2026 年 第 26 卷 第 29 期
2026, 26(29): 12618-10

科 学 技 术 与 工 程
Science Technology and Engineering

ISSN 1671-1815
CN 11-4688/T

DOI:10.12404/j.issn.1671-1815.2507689
引用格式:于金禾, 赵建印. 基于 PINN-NODE 与 HGNN 的复杂系统退化预测方法[J]. 科学技术与工程, 2026, 26(29): 12618-12627.
Yu Jinhe, Zhao Jianyin. Complex system degradation prediction method based on PINN-NODE and HGNN[J]. Science Technology and Engineering, 2026, 26(29): 12618-12627.

武器技术

基于 PINN-NODE 与 HGNN 的复杂系统退化预测方法

于金禾[1,2], 赵建印[1*]
(1. 海军航空大学岸防兵学院, 烟台 264001; 2. 中国人民解放军 92330 部队, 青岛 266100)

摘 要 为解决惯性测量单元(inertial measurement unit,IMU)等复杂系统退化预测中的非线性建模困难、物理可解释性不足及多源异构信息融合等问题,提出了一种结合物理信息约束神经微分方程(physics-informed neural ordinary differential equations,PINN-NODE)和异构图神经网络(heterogeneous graph neural networks,HGNN)的退化预测模型。该模型通过一个并行的双分支网络:在时间维度上,结合 PINN-NODE 实现物理约束下的连续时间动态建模,自然地处理不规则采样数据;在空间维度上,使用 HGNN 捕获传感器与环境因素之间的耦合关系,用动态边权重重新构建温度、振动等环境应力。最后,利用多层感知机进行时空特征的融合,得到端到端的预测模型结果。根据实验结果可知,与传统的 LSTM 模型对比,在 IMU 退化数据集上测试的 RMSE 降低了 56.43%,MAE 降低了 58.65%,极大地提高了预测精度以及物理可解释性。由此可见,提出的模型在对复杂系统退化的预测上有着明显的优势,为全生命周期健康管理提供了新的方法。

关键词 退化预测; 物理信息神经网络; 神经常微分方程; 异构图神经网络; 惯性测量单元
中图法分类号 TJ765.3; **文献标志码** A

Complex System Degradation Prediction Method Based on PINN-NODE and HGNN

YU Jin-he[1,2], ZHAO Jian-yin[1*]
(1. School of Shore Defense, Naval Aviation University, Yantai 264001, China;
2. No. 92330 Unit of PLA, Qingdao 266100, China)

[**Abstract**] Degradation prediction for complex systems such as inertial measurement units (IMUs) is challenged by the need for nonlinear modeling, limited physical interpretability, and multi-source heterogeneous data fusion. To address these issues, a degradation prediction model integrating physics-informed neural ordinary differential equations (PINN-NODE) and heterogeneous graph neural networks (HGNN) was proposed. A parallel dual-branch architecture was used. In the temporal dimension, continuous-time dynamics under physical constraints were modeled by PINN-NODE. Irregularly sampled data were handled. In the spatial dimension, coupling relationships between sensors and environmental factors were captured by HGNN. Environmental stresses were reconstructed using dynamic edge weights. Spatiotemporal features were fused by a multilayer perceptron (MLP) to obtain an end-to-end predictor. On the IMU degradation dataset, RMSE is reduced by 56.43%, and MAE is reduced by 58.65%, relative to an LSTM baseline. The proposed model is shown to provide improved prediction accuracy with enhanced physical interpretability.

[**Keywords**] degradation prediction; physics-informed neural networks; neural ordinary differential equations; heterogeneous graph neural networks; inertial measurement unit

惯性测量单元(inertial measurement unit, IMU)是现代导航、控制和定位系统的中心器件,广泛应用于航空航天、自动驾驶及无人平台等领域[1]。IMU 在长期使用过程中会持续受到器件老化、温度变化、机械振动等因素的影响,其零偏、比例因子等关键性能参数将发生漂移,进而导致测量精度下降,严重时甚至危害系统可靠性与运行安全[2]。因此,对 IMU 性能退化过程进行准确建模与趋势预

