



DOI:10.12404/j.issn.1671-1815.2505697

引用格式:陈琳英,张艳琴,石慧,等.基于数字孪生与 ResTCN-BiGRU-Attention 模型的空心阴极剩余寿命预测[J].科学技术与工程,2026,26(26):11501-11513.

Chen Linying, Zhang Yanqin, Shi Hui, et al. Remaining useful life prediction of hollow cathodes based on digital twin and ResTCN-BiGRU-Attention model[J]. Science Technology and Engineering, 2026, 26(26): 11501-11513.

基于数字孪生与 ResTCN-BiGRU-Attention 模型的空心阴极剩余寿命预测

陈琳英¹, 张艳琴^{2*}, 石慧², 宋仁旺², 李婧³

(1. 太原科技大学应用科学学院, 太原 030024; 2. 太原科技大学电子信息工程学院, 太原 030024;
3. 兰州空间技术物理研究所, 兰州 730000)

摘 要 空心阴极作为离子推力器系统的核心部件,发挥着为离子推力器点火和维持放电的作用,其功能结构件在长期工作中也会逐渐损耗,进而引起推力器系统失效。为有效提高离子推进系统的可靠性并降低系统的失效风险,提出一种基于数字孪生辅助残差时序-双向门控注意力(ResTCN-BiGRU-Attention)的模型对六硼化镧(LaB₆)空心阴极进行剩余寿命预测。首先,分析空心阴极的工作机理,利用数字孪生技术构建仿真模型以获取模拟数据;随后,引入子域自适应机制,通过最小化仿真域与真实域间细粒度特征差异,实现残差纠正。最后,采用 ResTCN-BiGRU-Attention 模型预测空心阴极的剩余寿命。实验结果表明,所提模型在均方误差、均方根误差、平均绝对误差和决定系数 4 项指标上分别达到 0.055、0.234 7、0.151 4 和 0.987 38,展现了模型良好的预测精度和泛化能力,为长寿命空心阴极的设计提供了一定的参考依据。

关键词 LaB₆空心阴极;数字孪生;残差网络;寿命预测

中图分类号 V467;

文献标志码 A

Remaining Useful Life Prediction of Hollow Cathodes Based on Digital Twin and ResTCN-BiGRU-Attention Model

CHEN Lin-ying¹, ZHANG Yan-qin^{2*}, SHI Hui², SONG Ren-wang², LI Jing³

(1. College of Applied Science, Taiyuan University of Science and Technology, Taiyuan 030024, China; 2. College of Electronic Information Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China; 3. Lanzhou Institute of Physics, Lanzhou 730000, China)

[Abstract] The hollow cathode, as the core component of an ion thruster system, plays a critical role in ignition and sustaining discharge for the thruster. However, its functional structural components gradually degrade during prolonged operation, ultimately leading to system failure. In order to effectively enhance the reliability of ion propulsion systems and mitigate operational risks, a digital twin-assisted residual temporal convolutional network-bidirectional gated recurrent unit-attention (ResTCN-BiGRU-Attention) model was proposed for predicting RUL (remaining useful life) of lanthanum hexaboride (LaB₆) hollow cathodes. First, the working mechanism of hollow cathodes was analyzed, and a dynamic simulation model was constructed using digital twin technology to obtain simulated data. Then, a subdomain adaptation mechanism was introduced to achieve residual correction by minimizing the discrepancy of fine-grained features between the simulated and real domains. Finally, the ResTCN-BiGRU-Attention model was applied for the RUL prediction of hollow cathodes. The results demonstrate that the proposed model achieves superior performance in four evaluation metrics, with the mean squared error, root mean squared error, mean absolute error, and coefficient of determination reaching 0.055, 0.234 7, 0.151 4, and 0.987 38, respectively. It is concluded that the model exhibits excellent prediction accuracy and generalizability, providing a valuable reference for the design of long-life hollow cathodes.

[Keywords] LaB₆ hollow cathode; digital twin; residual network; remaining useful life prediction

离子推力器作为深空探测的重要动力系统,与传统化学推进相比,可大幅减少推进剂的携带量,增加有效载荷,延长航天器的在轨寿命,成为支撑

新一代卫星平台复杂深空探测姿态控制、位置保持、轨道机动及高精度科学任务的关键技术。

离子推力器主要由空心阴极、放电室、屏栅、加

收稿日期:2025-08-02; 修订日期:2026-02-28

基金项目:国防科工局重点实验室基金项目(HTKJ2023KL510007)

第一作者:陈琳英(1976—),女,汉族,河南商丘人,博士,副教授。研究方向:复杂装备系统的故障诊断和健康管理。E-mail:2007004@tyust.edu.cn。

* 通信作者:张艳琴(2001—),女,汉族,山西大同人,硕士研究生。研究方向:智能信息处理。E-mail:842677432@qq.com。

投稿网址:www.stae.com.cn

速栅和中和器构成。空心阴极作为离子推力器的电子源在长期运行过程中性能会逐步退化,直接影响着推力器的工作寿命。空心阴极的失效模式具有强非线性和多因素耦合的特征,包括发射体烧蚀、离子溅射、气体杂质中毒等,导致寿命试验周期长、成本高。因此,如果能在其性能退化初期进行剩余使用寿命(remaining useful life, RUL)预测评估,开发精确的RUL预测模型,可有效降低系统的运行风险和成本,提升整个系统的可靠性和经济性^[14],也是保障深空探测、星座组网等长寿命航天任务可持续发展的有效措施。

近年来,基于深度学习的方法凭借其强大的特征提取能力,在寿命预测领域获得了广泛关注^[5-6]。然而,这类方法通常要求数据分布是均衡的,这一特性限制了其在工业场景中的应用^[7]。以空心阴极的发射体为例,在正常工况下运行,失效发生频率低且持续时间短,导致传感器采集到的失效寿命数据远少于正常数据,形成数据不平衡问题。当使用这种不平衡数据训练寿命预测模型时,整体损失最小化迫使模型识别多数正常状态,而忽略少数失效状态特征。为解决这个问题,研究者们提出了一些非平衡寿命预测方法^[8]。如通过重采样、对抗网络、焦点损失、类平衡损失等方法生成平衡数据。

