



基于核函数的寿命预测融合算法研究

唐欢, 李依竹, 吕鹏

(中车株洲电力机车研究所有限公司, 湖南 株洲 412001)

摘要: 实时寿命预测是评估运营中的轨道交通控制装置剩余寿命的有效手段, 目前实时寿命预测主要基于故障物理和基于退化数据这2种方法。在轨道交通控制装置生命周期的早期, 由于缺乏实时采集的退化数据, 基于故障物理方法的预测结果会优于基于退化数据方法, 而在生命周期末期, 随着大量退化数据的积累, 基于退化数据方法的预测结果会更加精确。因此, 文章提出了一种基于核函数的寿命预测融合算法, 将故障物理方法与退化数据方法的预测结果进行融合, 以获取全生命周期更为准确的寿命预测结果。文章以轨道交通控制装置某核心板卡上的光耦为例, 通过加速退化试验的数据对比验证了故障物理方法、退化数据方法和融合算法的结果, 结果显示融合算法在全生命周期内具有更高的预测精度。

关键词: 城市轨道交通; 实时寿命预测; 故障物理; 退化数据; 核函数

中图分类号: U239.9

文献标志码: A

文章编号: 1000-128X(2024)05-0012-05

0 引言

随着城市化进程的不断推进, 城市轨道交通作为城市交通的重要组成部分, 其安全性、稳定性和智能化水平直接影响着城市的运行效率和居民的出行体验。轨道交通系统的控制装置作为系统的核心组件, 承载着信号传输、功率控制等关键功能, 其性能的优劣直接关系到整个轨道交通系统的可靠性和稳定性。随着运营规模的扩大和技术的迭代, 如何有效预测和延长轨道交通控制装置的使用寿命, 成为了行业关注的焦点。目前, 在线式寿命预测技术作为评估产品剩余寿命的有效手段, 在轨道交通领域扮演着越来越重要的角色。故障物理方法和基于退化数据分析的方法是2种主要的在线式寿命预测技术。故障物理方法侧重于通过故障物理模型和实时环境应力数据来评估产品的剩余寿命, 而基于退化数据分析的方法则侧重于利用实时采集的退化数据来进行寿命评估。这2种方法在轨道交通控制装置的不同生命周期阶段各有优势, 但同时也存在一定的局限性。在产品的早期阶段, 由于缺乏实时采集的退化数据, 故障物理方法的预测结果相对更优。然而, 在产品的后期阶段, 由于积累了大量的

退化数据, 基于退化数据分析的方法的预测结果更加精确。

针对2种预测方法的优缺点, 本文将提出一种基于核函数的在线式寿命预测融合算法。该算法旨在结合故障物理方法和基于退化数据分析的方法的优势, 通过核函数处理故障物理模型和退化数据, 以期在整个产品生命周期中实现更高的预测精度。为了验证所提算法的有效性, 本研究选取轨道交通控制装置中核心板卡上的光耦作为研究对象, 并设计了加速退化试验。试验结果表明, 本文所提出的融合算法能够有效提升全生命周期中光耦寿命的预测精度, 为轨道交通控制装置的维护和寿命预测提供了新的解决方案。

1 基于故障物理的寿命预测算法

1.1 故障物理基本介绍

基于故障物理的寿命预测方法是指通过研究引起故障发生的物理、化学过程, 建立故障时间或性能参数与引起故障的要素之间定量关系的确定性模型, 目前常用的故障物理模型包括 Arrhenius 模型^[1]、Coffin-Manson 模型^[2]和广义的 Eyring 模型^[3]。

通信作者: 唐欢, 硕士, 主要从事电子装置可靠性方面的研究; E-mail: tanghuan3@csrzc.com

引用格式: 唐欢, 李依竹, 吕鹏. 基于核函数的寿命预测融合算法研究[J]. 机车电传动, 2024(5): 12-16.DOI:10.13890/j.issn.1000-128X.2024.05.002.

Citation: TANG Huan, LI Yizhu, LYU Peng. Research on fusion algorithm for service life prediction based on kernel functions[J]. Electric drive for locomotives, 2024(5): 12-16.DOI:10.13890/j.issn.1000-128X.2024.05.002.