收稿日期: 2025-11-05 修订日期: 2026-03-25
第一作者: 于金禾(1997—),女,汉族,山东青岛人,硕士研究生。研究方向:剩余寿命预测。E-mail:yujinhe1024@163.com。
* 通信作者: 赵建印(1976—),男,汉族,河北衡水人,博士,教授。研究方向:可靠性与延寿。E-mail:15553516651@163.com。

测,是实现剩余寿命评估和预测性维护的重要基础,对保障系统安全具有重要意义。

围绕复杂系统与关键传感器的退化预测问题,国内外学者已开展了大量研究,相关方法大体可分为基于物理机理或统计退化模型的方法、基于数据驱动的方法,以及物理机理与数据驱动相融合的方法。国外方面,基于随机过程、状态空间模型和物理机理的预测方法在剩余寿命预测中应用较早,具有较好的物理可解释性,但通常需要较强的先验假设,面对多因素耦合、非线性退化过程时建模难度较大[3]。在 IMU 及陀螺仪相关研究中,He 等[4]、Tan 等[5]分别采用 Wiener 过程、Kalman 修正等方法开展了速率陀螺和 MEMS 陀螺寿命评估研究,说明物理统计模型在器件寿命预测中具有一定应用基础。国内方面,已有研究将 LSTM、TCN 等深度学习模型引入航空发动机、滚动轴承等对象,并取得较好预测效果[3,6],表明数据驱动方法在退化模式提取方面具有明显优势。

相比传统方法,数据驱动模型能够依靠历史监测数据自动学习退化规律,从而减少对显式机理建模的依赖[6]。然而,现有 RNN、LSTM 等时序网络通常建立在规则采样和固定时间步长的假设之上[7],面对真实 IMU 监测数据中普遍存在的非均匀采样、观测间隔变化以及数据缺失等情况,往往需要插值或重采样等预处理步骤,不仅可能引入额外误差,也容易削弱时间连续性信息[8]。此外,在小样本、强噪声或复杂工况条件下,纯数据驱动模型缺乏必要的物理约束,容易出现过拟合以及与实际退化规律不一致的预测结果[9-10],限制了其可信度和工程应用价值。

为了兼顾模型表达能力和物理合理性,近年来融合物理机理与深度学习的研究逐渐成为国内外退化预测的重要发展方向[7,11]。其中,物理信息神经网络(physics-informed neural network,PINN)通过将物理定律嵌入损失函数,可有效增强模型的物理一致性与可解释性[12-16];神经常微分方程(neural ordinary differential equation,NODE)则将网络离散层扩展为连续时间动力系统,为不规则采样时间序列建模提供了新途径[17-20]。而图神经网络(graph neural network,GNN)在处理图结构数据与耦合关系方面具有优势[21],胡登宇等[22]将 GNN 用于复杂拓扑结构关系建模,验证了其在空间特征提取方面的有效性。异构图神经网络(heterogeneous graph neural network,HGNN)在多元变量关联建模、复杂拓扑关系刻画和异构信息融合方面展现出良好性能[23-28]。

从工程应用角度看,当前 IMU 健康管理仍较多依赖定期标定和经验维护,复杂工况下的预测性维护研究仍显不足。IMU 的退化是时间累积效应、环境应力与传感器耦合共同作用的结果,温度、振动和冲击等环境因素会影响器件退化速率,而陀螺仪、加速度计等元件之间也存在显著关联。现有方法多侧重单一时间维度或单一变量分析,难以同时刻画连续时间退化演化、耦合关系及环境应力影响。因此,构建一种兼具连续时间建模、物理先验约束能力和异构关系表达能力的 IMU 退化预测方法,具有明确的研究意义和工程价值。

针对上述问题,现提出一种融合物理信息约束神经微分方程(PINN-NODE)与异构图神经网络(HGNN)的 IMU 性能退化预测模型。针对 IMU 监测数据不规则采样、时间间隔非均匀的特点,引入 PINN-NODE 对退化过程进行连续时间动态建模,并通过单调性、疲劳累积性及环境应力条件一致性等物理先验对模型训练进行约束,从而提高预测结果的物理合理性。针对 IMU 内部多传感器及环境因素之间存在的复杂耦合关系,构建基于 HGNN 的空间建模分支,将陀螺仪、加速度计以及相关环境因素统一表示为异构图,实现多源异构信息的显式关联建模。通过时空双分支特征提取与融合,形成对 IMU 健康状态的综合表征,在提升预测精度的同时,增强模型可解释性和复杂工况下的适应能力。最后,通过验证实验表明所提方法能够有效捕捉 IMU 退化过程中的时间演化规律和空间耦合特征,为 IMU 及类似复杂传感系统的状态监测、剩余寿命预测提供新的技术支撑。