万宇等^[9]为了提升煤与瓦斯突出预测模型的稳定性,提出了过采样算法和支持向量机组合的分类预测模型,解决了小样本数量不均衡对模型训练的影响。孙佳佳等^[10]提出了一种基于生成对抗网络和深度神经网络相结合的入侵数据增强方法,解决样本集类别均衡问题。Liu等^[11]介绍了变分自动编码GAN(variational autoencoder generative adversarial network, VAE-GAN),将编码器集成到GAN中,以提高生成轴承数据的质量。Li等^[12]设计了一种改进的辅助分类器GAN(auxiliary classifier generative adversarial network, ACGAN)框架,可以利用随机噪声和标签信息生成多模态样本。然而,现有的基于GAN的方法仍存在明显不足:①训练过程不稳定易导致模型崩溃,且长时间的迭代过程导致训练难度高^[13];②少数类样本信息不足会导致生成数据包含干扰特征,导致生成的数据与真实数据存在较大差异^[14]。焦点损失(focal loss, FL)^[15]降低了易于分类的样本权重,使模型能够在训练期间专注于难以分类的少数类别样本;类平衡损失(class-balanced loss, CBL)^[16]基于有效样本数重新加权各类损失;动态加权平衡损失(dynamic weighted balanced loss, DWBL)^[17]则根据预测得分调整类权重。在预测与健康领域, Jia等^[18]将加权损失(weighted

loss, WL)纳入卷积神经网络,以解决不平衡数据的难题。He等^[19]采用动态惩罚因子解决类不平衡问题。Yu等^[20]设计了一个自适应损失函数,根据类别数量差异分配不同的权重,从而突出少数类别。但这类方法也存在一些局限性:①当数据严重不平衡时易过拟合少数类样本,导致分类边界不可靠^[21];②模型性能过度依赖少数类样本中嵌入的特征信息,影响算法泛化能力^[22]。

针对上述问题,现提出一种基于数字孪生协同ResTCN-BiGRU-Attention的预测方法。数字孪生技术构建空心阴极数字孪生仿真模型,生成仿真数据。应用通道注意力机制和软阈值函数的并行ResTCN模块,提取样本时间序列的局部特征;将提取到的局部特征再输入到多头注意力机制与前馈网络实现多传感数据融合;再利用注意力机制的BiGRU网络对融合特征进行全局特征提取,强化关键特征的表达与退化过程的建模能力。引入子域自适应机制,通过最小化仿真域与真实域间细粒度特征差异,实现残差纠正。以提升模型在不同域下的泛化能力和鲁棒性,为解决工业场景中数据分布不一致问题提供技术参考。

1 空心阴极失效机理分析

空心阴极是电推进系统的核心部件,起着点火、维持放电和中和离子流的作用^[23-26],工作过程如下^[27-29]:在离子发动机启动时,加热器内通入加热电流将空心阴极预热到适当温度,并向阴极管注入工质气体,提高管内压力。随后,对阴极施加点火电压,当气体流率达到阈值时,阴极气体被击穿,发射体和触发极之间形成稳定的自持弧光放电,阴极管内产生高密度的等离子体。空心阴极内部物理实体模型如图1所示。

空心阴极失效形式主要包括发射体、加热器、电极溅射和孔堵塞失效等^[30-31]。其中,发射体损耗是导致空心阴极失效的首要因素。若工作温度过高,发射体会因为过度蒸发,电子发射能力迅速衰退而失效;工作温度过低,发射体易中毒,其发射电流密度满足理查森-杜什曼方程(Richardson-Dushman)方程为

$$J_e = AT^2 \exp\left(-\frac{\varphi - \varphi_s}{kT}\right) \quad (1)$$

式(1)中: J_e 为发射电流密度, A/cm²; φ 为发射体材料的功函数,取2.66 eV; φ_s 为由肖特基效应引起的逸出功降低量,取0.05 eV; T 为发射体加热温度, K; A 为发射体常数,取90 A/(cm²·K²); k 为玻尔兹曼常数,取 1.38×10^{-23} J/K。

LaB₆发射体的蒸发率可表示为

$$V = a \exp\left(-\frac{b}{R_1 T}\right) \quad (2)$$

式(2)中: V 为发射体蒸发速率, $\mu\text{m}/\text{h}$; a 、 b 均为常数,分别取 $4 \times 10^{14} \mu\text{m}/\text{h}$, $570 \times 10^3 \text{ J}/\text{mol}$; R_1 为气体常数,取 $8.314 \text{ J}/(\text{mol} \cdot \text{K})$ 。

对式(1)和式(2)进行处理,得出发射体蒸发速率 V_1 与发射体表面发射电流密度 J_e 的关系表达式为

$$V_1 = D \exp(BJ_e) + C \quad (3)$$

式(3)中: V_1 为发射体蒸发速率, $\mu\text{m}/\text{kh}$; D 、 B 、 C 为拟合的常数,分别取 $66.26 \mu\text{m}/\text{kh}$, $0.02477 \text{ cm}^2/\text{A}$, $-88.66 \mu\text{m}/\text{kh}$ 。

由式(1)~式(3)可推出发射体寿命为

$$t = \frac{R - r}{V_1} \quad (4)$$

式(4)中: R 、 r 分别为发射体的外径和内径。




图1 空心阴极内部物理实体模型图

Fig. 1 Physical entity model of the internal hollow cathode

2 数字孪生模型构建

数字孪生是基于真实设备的几何、物理、行为和规则等模型生成高保真模拟数据^[32-34],以物理实体组件传感器采集的温度、尺寸等实测信号为基础,经预处理后结合理查森-杜什曼方程等物理规律,计算得到发射体尺寸、功函数等高保真关键参数;虚拟模型基于这些参数构建几何与物理特性仿真系统,生成初始仿真信号,再通过更新模型迭代调整参数,最大化与实测信号的近似度,产出全生命周期退化参数时序数据,为模型训练提供时序样本。

2.1 物理实体模型(PE)

电推进系统空心阴极的物理实体模型参数配置如下:发射体材料由 LaB₆制成,长度为 9 mm,材料功函数为 2.66 eV,触持极孔径 3 mm,距阴极孔 1 mm,阴极孔直径 0.3 mm。

2.2 虚拟设备模型(VE)