1) Arrhenius 模型

Arrhenius 模型用于表征寿命与温度的关系, 温度是唯一的故障加速因素, 其数学表达式为

$$\tau = A \cdot \exp\left(-\frac{E_a}{kT}\right) \quad (1)$$

式中: τ 为 Weibull 模型的特征寿命或是正态模型、对数正态模型的中位寿命; E_a 为活化能; k 为玻尔兹曼常数; T 为热力学温度; A 为与温度无关的常数。

2) Coffin-Manson 模型

Coffin-Manson 模型用于表征寿命与温度循环的关系, 其数学表达式为

$$N = \frac{C}{(\Delta T)^n}, \quad n > 1 \quad (2)$$

式中: N 为温度循环的循环次数; ΔT 为温度循环的范围; C 为经验常数。

3) 广义的 Eyring 模型

广义的 Eyring 模型描述了寿命与温度、非热应力的关系, 其中非热应力可以是湿度、电压、电流密度、压力、振动或者机械载荷等^[3], 其数学表达式为

$$\tau = \frac{C}{T^n} \cdot \exp\left(-\frac{E_a}{kT}\right) \cdot \exp(BX) \cdot \exp\left(\frac{DX}{kT}\right) \quad (3)$$

式中: X 为非热应力; B 、 D 为常数; DX 为交互作用项, 表示非热应力 X 和温度应力 T 之间相互影响。

1.2 基于故障物理的剩余寿命计算

采用前文的故障物理模型或者其他故障物理模型计算得到产品在对应环境条件下的寿命值 T 后, 工作了时间 t 之后的剩余寿命 $R(t)$ 可以通过式(4)计算得到。

$$R(t) = T - t \quad (4)$$

2 基于退化数据的寿命预测算法


2.1 双向 BiLSTM 模型

双向 BiLSTM 模型是一种循环神经网络 (Recurrent Neural Network, RNN) 的变种, 通过在前、后 2 个方向上运行 2 个独立的长短期记忆网络 (Long Short-Term Memory, LSTM) 来捕捉输入序列的上下文信息。BiLSTM 的前向计算和后向计算可以分别用于捕捉序列的历史信息和未来信息, 因此可以更全面地理解序列中各个位置的上下文关系^[4-5]。

在使用双向 BiLSTM 模型进行寿命预测时, 可以将寿命数据转化为 1 个序列。例如, 对于 1 个设备, 可以将其历史运行状态的数据按照时间顺序排列形成 1 个时间序列, 其中每个时间点的数据可以为表示设备状态的各种指标, 如温度、振动、电流等。这些数据经过预处理和特征提取后, 作为输入序列传入双向 BiLSTM 模型。双向 BiLSTM 模型通过前向和后向计算捕捉到序列数据的上下文信息, 学习设备运行状态的演变趋势和关联性, 并通过训练好的模型, 利用最新

的设备状态数据进行序列预测, 预测设备的未来寿命。

双向 BiLSTM 网络结构图如图 1 所示, 其中 BiLSTM 由前向和后向循环的 2 个 LSTM 网络构成, 综合了前向和后向的预测结构, 进而得到最终的神经网络预测结构。



x_i —输入值; y_i —预测值; Cell—LSTM网络结构单元。

图1 BiLSTM网络结构图

Fig. 1 Network structure of BiLSTM

LSTM 结构单元 (Cell)^[6-7]能够记录当前时刻状态, 也称记忆单元, 如图2所示。LSTM 的计算节点由遗忘门、输入门、输出门和细胞组成, 其中遗忘门负责丢弃记忆单元状态中的无用信息, 输入门决定哪些信息可以输入当前记忆单元状态, 输出门决定信息的最终输出^[8-9]。




图2 LSTM单元内部结构图

Fig. 2 Inner structure of LSTM cell

在任意的 t 时刻, LSTM 的状态更新算法过程为:

①遗忘门

$$f_t = \sigma(W_f x_t + U_f y_{t-1} + b_f) \quad (5)$$

②输入门

$$\left. \begin{aligned} i_t &= \sigma(W_i x_t + U_i y_{t-1} + b_i) \\ c'_t &= \tanh(W_c x_t + U_c y_{t-1} + b_c) \\ c_t &= f_t \cdot c_{t-1} + i_t \cdot c'_t \end{aligned} \right\} \quad (6)$$

③输出门

$$\left. \begin{aligned} o_t &= \sigma(W_o x_t + U_o y_{t-1} + b_o) \\ y_t &= o_t \cdot \tanh(c_t) \end{aligned} \right\} \quad (7)$$