1　预测模型总体框架

为了同时捕捉 IMU 性能退化过程的时间依赖性和多组件间的空间相关性,提出了一种结合物理信息约束神经常微分方程(PINN-NODE)和异构图神经网络(HGNN)的混合预测模型,其框架如图 1 所示。该模型采用两个并行的特征提取模块,分别学习退化过程中的时间动态信息和空间结构信息,再由融合模块实现联合预测。

时间维度上,PINN-NODE 分支以 IMU 监测序列及其对应环境应力作为输入,对退化过程进行连续时间动态建模。通过引入物理先验约束,使模型在拟合观测数据的同时,满足退化演化的物理一致性,从而提取反映时间累积退化特征的潜在表示。

空间维度上,HGNN 分支将 IMU 内部传感器及环境应力统一表示为异构图结构,采用不同类型节点对应陀螺仪、加速度计以及温度、振动、冲击等因素,

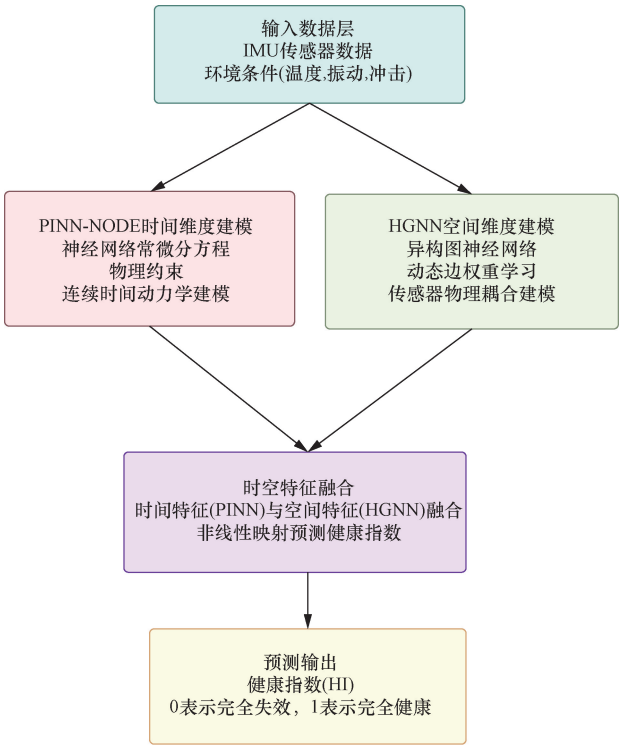

图 1 融合时空特征的退化预测模型框架图

Fig. 1 Framework of degradation prediction model integrating spatiotemporal features

不同类型边描述环境应力对核心传感器性能的影响关系。通过异构图卷积,学习多源变量之间的耦合关系,提取反映系统空间关联特征的嵌入表示。

在获得时间演化特征和空间耦合特征后,模型将两类特征进行拼接与非线性映射,形成统一的健康状态表征,并通过预测头输出最终的健康指数预测结果。该框架实现了退化时间、物理先验与空间耦合的协同建模,为 IMU 性能退化趋势预测提供了统一的时空融合方案。

2 时间演化特征建模

2.1 物理先验分析

IMU 的性能退化受到各种物理因素的持续影响。准确预测 IMU 的长期性能演化趋势,并确保预测结果符合物理规律,首先要分析影响 IMU 退化的关键物理因素,这些物理先验知识将作为“软约束”融入神经网络的损失函数中,从而引导模型学习到符合物理规律的退化模式。

2.1.1 单调性原则

单调性原则描述了系统退化在时间上内在的趋势。IMU 的性能损耗主要由材料疲劳、电子迁移和磨损老化等原因导致,在没有外部干预的前提下,性能退化是不可逆的。具体而言,内部结构产生的微裂纹扩展以及元器件参数的漂移,导致健康指数(health index, HI)随时间持续下降,且无法自行恢复。