虚拟环境集成物理实体的多种变量、尺度与能力,在虚拟空间中构建其几何形状(G_v)、物理特性

(P_v)、行为模型(B_v)及规则模型(R_v),即 $VE = (G_v, P_v, B_v, R_v)$ 。

G_v 通常为二维实体模型。 P_v 模拟实体的物理属性(如发射体尺寸变化、温度分布及功函数变换等),可借助 ANSYS 等有限元仿真软件实现建模;严格按照物理实体模型(PE)的实测参数(发射体长度 9 mm、触持极孔径 3 mm、阴极孔直径 0.3 mm 等),构建 1:1 几何模型,然后采用自适应四面体结构对发射体进行网格划分,通过仿真软件的参数化语言编程,将发射体退化规律嵌入仿真过程中,假设发射体外径衰减至 0.05 mm 时仿真终止,记录全生命周期的退化时序数据。当虚拟仿真结果与物理实测数据的偏差大于 5% 时,通过 CN_VS 连接调整虚拟模型的参数,实现校准。

B_v 描述在驱动因素(如加热发射体至点火温度、维持稳定的放电电流)或干扰因素(如材料嵌入、环境暴露)作用下的行为响应。 R_v 包含约束、关联和推断规则,使虚拟模型具备判断、评估、优化和预测功能。通过 VE 、 G_v 、 P_v 、 B_v 和 R_v 在功能和结构上耦合,形成 PE 的完整镜像。

2.3 服务模式(Ss)数据模型(DD)连接模型(CN)

S_s 包括物理实体(PE)和虚拟设备(VE)服务。通过在虚拟环境运行中校准参数,优化虚拟环境参数以保证其高度保真度与性能。

DD 包含 5 部分: $DD = (D_p, D_v, D_s, D_k, D_f)$ 。分别表示来自 PE、VE、 S_s 、领域知识的数据, D_f 表示 D_p 、 D_v 、 D_s 和 D_k 的融合数据。DD 整合物理与虚拟数据及其融合,极大丰富了数据集。

CN 通过 TCP/IP 等标准化协议和物联网、以太网等技术,搭配 JDBC 等专用接口,实现各模型之间的联动^[35-36],是虚拟实体与物理实体保持同步的关键。其中包括 6 部分: $CN = (CN_SD, CN_PD, CN_VD, CN_PS, CN_VS, CN_PV)$ 。其中 CN_SD 、 CN_PD 、 CN_VD 、 CN_PS 、 CN_VS 和 CN_PV 分别表示 S_s 和 DD、PE 和 DD、VE 和 DD、PE 和 S_s 、VE 和 S_s 、PE 和 VE 之间的连接。


应用所建立的空心阴极 DT 模型 $M_{DT} = (PE, VE, S_s, DD, CN)$ 创建 DT 驱动的 PHM 方法。图 2 所示为数字孪生驱动的 PHM 方法流程图。

步骤 1 DT 建模和校准。根据建立空心阴极的 DT,消除 PE 和 VE 偏差。

步骤 2 模型仿真和交互作用。

步骤 3 一致性的判断。当 PE 和 VE 之间的相对误差不超过 10% 时,判定二者一致,进入步骤 4;反之,不一致,进入步骤 5。

步骤 4 退化检测。随着 PE 的运行,性能会出



P_a 为物理实体实际监测值; P_e 为数字孪生模型预测值

图2 数字孪生驱动的PHM流程图

Fig. 2 Flowchart of digital twin-driven PHM

现下降,这将响应在孪生设备上,当部分指标超过阈值,说明PE已退化,随着退化的积累,空心阴极会发生失效,然后进入步骤6;否则,返回步骤2。

步骤5 对不一致进行判断。以相同条件下PE的历史状态时间序列为参考,判断是否由PE或VE引起不一致。若只有PE收集的状态与参考相似,则不一致由模型缺陷引起,然后转到步骤1;若只有VE输出的模拟状态与参考相似,则不一致由PE的突然故障和VE未知的突然干扰引起,然后转到步骤6。

步骤6 故障原因的识别和预测。

步骤7 根据预测结果,提出维修策略。

3 LaB₆空心阴极剩余寿命预测框架

3.1 时间卷积残差网络

传统的残差网络通过卷积块提取特征,其感受野有限,难以有效建模长时间序列依赖关系。因此,引入TCN模块通过扩张因果卷积扩大感受野高效捕捉长时依赖关系;并引入残差连接机制,实现跨层跳跃连接,有效缓解了梯度消失和爆炸问题,降低训练难度同时支持构建更深的网络。

向网络中输入多源序列 x , 包含多个数据特征可表示为: $x = [\varphi, \varphi_s, T, R, r] \in \mathbf{R}^{t \times 5}$ 。故TCN与残差连接的表达式为

$$z = \text{GELU}[\text{Conv}_{1 \times 1}(x) + F(x)] \quad (5)$$

$$F(x) = \sigma \{ w_3 \sigma [w_2 \sigma (w_1 x + b_1) + b_2] + b_3 \} \quad (6)$$

式中: $F(x)$ 为TCN网络的输出; σ 为GELU函数; w_1, w_2, w_3 为时间卷积核权重; b_1, b_2, b_3 为偏置项。

在此基础上,引入通道注意力机制和软阈值函数,用注意力机制中每个特征通道的软阈值替换传统非线性层,使网络能自动聚焦关键特征,提升时序数据在时间卷积残差模型上的特征学习能力,如图3中ResTCN部分所示。

3.2 特征融合


该模块用于多传感特征融合(如图3特征融合部分),是将ResTCN网络输出输入至此。首先,一维卷积用于提取局部空间交互;其次,多头注意力捕捉传感器之间的全局相关性。通过残差连接将原始特征和多头注意力输出的结果输入至前馈网络中进一步优化,有效融合不同传感器的特征。

ResTCN输出的特征序列 $z \in \mathbf{R}^{T \times C_{in}}$ 通过多头注意力得到

$$\text{Attention}(Q_z, K_z, V_z) = \text{softmax} \left(\frac{Q_z K_z^T}{\sqrt{d_k}} \right) V_z \quad (7)$$

式(7)中: Q_z, K_z, V_z 分别为查询、键和值矩阵; d_k 为每个键向量的维度; softmax 为归一化函数。

将这3个矩阵分成多个头,每个头均执行缩放点积注意力运算。再将所有头的输出加和,形成长向量,表达式为



X_{t-1} 、 X_t 、 X_{t+1} 分别为输入序列中第 $t-1$ 、 t 、 $t+1$ 个时刻的输入向量; X_T 为输入序列中第 T 个时刻 (即序列最后一个时刻) 的输入向量; h_{t-1} 、 h_t 、 h_{t+1} 分别为第 $t-1$ 、 t 、 $t+1$ 个时刻的隐藏状态向量; h_T 为第 T 个时刻的最终隐藏状态向量; Y_{t-1} 、 Y_t 、 Y_{t+1} 分别为第 $t-1$ 、 t 、 $t+1$ 个时刻的输出向量; Y_T 为第 T 个时刻的最终输出向量