式中: f_t 、 i_t 、 o_t 、 c'_t 、 c_t 分别代表遗忘门、输入门、输出门、记忆细胞的候选值、细胞状态; $\sigma()$ 和 $\tanh()$ 分别为 sigmoid 函数和双曲正切函数; W 、 U 和 b 分别为

输入权重矩阵、循环权重矩阵和偏置矩阵； y_i 为最终输出。

2.2 基于双向BiLSTM模型的剩余寿命计算

基于数据驱动的剩余寿命预测是采用miner线性损伤方法，认为性能参数 θ 在 t 时刻的损伤量 $\Delta\theta(t)$ 的大小和系统已经工作的时间 t 成正比关系，具体为

$$\frac{\Delta\theta(t)}{\Delta\theta_{th}} = \frac{t}{T_{end}} = \frac{t}{t+R(t)} \quad (8)$$

式中： $\Delta\theta(t)$ 为性能参数 θ 工作到 t 时刻的损伤量， $\Delta\theta(t) = \theta(t) - \theta(0)$ ，其中 $\theta(0)$ 为性能参数 θ 的初始值； $\Delta\theta_{th}$ 为性能参数 θ 的裕量，可用性能参数的初始值和阈值相减得到； T_{end} 为性能参数 θ 可能达到的最大寿命值，它等于已经工作了的时间 t 加上 t 之后的剩余寿命 $R(t)$ 。

根据式(8)，可得到 t 时刻的剩余寿命 $R(t)$ 为

$$R(t) = \frac{\Delta\theta_{th} - \Delta\theta(t)}{\Delta\theta(t)} \cdot t \quad (9)$$

3 基于核函数的融合算法

3.1 核函数融合预测的原理介绍

核函数融合预测的整体框架如图3所示。核函数融合的流程为：首先使用故障物理模型预测得到一个剩余寿命，然后使用数据驱动算法预测得到另一个剩余寿命，最后选择合适的核函数，采用类似权重分配的方法，融合两者预测的结果^[10-11]。




图3 基于核函数的融合算法计算路线

Fig. 3 Calculation process of the kernel function-based fusion algorithm

当产品刚投入工作时，测量记录的数据还不足以得到比较好的寿命预测结果，此时能得到的主要是产品的工作应力和环境应力等参数。因此，在融合预测的初期，故障物理的预测结果占比大；随着时间的进行，数据量增加，数据驱动预测结果准确性增加，需

要增大数据驱动的权重^[12-14]。

故障物理模型和数据驱动预测的剩余寿命预测应当是一个非增函数，可选用Logistic函数作为核函数进行预测，Logistic函数是一个指数型的单调递减函数，取值在0~1^[15-16]，其函数为：

$$K_{pof}(t_0, t_i) = \begin{cases} \frac{1}{1 + \exp(b \cdot \frac{t_i - t_0}{T_{end} - t_0})}, & 0 \leq b \leq b_{max} \\ 0, & \text{其他} \end{cases} \quad (10)$$

$$K_{data}(t_0, t_i) = 1 - K_{pof}(t_0, t_i)$$

式中： $K_{pof}(t_0, t_i)$ 为故障物理模型的核函数系数； $K_{data}(t_0, t_i)$ 为基于数据驱动的核函数； b 为常量参数，控制核函数的变化形状， b 越大，核函数的衰减速度越快； t_0 、 t_i 分别为故障物理和数据驱动预测的剩余寿命的算术平均值， t_i 的具体计算见式(11)。

$$t_i = \frac{R_{pof}(i) + R_{data}(i)}{2}, \quad i = 0, 1, 2, \dots, n \quad (11)$$

式中： $R_{pof}(i)$ 、 $R_{data}(i)$ 分别为时刻 i 的故障物理和基于数据驱动预测得到的剩余寿命值。

利用该核函数融合得到的融合寿命 $R_{merge}(\theta)$ 为

$$R_{merge}(\theta) = \frac{K_{pof}(t_0, t_i)R_{pof}(i) + K_{data}(t_0, t_i)R_{data}(i)}{K_{pof}(t_0, t_i) + K_{data}(t_0, t_i)} \quad (12)$$