由于 IMU 监测数据中存在测量噪声、瞬时环境干扰或短期可恢复的温漂,一个未受物理约束、过于灵活的深度神经网络为了在局部数据点上追求极致的拟合精度,可能会将噪声或波动判断为“性能回升”这一错误现象。这种过拟合与退化的本质规律背道而驰,会干扰剩余使用寿命估计和维护决策,削弱预测结果的可信度和可解释性。

因此,将单调性原则作为正则化项加入训练过程中,惩罚违背单调性的预测行为,能有效引导模型学到平滑且单向的退化趋势,从而改进模型的泛化能力及长期预测的稳定性。

2.1.2 条件相关性原则

条件相关性原则主要针对环境应力对退化过程的影响。IMU 所处的物理环境并非恒定不变,温度、振动、冲击等时变的环境应力是加速其性能衰减的主要环境应力因素。条件相关性原则旨在建立环境条件与性能退化速率之间明确的因果关联。

温度是影响 IMU 性能最显著的环境因素。根据 Arrhenius 定律,高温加速材料的老化、氧化和蠕变等过程,造成不可逆转的性能下降。高温还会引起元器件参数的漂移,导致传感器输出的偏置(bias)和比例因子(scale factor)发生漂移。

振动是 IMU 在工作载体上的常态,长时间的振动会导致器件内部微结构出现疲劳损伤,当损伤累积到一定程度时,便会产生微裂纹并逐渐扩展,导致性能下降。振动强度越大,损伤累积速率越快,退化速率与振动强度成正比。

机械冲击属于瞬间的高强度应力事件,可能会致使设备出现永久性形变,造成性能发生阶跃式的下跌或者严重退化的情况。

综上,温度、振动和冲击的强度越大,其退化速率也必定越快,或至少不会小于其他环境条件下的退化速率。

2.2 基于 Neural ODE 的连续时间建模

采用神经常微分方程,将关键内部状态表示为随时间 t 变化的潜在状态向量 $\boldsymbol{h}(t) \in \mathbf{R}^d$,构建能自然处理任意时间间隔观测的连续时间模型,其演化过程由以下常微分方程定义为

$$\frac{\mathrm{d}\boldsymbol{h}(t)}{\mathrm{d}t} = f_\theta[\boldsymbol{h}(t),\boldsymbol{e}(t)] \tag{1}$$

式(1)中:$\boldsymbol{h}(t)$ 为随时间变化的 d 维潜在状态向量;$\boldsymbol{e}(t) \in \mathbf{R}^{d_e}$ 为 d_e 维环境应力条件向量;f_θ:$\mathbf{R}^{d+d_e} \to \mathbf{R}^d$ 为由可学习参数 θ 构成的神经网络。

给定初始观测特征 $\boldsymbol{x}_0$ 和环境条件序列 $\{\boldsymbol{e}(t)\}_{t=0}^{T}$,模型首先通过编码器网络将观测映射

为初始潜在状态,表达式为

$$\begin{aligned}\boldsymbol{h}_0 &= \text{Encoder}(\boldsymbol{x}_0)\\ &= \tanh\{\boldsymbol{W}_e^{(2)}\tanh[\boldsymbol{W}_e^{(1)}\boldsymbol{x}_0+\boldsymbol{b}_e^{(1)}]+\boldsymbol{b}_e^{(2)}\}\end{aligned} \tag{2}$$

式(2)中:$\boldsymbol{x}_0$ 为初始观测特征向量;$\boldsymbol{W}_e^{(1)}\in\mathbf{R}^{d_h\times d_x}$ 和 $\boldsymbol{W}_e^{(2)}\in\mathbf{R}^{d\times d_h}$ 为编码器权重矩阵;$\boldsymbol{b}_e^{(1)}\in\mathbf{R}^{d_h}$ 和 $\boldsymbol{b}_e^{(2)}\in\mathbf{R}^{d}$ 为偏置向量;d_x 为输入特征空间的维度;d_h 为神经网络隐藏层的维度。

随后利用数值积分器求解常微分方程,获得潜在状态轨迹 $\{\boldsymbol{h}(t)\}_{t=0}^{T}$,表达式为

$$\boldsymbol{h}(t)=\boldsymbol{h}_0+\int_0^t f_\theta[\boldsymbol{h}(\tau),\boldsymbol{e}(\tau)]\mathrm{d}\tau \tag{3}$$