图3 特征提取部分内部结构图

Fig. 3 Internal structure diagram of the feature extraction part

$$\text{MultiHead}(H) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_H)$$

$$(8)$$

$$\text{head}_H = \text{Attention}(Q_z, K_z, V_z) \in \mathbf{R}^{T \times d_k}$$

$$(9)$$

然后,对拼接后的向量进行线性变换,以整合来自不同头的信息,注意力操作后再通过残差连接和层归一化,即

$$x_{\text{attn}} = \text{LayerNorm}[x + \text{Attention}(z_1, z_2, \dots, z_H)]$$

$$(10)$$

式(10)中: $\text{Attention}(z_1, z_2, \dots, z_H)$ 为多头注意力的输出。

残差连接 $x + \text{Attention}(z_1, z_2, \dots, z_H)$ 后通过 LayerNorm 归一化得到最终输出 x_{attn} 这确保了全局信息的有效捕捉和梯度的稳定传递。

前馈神经网络使用两层线性层、GELU 激活函数以及 dropout 进行正则化,再使用残差连接与层归一化,即

$$\text{FFN}(x) = W_2[\text{GELU}(W_1 x_{\text{attn}})]$$

$$(11)$$

$$x_{\text{output}} = \text{LayerNorm}[x + \text{FFN}(x)]$$

$$(12)$$

式中: W_1 为第一个线性变换的权重矩阵,该矩阵将输入特征从原始的嵌入维度映射到更高的隐藏维度; W_2 为第二个线性变换的权重矩阵,它将经过 GELU 激活后的隐藏状态表示重新映射回原始的嵌入维度,从而使得输出与输入维度上保持一致。

将 FFN 的输出与注意力原始输入相加得 $x + \text{FFN}(x)$,形成残差结构,并通过 LayerNorm 归一化得到最终的输出结果 x_{output} ,这增强了模型的表达能力和非线性建模能力。

3.3 双向门控循环网络

门控循环单元(gated recurrent unit, GRU)是循环神经网络(recurrent neural network, RNN)的变体,相比 RNN 和长短期记忆网络(long short-term memory, LSTM)更简洁且参数更少。双向门控循环单元(bidirectional gated recurrent unit, BiGRU)引入了双向结构,更好地捕捉时间序列的双向依赖关系。当前隐藏状态由前向和后向的输出及当前时刻的输入共同决定。如图 3 中的 BiGRU + Attention 部分所示,该模块在 BiGRU 的基础上加入了通道注意力机制,聚焦关键信息建模。

BiGRU 模块的公式为

$$\vec{h}_t = \text{GRU}(\vec{h}_{t-1}, x_{\text{output}}^t) \quad (13)$$

$$\tilde{h}_t = \text{GRU}(\tilde{h}_{t+1}, x_{\text{output}}^t) \quad (14)$$

式中: $\vec{h}_t$ 为从左到右的隐藏状态; $\tilde{h}_t$ 为从右到左的隐藏状态; x_{output}^t 为输入序列中第 t 个元素; $\vec{h}_{t-1}$ 为向前传播隐藏状态的输出结果; $\tilde{h}_{t+1}$ 为向后传播的输出结果。

随后将两个方向的隐藏状态拼接在一起,得到最终的隐藏状态 h_t 。

$$h_t = [\vec{h}_t; \tilde{h}_t] \quad (15)$$

式(15)中: $[\cdot; \cdot]$ 为向量的拼接操作。

最后,将隐藏状态 h_t 传递给全连接层得到输出 y_t 。

$$y_t = \text{softmax}(Wh_t + b) \quad (16)$$

式(16)中: W 为在 t 时刻信息前向和后向传播隐藏层输出的权重; b 为 t 时刻 BiGRU 隐藏状态所对应的偏置; y_t 为最终的输出。

3.4 子域自适应机制

子域自适应是域自适应的一个细粒度分支,如图 4 所示。其核心思想是:在源域和目标域整体分布对齐的基础上,进一步对同一类别对应的子域进行条件分布对齐,从而减少同类样本在不同域之间的分布差异。把源域和目标域分别拆成 c 个子域,对每个子域对计算局部最大平均差异(local maximum mean discrepancy, LMMD),LMMD 表达式为

$$L_H(P_c, Q_c) = E_c \|\psi(x^s) - \psi(x^t)\|_H^2 \quad (17)$$

式(17)中: H 为再生核希尔伯特空间; x^s 和 x^t 分别为来自源域和目标域的样本,二者遵循概率分布 P 和 Q ; $E[\cdot]$ 为数学期望的运算; $E_{P_c}[\psi(x^s)]$ 为对源域样本经特征映射后的特征值求期望; $E_{Q_c}[\psi(x^t)]$ 为对目标域样本经特征映射后的特征值求期望; $\psi(\cdot)$ 为数据特征映射过程; P_c 和 Q_c 分别为仿真域和真实域中数据类别 c 的概率分布。

如果每个寿命样本都属于类别 c ,则其权重可表示为 w^c ,则 $L_H(P_c, Q_c)$ 的经验估计可以表示为

$$L_H(P_c, Q_c) = \frac{1}{C} \sum_{c=1}^C \left\| \sum_{i=1}^{n_s} w_i^{sc} \psi(x_i^s) - \sum_{j=1}^{n_t} w_j^{tc} \psi(x_j^t) \right\|_H^2 \quad (18)$$

式(18)中: n_s 为源域中寿命样本数; n_t 为目标域中寿命样本数; w^{sc} 为源域样本的相似度; w^{tc} 为目标域样本的相似度,且满足源域和目标域中所有权重和为 1。

$$\begin{cases} \sum_{i=1}^{n_s} w_i^{sc} = 1 \\ \sum_{j=1}^{n_t} w_j^{tc} = 1 \end{cases} \quad (19)$$