3.2 基于核函数的剩余寿命计算

基于核函数的剩余寿命计算的流程包括以下步骤：

①采用故障物理模型预测剩余寿命。利用故障物理寿命模型，输入相关模型的参数和应力参数后，由模型直接计算得到故障物理寿命值，然后用式(4)计算剩余寿命值。

②数据驱动剩余寿命预测。首先利用数据驱动的预测算法，预测得到性能参数的退化值，然后再用式(9)把性能参数值转化为剩余寿命值。

③核函数融合。利用核函数式(10)~式(12)，将故障物理和数据驱动各自预测得到的剩余寿命进行融合，得到融合的剩余寿命。

4 案例研究

为验证基于核函数的故障物理和数据驱动融合预测方法的可行性与可靠性，本文以某轨道交通控制装置中核心板卡上的光耦为例，在该板卡上增加了1路光耦实时退化参数监测电路。该监测电路通过实时监测光耦一次侧和二次侧限流电阻上的电压，计算推导一次侧和二次侧的电流，进而实时计算光耦的退化参数“电流传输比(CTR)”。本案例以该光耦在加速退化试验中记录的CTR数据进行计算说明。

加速退化试验的环境温度设置为恒定高温85℃，时间为1 000 h，每间隔10 h记录1次光耦CTR值，并

假设CTR值在初始值的基础上退化5%即认为“光耦故障”。部分试验数据如表1所示。

表1 退化试验部分数据

Table 1 Partial data from degradation experiments

试验时间/h	CTR	试验时间/h	CTR
0	0.849	80	0.840
10	0.845	90	0.840
20	0.844	⋮	⋮
30	0.841	960	0.812
40	0.841	970	0.813
50	0.841	980	0.812
60	0.840	990	0.812
70	0.840	1 000	0.811

以广义的Eyring模型为基础,通过加速寿命试验拟合得到某型号光耦的加速寿命模型,计算公式为

$$L=L_0\times\left(\frac{J}{J_0}\right)^N\times\exp\left(\frac{E_a}{K}\cdot\left(\frac{1}{T_0}-\frac{1}{T}\right)\right)$$
 (13)

式中: L 为光耦实际寿命; L_0 为某初始试验条件下计算得到的光耦寿命,取 $L_0=1\ 100\text{ h}$; J 为实际使用条件下的工作电流; J_0 为初始试验条件下的工作电流; T 为实际使用条件下的环境温度; T_0 为初始试验条件下的环境温度, $T_0=85\text{ }^{\circ}\text{C}$; N 为模型系数,取 $N=2$ 。

本试验以恒定85℃高温加速退化试验为例,设置工作电流与初始试验条件保持一致,则可以认为 $L=L_0=1\ 100\text{ h}$ 。

分别利用故障物理的寿命预测方法、基于退化数据的寿命预测方法和基于核函数的寿命预测融合算法计算光耦的剩余寿命,计算结果如图4所示。




图4 寿命预测结果对比

Fig. 4 Comparison of service life prediction results

由图4可知,在加速退化试验初期,故障物理方法计算结果与真实结果更吻合;到试验末期,基于退化数据的方法计算结果与真实结果更吻合;通过核函数的融合算法,使得全生命周期的预测结果得到了一定的提升。

5 结束语

为改善现有轨道交通控制装置寿命预测方法的局限性,提高轨道交通控制装置寿命预测的准确性,本文提出了一种全新的在线式寿命预测方法。该方法通过将故障物理寿命预测方法和基于退化数据的寿命预测方法相结合,融合2种方法的优势,并以轨道交通控制装置某核心板卡上的光耦为例,通过加速退化试验验证了本方法的可行性和有效性,证明了其在寿命预测中的优越性能,在整个生命周期内提升了预测精度,能够为轨道交通控制装置提供更可靠和准确的剩余寿命评估,进而实现更优的设备管理和维护策略,对提高轨道交通控制装置的可靠性和降低运营成本将产生积极的影响。在未来的工作中,将在现有技术的基础上结合大数据和最新的人工智能技术开展研究,将轨道交通控制装置寿命预测方法提升至新的水平。

参考文献:

[1] AZIZ S B, ABIDIN Z H Z. Electrical conduction mechanism in solid polymer electrolytes: new concepts to arrhenius equation[J]. Journal of soft matter, 2013, 2013(1): 323868.