式(3)中:τ 为积分变量。

最终通过解码器网络将潜在状态映射回观测空间,即

$$\begin{aligned}\hat{\boldsymbol{x}}(t) &= \text{Decoder}[\boldsymbol{h}(t)]\\ &= \tanh\{\boldsymbol{W}_d^{(2)}\tanh[\boldsymbol{W}_d^{(1)}\boldsymbol{h}(t)+\\ &\quad \boldsymbol{b}_d^{(1)}]+\boldsymbol{b}_d^{(2)}\}\end{aligned} \tag{4}$$

式(4)中:$\hat{\boldsymbol{x}}(t)$ 为最终预测输出向量;$\boldsymbol{W}_d^{(1)}\in\mathbf{R}^{d_h\times d}$ 和 $\boldsymbol{W}_d^{(2)}\in\mathbf{R}^{d_x\times d_h}$ 为解码器权重矩阵;$\boldsymbol{b}_d^{(1)}\in\mathbf{R}^{d_h}$ 和 $\boldsymbol{b}_d^{(2)}\in\mathbf{R}^{d_x}$ 为偏置向量。

2.3　物理信息约束的复合损失函数

要将温度、振动和冲击等因素融入神经网络模型中,需要将这类描述性的物理原理转化为可计算、可优化的目标,即损失函数。为了使模型的预测不仅能拟合观测数据,更能遵循 IMU 器件在实际工作环境中的内在物理退化规律,设计了一个基于物理信息的复合损失函数,以约束神经网络严格遵守物理定律。

该损失函数由两部分构成:传统的数据拟合损失项 $\mathcal{L}_{\text{data}}$ 和物理约束损失项 $\mathcal{L}_{\text{physics}}$。模型的总损失函数表达式为

$$\mathcal{L}_{\text{total}}=\mathcal{L}_{\text{data}}+\lambda_{\text{physics}}\mathcal{L}_{\text{physics}} \tag{5}$$

式(5)中:λ_{physics} 为物理约束权重系数。

数据拟合损失项 $\mathcal{L}_{\text{data}}$ 采用均方误差(mean squared error, MSE)来衡量预测值与真实值之间的差异,表达式为

$$\mathcal{L}_{\text{data}}=\frac{1}{BT}\sum_{b=1}^{B}\sum_{t=1}^{T}\left|\boldsymbol{x}_{b,t}-\hat{\boldsymbol{x}}_{b,t}\right|_2^2 \tag{6}$$

式(6)中:B 为批次大小;T 为时间序列长度;$\boldsymbol{x}_{b,t}$ 为第 b 个样本在时刻 t 的真实观测值;$\hat{\boldsymbol{x}}_{b,t}$ 为对应预测值。

物理约束损失项 $\mathcal{L}_{\text{physics}}$ 是一个复合项,由多个独立的物理约束损失加权构成,表达式为

$$\begin{aligned}\mathcal{L}_{\text{physics}} &= \lambda_{\text{m}}\mathcal{L}_{\text{monotonic}}+\lambda_{\text{t}}\mathcal{L}_{\text{temp}}+\\ &\quad \lambda_{\text{v}}\mathcal{L}_{\text{vib}}+\lambda_{\text{s}}\mathcal{L}_{\text{impact}}+\lambda_{\text{f}}\mathcal{L}_{\text{fatigue}}\end{aligned} \tag{7}$$

式(7)中:λ_{m}、λ_{t}、λ_{v}、λ_{s}、λ_{f} 分别为各物理约束项的权重系数。

$\mathcal{L}_{\text{physics}}$ 不是简单地将多项物理规律线性叠加。为确保神经网络能深刻理解并遵循 IMU 性能退化的内在机理与外在动因,将物理约束划分为两大类:序贯一致性与条件一致性,确保模型预测结果在时间和因果两个维度上均保持物理真实性。

2.3.1　序贯一致性约束

序贯一致性旨在约束内在演化逻辑。系统内部状态的演变遵循特定的时间序列规律,其健康指数(health index, HI)的演化具有天然的单调性。序贯一致性损失确保模型在“纵向自比”,即同一样本在相邻时刻 $(t,t+1)$ 的预测结果是单向且递减的,因此采用单点惩罚 $\text{ReLU}(\Delta\hat{y}_{b,t}+\epsilon)$,确保演化过程符合内在逻辑。