在源域和目标域中每个样本 x_i 对应的权重定义为

$$w_i^c = \frac{y_i^c}{\sum_{i=1}^n y_i^c} \quad (20)$$

式(20)中: y_i^c 为第 i 个样本 x_i 在类别 c 下的某种原始度量值。

若特征提取器表示为 $G_f(\cdot)$, SAM 定义为

$$\begin{aligned} \hat{L}_H(P_c, Q_c) = \frac{1}{C} \sum_{c=1}^C \left\{ \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} w_i^{sc} w_j^{tc} k[G_f(x_i^s), G_f(x_j^t)] + \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} w_i^{tc} w_j^{tc} k[G_f(x_i^t), G_f(x_j^t)] - 2 \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} w_i^{sc} w_j^{tc} k[G_f(x_i^s), G_f(x_j^t)] \right\} \end{aligned} \quad (21)$$

式(21)中: $G_f(\cdot)$ 为特征提取器; $k(\cdot)$ 为核函数,计算样本间的相似度; C 为相似度计算参数,控制特征空间中样本间相似度的度量方式。

通过整合所提出的方法细节,提出 LaB₀ 空心阴极剩余寿命预测框架如图 5 所示,过程如下。

(1)数据预处理。对所得的样本数据进行降噪处理并利用最大最小值归一化为 $[0, 1]$ 。

(2)特征提取模块。将空心阴极的数据并行输




图 4 子域自适应机制

Fig. 4 Sub-domain adaptive mechanism




图 5 数字孪生协同ResTCN-BiGRU-Attention模型对LaB₆空心阴极寿命预测框架
Fig.5 The digital twin-enabled ResTCN-BiGRU-Attention model for the prediction framework of LaB₆ hollow cathode life

入到融合通道注意力机制的 ResTCN 网络提取样本局部时序特征;随后,引入多头注意力机制和前馈网络实现多传感数据融合;最后,将融合后的特征输入到结合注意力机制 BiGRU 网络中进行全局特征提取,强化关键特征的表达能力。

(3)残差纠正。将仿真域和真实域提取的特征输入等式(21),纠正域间残差。当残差损失函数达到极小值时,表明模型预测结果可信度高;反之,需要重新进行特征提取和残差纠正。迭代过程中,选择训练损失最小的模型作为最终的最优模型。

(4)模型评估。采用均方误差(mean squared error,MSE)、均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)和决定系数(R^2)评价模型性能,并与其他预测模型对比分析,验证所提模型在空心阴极寿命预测中的有效性与优越性。

4 实验验证及结果分析

使用仿真实验数据来验证所提模型的有效性和准确性。根据设定的工作参数,与兰州空间技术物理研究所研制的 LaB₆空心阴极工作寿命相比,验证模型的可行性和优越性。

4.1 数据集描述

空心阴极发射体的少量寿命数据是通过传感器采集得到的,该数据集所包含的退化变量分别为发射体材料的功函数 φ 、由肖特基效应引起的逸出功降低量 φ_s 、发射体加热温度 T 、发射体外径 R 和内径 r ,但由于真实数据稀缺,因此,根据文献[3]以及式(1)~式(4)进行计算仿真,得到符合空心阴极物理退化规律的 2 000 个样本数据。在数据参数的不确定范围内,通过建立数字孪生模型生成 5 000 个仿真样本数据,为确保样本分布的可靠性,所有仿真样本均通过物理实体实测数据进行校准,仿真与实测数据的相对误差 $\leq 5\%$,共同构成空心阴极的数据集。参数不确定度范围如表 1 所示。所设定的工作参数包含发射体电流 5 A、氙气流率为 0.1 mg/s、发射体长度为 9 mm。其中由于发射体温度数据监测难度大,结合文献[3]中发射体轴向温度测量结果与等离子体密度对应的温度分布规律,对发射体温度分布进行如下设定:将发射体按距下游顶端距离划分为 4 部分(0~1 mm、1~2 mm、2~3 mm 及剩余部分),各部分顶端与末端的温度差值分别设定为 30、15、10、5 K,且每部分内温度沿轴向均匀下降,发射体从下游顶端至上游总温降为 60 K。计算过程中,对发射体沿轴向进行微分处理,各微分单元温度依次递减,对应发射电流同步降低,对每个

微分单元提供的发射电流进行累计,用额定发射电流这一条件进行约束。

根据文献[4],将实验中空心阴极的最大寿命值设定为 52 kh。在数据预处理过程中,采用滑动窗口均值滤波对原始数据进行降噪处理,然后采用 max-min 值归一化为[0,1]。在第 3 节提出的剩余寿命预测框架 ResTCN-BiGRU-Attention 神经网络模型中,先将数据并行输入到融合通道注意力机制的 ResTCN 网络提取样本局部时序特征;再引入多头注意力机制和前馈网络实现多传感数据融合;然后,将融合后的特征输入到结合注意力机制 BiGRU 网络中进行全局特征提取,最后输出寿命预测结果。其学习率为 0.001,批次大小为 64,训练轮数为 500,优化器为 Adam,将 7 000 个训练样本按照 7:3 的比例划分为训练集和验证集。

表 1 寿命模型中输入参数

Table 1 Input parameters of the life expectancy model

输入参数	额定值	不确定度
φ/eV	2.66	± 0.01
φ_s/eV	0.05	± 0.0025
T/K	1 923	± 20
R/mm	4.5	± 0.1
r/mm	1.5	± 0.1

4.2 评价指标

为了验证所提模型的性能,采用以下 4 个用于度量统计学上的剩余使用寿命(remaining useful life,RUL)预测的评价指标。

(1)均方误差(MSE)是预测值与真实值之间差值平方的平均数。

$$\text{MSE} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (22)$$

式(22)中: $\hat{y}_i$ 为每个时间步长的 RUL 预测值; y_i 为 RUL 真实值。

(2)均方根误差(RMSE)是 MSE 的平方根。

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (23)$$

(3)平均绝对误差(MAE)是预测值与真实值之间绝对误差的平均值。

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |\hat{y}_i - y_i| \quad (24)$$

(4)决定系数(R^2)表示模型对目标变量差异的解释能力,值域为[0,1]。

$$R^2 = 1 - \frac{\sum_{i=1}^m (\hat{y}_i - y_i)^2}{\sum_{i=1}^m (\bar{y}_i - y_i)^2} \quad (25)$$

式(25)中: $\bar{y}_i$ 为 RUL 真实值的均值。

4.3 试验结果分析

4.3.1 RUL 预测结果及分析

在数据量有限的情况下,为尽可能真实地模拟实验中 RUL 预测过程,该实验将测试集结果划分为 52 个循环周期,并取各周期结果的平均值作为该周期的 RUL 值。假设剩余寿命降至约 15 kh 时,空心阴极处于失效状态。为了验证所提模型优势,选取 CNN、ResNet、LSTM、BiLSTM、GRU、BiGRU、ResTCN-LSTM-Attention、ResTCN-BiLSTM-Attention、ResTCN-GRU-Attention 作为对比模型,各模型具体参数如表 2 所示。

