法在多个测试集上的平均表现, 剩余寿命与预测误差均已实际运行时间表示。观察可知, 在装备退化指标上实施的 Bi-LSTM、Transformer 等方法之间表现相近^[23-25], 且 Transformer 相较于其他方法在剩余寿命较短时表现出较好的收敛特性。卷积神经网络误差较大, 难以实现对长寿命装备进行准确的剩余寿命预测。此外, 通过将装备采样数据直接输入双 Bi-LSTM 方法, 与所提方法

相比存在较大误差。

将多个剩余寿命预测方法在装备数据集上进行剩余寿命预测, 采用均方根误差与平均评分作为实验结果对比的衡量标准, 可得: 所提方法预测模型相比于其他 4 种模型具有更低的均方根误差及平均评分, 相较于 Bi-LSTM 模型均方根误差降低了 28.0%, 平均评分降低了 9.9%, 相较于 Transformer 模型均方根误差降低了 33.5%, 平均评分降低了 14.2%。其他方法相比所提方法 RMSE 值增长 2.8 以上, MScore 值增长 0.1 以上, 进一步验证了所提方法的有效性与先进性。在已有研究中深度学习模型具有突出的深层次学习能力, 能够挖掘退化信息, 例如建立准确的滚动轴承 RUL 预测模型^[23-24]。然而, 本文试验结果验证了 Transformer 凭借自注意力机制, 能够实现针对退化指标与装备退化过程之间的依赖关系, 使其在本文数据集中表现优于其他深度学习模型。本文方法去除退化指标构建及其之前工作, 将采样数据直接应用与 Transformer-Bi-LSTM 模型, 可得其预测效果衰退, 这是由于装备采样数据的直接输入, 引入了大量无关信息或干扰信息, 使得模型受到干扰, 这表明了前期退化指标构建的必要性。

3 结束语

针对武器装备单板级别数据集, 构建了结合 Transformer 和 Bi-LSTM 的剩余寿命预测模型。针对复杂环境下武器装备数据集研究数据预处理方法, 并提出退化指标评估方法, 对数据集进行筛选。模型训练分为两个阶段, 第一阶段为基于退化指标的 Transformer 训练, 实现其对退化信息的提取功能; 第二阶段加入顺序编码方法, 将提取的退化信息按照距离编码后输入 Bi-LSTM 进行训练, 从而获

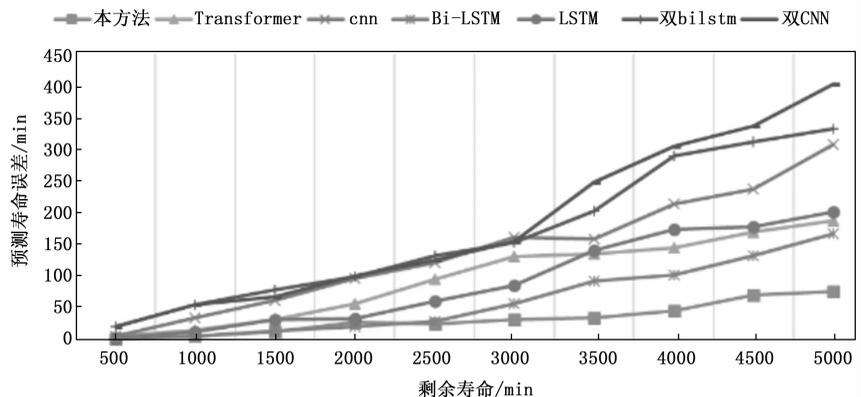


图 11 不同方法预测误差比较

表 2 基于正常寿命设备集的方法评估

方法	LSTM	Bi-LSTM	CNN	Transformer	双 Bi-LSTM	Transformer-Bi-LSTM(本文)	本文方法
RMSE	23.05	21.74	18.42	23.53	25.52	17.00	15.65
MScore	1.24	1.13	2.62	1.19	2.43	1.21	1.02
Pcorrect/%	86.54	86.32	79.12	87.71	86.12	88.20	89.34

取剩余寿命预测值。验证方法架构在武器装备数据集上的可行性, 在长寿命时长的预测准确度提高 1.53% 以上, RMSE 与 MScore 分别降低 15% 和 9%, 在实际应用中具备更高的稳定性, 验证了模型在处理长距离继承的能力上, 表现出该方法相比于其他方法表现出较好的性能和稳定性。未来, 我们将尝试把本文方法拓展至武器装备各单板, 并整合至分系统级别, 实现更高层次的装备健康管理。

参考文献:

- [1] 赵仁星, 王玲, 冯明月, 等. “马赛克战”作战概念构想及对策分析 [J]. 空天防御, 2021, 4 (3): 48-54.
- [2] YUCESAN Y A, DOURADO A, VIANA F A C. A survey of modeling for prognosis and health management of industrial equipment [J]. *Advanced Engineering Informatics*, 2021, 50: 101404.
- [3] KHALEGHI S, HOSEN M S, KARIMI D, et al. Developing an online data-driven approach for prognostics and health management of lithium-ion batteries [J]. *Applied Energy*, 2022, 308: 118348.
- [4] XU J, WANG Y, XU L. PHM-oriented integrated fusion prognostics for aircraft engines based on sensor data [J]. *IEEE Sensors Journal*, 2013, 14 (4): 1124-1132.
- [5] 景博, 黄崧琳, 王生龙, 等. 军用飞机 PHM 系统一体化设计架构分析 [J]. 航空工程进展, 2022, 13 (3): 64-73.
- [6] BROTHERTON T, MACKEY R. Anomaly detector fusion processing for advanced military aircraft [C] // 2001 IEEE Aerospace Conference Proceedings (Cat. No. 01TH8542). IEEE, 2001, 6: 3125-3137.
- [7] PATTNAIK T, BALLAL M S. Predictive approach for age and RUL estimation of lithium-ion batteries in EVs based on capacitance [C] // 2023 IEEE International Conference on Power Electronics, Smart Grid, and Renewable Energy (PESGRE), 2023.
- [8] LIANG T, WANG R, ZHANG X, et al. Predicting reliability and remaining useful life of rolling bearings based on optimized neural networks [J]. *Structural Durability & Health Monitoring*, 2023, 17 (5): 433-455.
- [9] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks [J]. *Reliability Engineering & System Safety*, 2018, 172: 1-11.
- [10] ZHAO R, YAN R, WANG J, et al. Learning to monitor machine health with convolutional bi-directional LSTM networks [J]. *Sensors*, 2017, 17 (2): 273.
- [11] ZHU J, CHEN N, PENG W. Estimation of bearing remaining useful life based on multiscale convolutional neural network [J]. *IEEE Transactions on Industrial Electronics*, 2018, 66 (4): 3208-3216.
- [12] 王者蓝, 赵宏杰, 赵凡, 等. 基于卷积神经网络与滤波融合算法的某惯导系统剩余寿命预测模型建立 [J]. 空天防御, 2023, 6 (1): 70-77.
- [13] HUANG C G, HUANG H Z, LI Y F. A bidirectional LSTM prognostics method under multiple operational conditions [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66 (11): 8792-8802.
- [14] BARANDAS M, FOLGADO D, FERNANDES L, et al. TS-FEL: time series feature extraction library [J]. *SoftwareX*, 2020, 11: 100456.
- [15] XU X, LIU H, YAO M. Recent progress of anomaly detection [J]. *Complexity*, 2019, 2019.
- [16] COOK A A, MISIRLIG, FAN Z. Anomaly detection for IoT time-series data: a survey [J]. *IEEE Internet of Things Journal*, 2019, 7 (7): 6481-6494.
- [17] LEI Y, LI N, GUO L, et al. Machinery health prognostics: a systematic review from data acquisition to RUL prediction [J]. *Mechanical Systems and Signal Processing*, 2018, 104: 799-834.
- [18] CHENG Z, CAI B. Predicting the remaining useful life of rolling element bearings using locally linear fusion regression [J]. *Journal of Intelligent and Fuzzy Systems*, 2018, 34 (6): 1-12.
- [19] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A S. A comparative analysis of forecasting financial time series using arima, lstm, and bilstm [J]. *ArXiv Preprint ArXiv*: 1911.09512, 2019.
- [20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [21] NGUYEN M, LAI V, VEYSEH A P B, et al. Trankit: a light-weight transformer-based toolkit for multilingual natural language processing [J]. *ArXiv Preprint ArXiv*: 2101.03289, 2021.
- [22] 宋晓, 周哲韬, 刘路, 等. 一种基于 Transformer 模型的滚动轴承剩余使用寿命预测方法 [J]. 北京航空航天大学学报, 2023, 49 (2): 430-443.
- [23] ZHU J, CHEN N, PENG W, et al. Estimation of bearing remaining useful life based on multiscale convolutional neural network [J]. *IEEE Transactions on Industrial Electronics*, 2018, 66 (4): 3208-3216.
- [24] LIN W, MIAO X, CHEN J, et al. Forecasting thermal parameters for ultra-high voltage transformers using long- and short-term time-series network with conditional mutual information [J]. *IET Electric Power Applications*, 2022, 6 (5): 548-564.
- [25] DAS A, HUSSAIN S, YANG F, et al. Deep recurrent architecture with attention for remaining useful life estimation [C] // TENCON 2019-2019 IEEE Region 10 Conference (TENCON), 2019.