[2] BASARAN C, YAN C Y. A thermodynamic framework for damage mechanics of solder joints[J]. Journal of electronic materials, 1998, 120(4): 379-384.

[3] ACHCAR J A, NETO F L. Accelerated life tests with an exponential distribution: a Bayesian approach with the generalized eyring model and type II censored data[J]. Revista de matematica e estatistica, 1992(10): 31-46.

[4] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks[J]. IEEE transactions on signal processing, 1997, 45(11): 2673-2681.

[5] HUANG Zhiheng, XU Wei, YU Kai. Bidirectional LSTM-CRF models for sequence tagging[EB/OL]. (2015-08-09) [2024-05-12]. <https://arxiv.org/abs/1508.01991>.

[6] BAZI R, BENKEDJOUH T, HABBOUCHE H, et al. A hybrid CNN-BiLSTM approach-based variational mode decomposition for tool wear monitoring[J]. The international journal of advanced manufacturing technology, 2022, 119 (5): 3803-3817.

[7] CAI Yi, GUO Jinlu, TANG Zhenpeng. An EEMD-CNN-BiLSTM-attention neural network for mixed frequency stock return forecasting[J]. Journal of intelligent & fuzzy systems: applications in engineering and technology, 2022, 43(1): 1399-1415.

[8] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.

[9] DUBUC C, BOUDREAU D, PATENAUDE F, et al. An automatic modulation recognition algorithm for spectrum

- monitoring applications[C]//IEEE. 1999 IEEE International Conference on Communications. Vancouver: IEEE, 1999: 570-574.
- [10] MA Li, YAO Wenlong, DAI Xinguan, et al. A new evidence weight combination and probability allocation method in multi-sensor data fusion[J]. *Sensors*, 2023, 23(2): 722.
- [11] FAN Hangming, WANG Rui, HUO Yuchi, et al. Real-time monte carlo denoising with weight sharing kernel prediction network[J]. *Computer graphics forum*, 2021, 40(4): 15-27.
- [12] ABIDIN Z, DESTIAN W, UMER R. Combining support vector machine with radial basis function kernel and information gain for sentiment analysis of movie reviews[J]. *Journal of physics: conference series*, 2021, 1918(4): 042157.
- [13] NGUYEN H N, OHN S Y, CHOI W J. Combined kernel function for support vector machine and learning method based on evolutionary algorithm[C]//Springer. *Neural Information Processing*. Heidelberg: Springer, 2004: 1273-1278.
- [14] BHAVSAR H, GANATRA A. Increasing efficiency of support vector machine using the novel kernel function: combination of polynomial and radial basis function[J]. *International journal on advanced computer theory and engineering*, 2014, 3(5): 17-24.
- [15] LIU Jingwei. Protein function prediction based on kernel logistic regression with 2-order graphic neighbor information [EB/OL]. (2021-07-18) [2024-05-12]. <https://arxiv.org/abs/1207.4463>.
- [16] XU Chen, PENG Zhiming, JING Wenfeng. Sparse kernel logistic regression based on L1/2 regularization[J]. *Science China: information sciences*, 2013, 56(4): 1-16.

Research on fusion algorithm for service life prediction based on kernel functions

TANG Huan, LI Yizhu, LYU Peng

(CRRC Zhuzhou Institute Co., Ltd., Zhuzhou, Hunan 412001, China)

Abstract: Real-time service life prediction offers an effective means of assessing the remaining service life of operational control devices in rail transit systems. Currently, the primary methods employed for this purpose are based on physics-of-failure analysis and degradation data, respectively. Early in the lifecycle of these control devices, the lack of real-time degradation data makes the physics-of-failure-based methods more accurate. However, as these devices approach the end of their lifecycle, a large amount of degradation data accumulates, allowing the degradation-data-based methods to yield more precise predictions. This paper proposes a kernel function-based fusion algorithm for service life prediction that combines predictions from both methods to enhance accuracy in predictions throughout the entire lifecycle. Accelerated degradation experiments were conducted using an optical coupler on a core board of a rail transit control device to compare the results from the physics-of-failure-based method, the degradation-data-based method, and the proposed fusion algorithm. The results demonstrate that the fusion algorithm achieves higher prediction accuracy throughout the entire lifecycle compared with the other two methods.

Keywords: urban rail transit; real-time service life prediction; physics-of-failure; degradation data; kernel function