图 6 所示为不同模型在同一数据集上的 RUL 预测结果。对比分析表明:CNN、LSTM、BiLSTM、GRU、BiGRU 模型因采用传统的卷积时序模型对多元特征捕捉不足且建模能力有限,导致在循环早期或中期与真实衰减趋势存在较大偏差,ResTCN-LSTM-Attention、ResTCN-BiLSTM-Attention、ResTCN-GRU-Attention 因计算量大,梯度不稳定,影响长期依赖建模效果。所提方法通过“局部特征-数据融合-全局建模”的分层设计,既精准捕捉细粒度退化细节,又有效建模长时序依赖关系,融合通道注意力机制可增强对关键退化特征的权重分配,增加模型的鲁棒性。本文模型预测的全寿命周期约为 52 kh,0~15 kh 为健康阶段,从 15 kh 开始退化,到约 52 kh 失效,符合最大寿命设定值,验证了该模型的有效性。

如表 3、图 7 和图 8 所示,本文模型相较于其他模型实现了低 MSE、RMSE、MAE,高 R^2 的效果。分析如下:所提 ResTCN-BiGRU-Attention 模型 MSE 仅为次优模型 ResTCN-BiLSTM-Attention 的 1/6, RMSE 降低约 51.6%,MAE 降低约 77%,证明引入 BiGRU 和 Attention 机制显著提升了模型对长期依

赖和关键退化阶段的捕捉能力, $R^2=0.987\ 38$,接近 1,说明注意力机制通过动态聚焦退化关键阶段(如末期 RUL 快速下降区间),显著提升了模型对复杂退化模式的适应性。

4.3.2 消融实验结果及分析

第 3 节提出的 ResTCN-BiGRU-Attention 神经网络模型中,ResTCN 模块凭借并行残差时间卷积与通道注意力机制的融合,可有效提取数据局部时序特征,为后续 BiGRU 的全局特征建模奠定基础;引入注意力机制则能自适应聚焦并融合关键特征,从而实现高精度剩余寿命预测。为验证 ResTCN、BiGRU、注意力机制核心组件的影响,在 LaB₆ 空心阴极数据集上进行了迭代周期为 500 次的消融实验。


由表 4 和图 9 可见:ResTCN 模块通过其扩张因果卷积和残差连接结构,精于捕获时间序列中的多尺度局部依赖关系。仅使用 ResTCN 模型预测时,其 MSE 为 0.127 4,相较于基线模型 ResNet18 (MSE=1.108 3)性能显著提升约 84%,这一结果证明在空心阴极寿命预测任务中,ResTCN 能有效提

表 3 不同模型预测性能对比

Table 3 Comparison of prediction performance among different models				
模型	MSE	RMSE	MAE	R^2
CNN	1.669 2	1.623 8	1.091 6	0.786 4
ResNet	0.563 3	0.750 5	0.643 5	0.924 1
LSTM	1.144 7	1.159 6	0.914 9	0.795 2
BiLSTM	0.983 9	0.991 9	0.855 9	0.886 7
GRU	1.033 1	1.016 4	0.829 7	0.857 6
BiGRU	0.646 6	0.804 1	0.650 0	0.889 8
ResTCN-LSTM-Attention	0.841 9	0.917 6	0.751 2	0.914 7
ResTCN-BiLSTM-Attention	0.335 6	0.479 3	0.419 0	0.937 2
ResTCN-GRU-Attention	0.465 8	0.682 5	0.587 2	0.925 6
本文模型	0.055 09	0.234 71	0.151 41	0.987 38

表 2 各模型参数配置

Table 2 Configuration of model parameters	
模型	参数
本文模型	3 层 TCN 残差块,卷积核大小 $K=3$,膨胀系数 $d_1=1, d_2=2, d_3=4$,采用 GELU 激活函数;特征融合块:1D 卷积($K=3$) + 多头自注意力(头数:2;嵌入维度:16) + FFN(隐藏层:64;GELU 激活);BiGRU + 通道注意力模块(输入层:16;隐藏层:16),通道注意力(通道数 16、降维系数 4)
CNN	2 层卷积网络, $K=3$
ResNet	3 个串联残差块,每个残差块含有两层 64 维线性层,激活函数 ReLU
LSTM	1 层 LSTM 网络,隐藏层 50
BiLSTM	1 层 BiLSTM 网络(隐藏层:50),双向传播(输出维度 100)
BiGRU	1 层 BiGRU 网络(隐藏层:64;激活函数:GELU)
ResTCN-LSTM-Attention	TCN 残差块($K=3$;残差连接 + 通道注意力(通道数 16、降维系数 4));特征融合模块:多头自注意力(头数:2;嵌入维度:16);LSTM + 注意力模块(输入层:16;隐藏层:16)
ResTCN-BiLSTM-Attention	传感器分支和特征融合模块同 ResTCN-LSTM-Attention;BiLSTM + 注意力模块(输入层:16;隐藏层:16),双向传播(输出维度 32),通道注意力(通道数 32、降维系数 4)
ResTCN-GRU-Attention	传感器分支和特征融合模块同 ResTCN-LSTM-Attention;GRU + 注意力模块:(输入层:16;隐藏层:16),通道注意力(通道数 16、降维系数 4)

图6 各模型对LaB₆发射体剩余寿命可视化图Fig. 6 The visualization of the remaining life of the LaB₆ emitter by various models

取具有判别性的局部退化特征,其并行多尺度卷积与通道注意力机制的结合,更能精准捕捉不同时间维度下的退化模式,为后续全局特征提取奠定基础。

BiGRU 模块专注于长时间序列的全局建模。实验验证,ResNet18-BiGRU 模型的 MSE (0.879 8)

比 ResNet 提升约 20.6%,表明 BiGRU 可增强模型的全局建模能力。而当 BiGRU 与局部特征提取器 ResTCN 结合时,模型 MSE(0.120 6)相较于单独使用 ResTCN 模型(0.127 4)提升约 5.34%,这说明 BiGRU 能够对 ResTCN 提取的局部特征建立依赖关




图 7 各模型 MSE、RMSE 和 MAE 对比
Fig. 7 Comparison of MSE, RMSE and MAE among different models