1)单调性损失

设备性能退化是一个不可逆的过程,单调性约束用于惩罚任何导致预测健康指数出现“反弹”或“恢复”的非物理行为。为了在惩罚正向增长的同时,允许微小的、由噪声或计算误差引起的波动,该过程引入一个很小的容忍阈值 $\epsilon>0$,增加模型的鲁棒性。其表达式为

$$\mathcal{L}_{\text{monotonic}}=\frac{1}{B(T-1)}\sum_{b=1}^{B}\sum_{t=1}^{T-1}\text{ReLU}(\Delta\hat{y}_{b,t}+\epsilon) \tag{8}$$

式(8)中:$\hat{y}_{b,t}$ 为批次 b 中 t 时刻的预测健康指数;$\Delta\hat{y}_{b,t}=\hat{y}_{b,t+1}-\hat{y}_{b,t}$ 为连续两个时间步之间健康指数的变化量;$\text{ReLU}(\cdot)$ 为修正线性单元函数,确保只有当健康指数出现不合理的增长时,损失项才为正。根据物理原理,当模型能够预测出健康指数下降或不变,即 $\Delta\hat{y}_{b,t}\leqslant 0$,此时 ReLU 函数的输出几乎总是小于或等于 ϵ,在实际计算中可以视为 0 或一个极小值,因此不产生惩罚,符合物理规律。当 $\Delta\hat{y}_{b,t}>0$,此时 ReLU 函数的输出就是一个大于零的惩罚项,这个惩罚会通过梯度下降促使模型调整参数,直到这个违反物理规律的现象被修正。

2)疲劳损伤累积损失

疲劳损伤同样具有单向累积性,因此损失函数惩罚模型作出任何“健康状况好转”的预测。

$$\mathcal{L}_{\text{fatigue}}=\frac{1}{B(T-1)}\sum_{b=1}^{B}\sum_{t=1}^{T-1}\text{ReLU}(\Delta\hat{y}_{b,t}+\epsilon) \tag{9}$$

序贯一致性损失保证模型的退化趋势单调,且减少因数据噪声而导致的错误预测。

2.3.2　条件一致性约束

条件一致性损失关注的是系统对外部环境的

响应必须遵循明确的物理因果规律,以保证模型能正确学习到输入条件与输出结果之间的正相关关系。条件一致性损失是一个横向、外部的比较,比较对象是处在不同条件下的两个数据点 i 和 j。采用成对排序损失 $\mathrm{ReLU}(\Delta\hat{y}_i - \Delta\hat{y}_j)$ 的思想,该方法专注于学习预测值之间的相对排序关系,确保整个数据集因果关系一致。

1)温度损失函数

更高的工作温度对应着更快的退化速率。本约束旨在强制模型学习到退化速率与温度之间的这种正相关性。采用成对排序损失,在同一批次的训练数据中,任意选取两个不同的时间点 i 和 j。如果 i 时刻的温度 Temp_i 高于 j 时刻的温度 Temp_j,期望 i 时刻的退化速率 $\Delta\hat{y}_i$ 大于等于 j 时刻的退化速率 $\Delta\hat{y}_j$,即 $\Delta\hat{y}_i \geqslant \Delta\hat{y}_j$,因此惩罚所有 $\Delta\hat{y}_i < \Delta\hat{y}_j$ 这一关系的数据对。表达式为

$$\mathcal{L}_{\mathrm{temp}} = E_{(i,j)\mid \mathrm{Temp}_i > \mathrm{Temp}_j}[\mathrm{ReLU}(\Delta\hat{y}_j - \Delta\hat{y}_i)] \tag{10}$$

式(10)中:$E[\cdot]$ 表示对所有满足 $\mathrm{Temp}_i > \mathrm{Temp}_j$ 条件的数据对 (i,j) 上取期望,即计算平均值,确保了模型训练是基于整体数据的统计规律而非少数极端样本,使学习过程更加稳定和鲁棒。

当输入为负数时,即 $\Delta\hat{y}_i \geqslant \Delta\hat{y}_j$,ReLU 函数的输出为 0。这意味着,当模型的预测顺序与物理规律一致时,损失函数的值为零,不产生任何惩罚。当输入为非负数时,即 $\Delta\hat{y}_i < \Delta\hat{y}_j$,ReLU 函数的输出就是其输入值本身。这意味着一旦模型的预测顺序违反物理规律,就会产生一个正的损失值,用于惩罚这个错误的预测排序,从而通过反向传播算法促使模型调整参数。