图 8 各模型的 R^2 对比
Fig. 8 Comparison of R^2 among different models

系,进而高效提取全局特征。

在 ResTCN 提取局部特征的基础上引入通道注意力机制 ($MSE = 0.2111$) 相比 ResTCN 单独作用时性能提升约 65.7%,这是因为通道注意力机制为不同时间步长和传感器通道特征自适应分配权重,使模型聚焦于对剩余寿命预测重要的关键特征。将通道注意力机制与 ResTCN、BiGRU 模块相结合,构成的所提模型取得了所有消融模型中的最优性能 ($MSE = 0.1167, R^2 = 0.9848$),充分彰显了该模型在空心阴极剩余寿命预测任务中的优越性。

表4 空心阴极发射体数据集上消融实验结果
Table 4 Ablation experiment results on the hollow cathode emitter dataset

模型	MSE	RMSE	MAE	R^2
ResNet18	1.108 3	1.052 8	0.939 6	0.893 2
ResNet18-BiGRU	0.879 8	0.938 0	0.845 1	0.926 7
ResNet18-Attention	0.958 1	0.978 8	0.733 7	0.939 2
ResNet18-BiGRU-Attention	0.385 6	0.359 0	0.376 5	0.954 3
ResTCN	0.127 4	0.356 9	0.276 2	0.968 7
ResTCN-BiGRU	0.120 6	0.325 0	0.273 6	0.969 4
ResTCN-Attention	0.211 1	0.459 4	0.343 1	0.957 8
本文模型	0.116 7	0.245 8	0.266 3	0.984 8




图9 各模型评价指标对比

Fig. 9 Comparison of evaluation metrics among different models

5 结论

为准确的估计空心阴极的剩余寿命,提出了一种基于数字孪生协同 ResTCN-BiGRU-Attention 的方法,得到以下结论。

(1)针对离子推力器空心阴极实际运行数据不足的问题,利用数字孪生技术构建仿真模型,生成仿真数据,缓解数据稀缺问题。

(2)为克服传统方法在特征提取、残差纠正和建模能力上的不足,提出子域自适应机制和 ResTCN-BiGRU-Attention 模型。该模型首先利用通道注意力机制的并行 ResTCN 网络提取时间序列中的局部特征;接着,引入多头注意力机制和前馈网络实现多传感数据的融合;然后,结合注意力机制的 BiGRU 网络对融合后的数据进行全局建模;最后,通过子域自适应机制对两域的特征进行残差纠正与反馈,以提升寿命预测的准确性与鲁棒性。

(3)将所提模型与 ResNet、ResTCN-GRU-Atten-

tion、ResTCN-LSTM-Attention 及 ResTCN-BiLSTM-Attention 等模型进行对比,实验结果表明,所提模型 MSE、RMSE、MAE 和 R^2 分别为 0.055、0.234 7、0.151 4 和 0.987 38,验证其在空心阴极寿命预测任务中的有效性与优势。

参 考 文 献

- [1] 张天平,张雪儿. 离子电推进的航天器应用实践及启示[J]. 真空与低温, 2019, 25(2): 73-81.
Zhang Tianping, Zhang Xue'er. Application practices and realizations of the ion electric propulsion on spacecraft[J]. Vacuum and Cryogenics, 2019, 25(2): 73-81.
- [2] 张天平,唐福俊,田华兵. 国外电推进系统空心阴极技术[J]. 上海航天, 2008(1): 39-46.
Zhang Tianping, Tang Fujun, Tian Huabing. Foreign technique status of hollow cathode for electric propulsion[J]. Aerospace Shanghai, 2008(1): 39-46.
- [3] 李璇,张天平,张雪儿. LaB₆空心阴极发射体失效的工作寿命预测及可靠性定量评估[J]. 真空与低温, 2023, 29(4): 392-398.
Li Xuan, Zhang Tianping, Zhang Xue'er. Operational life prediction and quantitative reliability evaluation of LaB₆ hollow cathode emitter failure[J]. Vacuum and Cryogenics, 2023, 29(4): 392-398.
- [4] 郭宁,江豪成,顾佐. 离子发动机空心阴极寿命预测[J]. 真空, 2009, 46(4): 83-85.
Guo Ning, Jiang Haocheng, Gu Zuo. Life prediction of hollow cathode in ion thruster[J]. Vacuum, 2009, 46(4): 83-85.
- [5] Wang W, Lei Y, Yan T, et al. Residual convolution long short-term memory network for machines remaining useful life prediction and uncertainty quantification[J]. Journal of Dynamics, Monitoring and Diagnostics, 2022, 1(1): 2-8.
- [6] Lin J, Shao H D, Zhou X D, et al. Generalized MAML for few-shot cross-domain fault diagnosis of bearing driven by heterogeneous signals[J]. Expert Systems with Applications, 2023, 230: 120696.
- [7] Chen X, Shao H, Xiao Y, et al. Collaborative fault diagnosis of rotating machinery via dual adversarial guided unsupervised multi-domain adaptation network[J]. Mechanical Systems and Signal Processing, 2023, 198: 110427.
- [8] Ren Z, Lin T, Feng K, et al. A systematic review on imbalanced learning methods in intelligent fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-35.
- [9] 万字,齐金平,张儒,等. 基于过采样支持向量机的煤与瓦斯突出预测[J]. 科学技术与工程, 2021, 21(28): 12080-12087.
Wan Yu, Qi Jinping, Zhang Ru, et al. Research on prediction of coal and gas outburst based on over-sampling SVM[J]. Science Technology and Engineering, 2021, 21(28): 12080-12087.
- [10] 孙佳佳,李承礼,常德显,等. 基于生成对抗网络的入侵检测类别不平衡问题数据增强方法[J]. 科学技术与工程, 2022, 22(18): 7965-7971.
Sun Jiajia, Li Chengli, Chang Dexian, et al. A data augmentation method for intrusion detection imbalance problem using generative adversarial networks[J]. Science Technology and Engineering, 2022, 22(18): 7965-7971.

- [11] Liu S W, Jiang H K, et al. Rolling bearing fault diagnosis using variational autoencoding generative adversarial networks with deep regret analysis[J]. Measurement, 2021, 168: 108371.
- [12] Li W, Zhang X, Shao H D, et al. Multi-mode data augmentation and fault diagnosis of rotating machinery using modified ACGAN designed with new framework[J]. Advanced Engineering Informatics, 2022, 52: 101552.
- [13] Zhao X L, Yao J Y, Deng W X, et al. Normalized conditional variational auto-encoder with adaptive focal loss for imbalanced fault diagnosis of bearing-rotor system[J]. Mechanical Systems and Signal Processing, 2022, 170: 108826.
- [14] Peng Y Z, Wang Y, Shao Y M. A novel bearing imbalance Fault-diagnosis method based on a Wasserstein conditional generative adversarial network[J]. Measurement, 2022, 192: 110924.
- [15] Lin Z Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017(99): 2999-3007.
- [16] Luo J Q, Xu S X, Wang H Y, et al. Improving GBDT performance on imbalanced datasets: an empirical study of class-balanced loss functions[J]. Neurocomputing, 2025, 634: 129896.
- [17] Fernando K, Tsokos C. Dynamically weighted balanced loss: class imbalanced learning and confidence calibration of deep neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(7): 2940-2951.
- [18] Jia F, Lei Y G, Lin J, et al. Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization[J]. Mechanical Systems and Signal Processing, 2018, 110: 349-367.
- [19] He Z Y, Shao H D, et al. Support tensor machine with dynamic penalty factors and its application to the fault diagnosis of rotating machinery with unbalanced data[J]. Mechanical Systems and Signal Processing, 2020, 141: 106441.
- [20] Yu Y X, Wang H, Li Y, et al. Pareto-optimal adaptive loss residual shrinkage network for imbalanced fault diagnostics of machines[J]. IEEE Transactions on Industrial Informatics, 2022, 18(4): 2233-2243.
- [21] Ren Z J, Zhu Y S, Liu Z L, et al. Adaptive cost-sensitive learning: improving the convergence of intelligent diagnosis models under imbalanced data[J]. Knowledge-Based Systems, 2022, 241: 108-296.
- [22] Liu H, Liu Z Y, Jia W Q, et al. A novel imbalanced data classification method based on weakly supervised learning for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2022, 18(3): 1583-1593.
- [23] 谢侃, 衣晓龙, 梁福文, 等. 空心阴极与霍尔推力器放电振荡关系实验研究[J]. 固体火箭技术, 2022, 45(3): 484-490.
- Xie Kan, Yi Xiaolong, Liang Fuwen, et al. Experimental investigation on relationship between hollow cathode and discharge oscillation in hall thruster[J]. Journal of Solid Rocket Technology, 2022, 45(3): 484-490.
- [24] 孙明明, 顾佐, 郭宁, 等. 离子推力器空心阴极热特性模拟分析[J]. 强激光与粒子束, 2010, 22(5): 1149-1152.
- Sun Mingming, Gu Zuo, Guo Ning, et al. Simulation and analysis of thermal characteristics of hollow cathode in ion thruster[J]. High Power Laser and Particle Beams, 2010, 22(5): 1149-1152.
- [25] 杨威, 张天平, 冯杰, 等. 石墨触持极空心阴极性能实验研究[J]. 真空与低温, 2017, 23(2): 87-91.
- Yang Wei, Zhang Tianping, Feng Jie, et al. Experimental investigation on performance of hollow cathode with graphite keeper[J]. Vacuum and Cryogenics, 2017, 23(2): 87-91.
- [26] 郭宁, 邱家稳, 顾佐, 等. 20 cm 氙离子发动机空心阴极 3 000 h 寿命试验[J]. 真空与低温, 2006(4): 204-206.
- Guo Ning, Qiu Jiawen, Gu Zuo, et al. 3 000-hour life test of hollow cathode for 20 cm Xenon ion thruster[J]. Vacuum and Cryogenics, 2006(4): 204-206.
- [27] 杨威, 史楷, 谷增杰, 等. LaB6 空心阴极放电电压波动现象及发生机理[J]. 科学技术与工程, 2020, 20(33): 13914-13918.
- Yang Wei, Shi Kai, Gu Zengjie, et al. Discharge voltage fluctuation phenomenon and its generation mechanism in LaB6 hollow cathode[J]. Science Technology and Engineering, 2020, 20(33): 13914-13918.
- [28] Hsieh J H, Huang Y L, Huang P H, et al. Investigation of anode diameter and keeper geometry influence on open-end emitter heaterless hollowcathode discharge[J]. Vacuum, 2024, 229: 113504.
- [29] Tian F, Miao L, Xia Q M, et al. A global model for evaluating discharge characteristics and performance of hollow cathodes[J]. Chinese Journal of Aeronautics, 2024, 37(9): 72-84.
- [30] 谢侃, 张天平, 武志文, 等. 离子发动机放电阴极的溅射腐蚀机理研究综述[J]. 真空科学与技术学报, 2014, 34(5): 461-468.
- Xie Kan, Zhang Tianping, Wu Zhiwen, et al. A review of sputtering erosion mechanism in discharge cathode for ion thrusters[J]. Journal of Vacuum Science and Technology, 2014, 34(5): 461-468.
- [31] 郭宁, 江豪成, 高军, 等. 等离子发动机空心阴极失效形式分析[J]. 真空与低温, 2005, 11(4): 239-242.
- Guo Ning, Jiang Haocheng, Gao Jun, et al. Analysis of failure modes in hollow cathodes for ion thrusters[J]. Vacuum and Cryogenics, 2005, 11(4): 239-242.
- [32] Tao F, Zhang M, Liu Y, et al. Digital twin driven prognostics and health management for complex equipment[J]. CIRP Annals-Manufacturing Technology, 2018, 67(1): 169-172.
- [33] Ke F, Ji J, Zhang Y, et al. Digital twin-driven intelligent assessment of gear surface degradation[J]. Mechanical Systems and Signal Processing, 2023, 186: 109896.
- [34] Cui L, Wang X, Liu D, et al. An adaptive sparse graph learning method based on digital twin dictionary for remaining useful life prediction of rolling element bearings[J]. IEEE Transactions on Industrial Informatics, 2024, 20(9): 10892-10900.
- [35] Kang T W, Mo Y. A comprehensive digital twin framework for building environment monitoring with emphasis on real-time data connectivity and predictability[J]. Developments in the Built Environment, 2024(17): 100309.
- [36] 陶飞, 马昕, 戚庆林, 等. 数字孪生连接交互理论与关键技术[J]. 计算机集成制造系统, 2023, 29(1): 1-10.
- Tao Fei, Ma Xin, Qi Qinglin, et al. Theory and key technologies of digital twin connection and interaction[J]. Computer Integrated Manufacturing System, 2023, 29(1): 1-10.