2)振动损失函数

振动强度与退化速率之间也存在着明确的正相关关系。同样采用成对排序损失框架,任意选取两个时间点 i 和 j,如果 i 时刻的振动 Vib_i 大于 j 时刻的振动 Vib_j,则期望 i 时刻的退化速率 $\Delta\hat{y}_i$ 大于等于 j 时刻的退化速率 $\Delta\hat{y}_j$。对违反此关系的数据进行惩罚,表达式为

$$\mathcal{L}_{\mathrm{vib}} = E_{(i,j)\mid \mathrm{Vib}_i > \mathrm{Vib}_j}[\mathrm{ReLU}(\Delta\hat{y}_j - \Delta\hat{y}_i)] \tag{11}$$

该损失函数引导模型学习到在面对更剧烈的振动环境时,必须预测出更快的性能下降速率。

3)冲击损失函数

冲击的强度或幅值与其造成的性能退化程度呈现出明确的正相关关系。对于任意两个不同的冲击事件,冲击强度较高的事件所导致的性能退化程度,应不小于冲击强度较低事件所造成的退化。

取数据集中两个不同的样本 i 和 j,Impact_i 和 Impact_j 分别表示作用于样本 i 和 j 的冲击强度,$\Delta\hat{y}_i$ 和 $\Delta\hat{y}_j$ 是模型对这两个样本预测的性能退化量。如果 $\mathrm{Impact}_i > \mathrm{Impact}_j$,理论上应有 $\Delta\hat{y}_i \geqslant \Delta\hat{y}_j$。“冲击越大,退化越剧烈”的物理原理转化为数学约束的表达式为

$$\mathcal{L}_{\mathrm{impact}} = E_{(i,j)\mid \mathrm{Impact}_i > \mathrm{Impact}_j}[\mathrm{ReLU}(\Delta\hat{y}_j - \Delta\hat{y}_i)] \tag{12}$$

通过上述约束,使复合损失函数识别并量化模型预测结果与物理原理相悖的情况,惩罚并修正不符合物理现实的预测,从而做出更加合理可靠的预测。

2.4 时间演化特征的生成

在通过神经微分方程(NODE)对 IMU 的退化轨迹进行连续时间建模,并利用物理约束对其进行正则化之后,模型获得了一条高维的、隐含了系统退化规律的潜在状态轨迹。该轨迹可表示为一个矩阵 $\boldsymbol{Z}_{\mathrm{latent}} \in \mathbf{R}^{T\times d_t}$,其中 T 为输入序列的长度,d_t 为隐藏状态的维度。

$$\boldsymbol{Z}_{\mathrm{latent}} = [z_1, z_2, \cdots, z_T] \tag{13}$$

式(13)中:每一个向量 $z_t \in \mathbf{R}^{d_t}$ 代表在时间步 t 系统的一个抽象的、综合的健康状态表示。

为了给后续时空融合模块提供一个维度固定、概括了整个时间序列演化历史的特征向量,本模型选取序列最后一个时间步的隐藏状态向量 z_T 作为时间维度建模的最终输出。在循环或序贯模型中,最后一步的隐藏状态 z_T 理论上已经编码并累积了从初始时刻到当前时刻的所有信息。将这个向量称为时间演化特征,记作 $\boldsymbol{h}_{\mathrm{temporal}}$,其定义为

$$\boldsymbol{h}_{\mathrm{temporal}} = z_T \tag{14}$$

最终得到的向量 $\boldsymbol{h}_{\mathrm{temporal}} \in \mathbf{R}^{d_t}$ 全面地编码了 IMU 系统在物理规律约束下的时间累积退化效应,并作为时间维度建模模块的输出供后续时空融合模块使用。

3 空间耦合特征建模

IMU 通过陀螺仪和加速度计等传感器实时测量角速度和线加速度,提供基础运动信息。内部的多个传感器不是各自独立,而是与周围环境存在着复杂的物理耦合关系。为了精准刻画这种异构的相互作用,引入了异构图神经网络(heterogeneous graph neural networks,HGNNs),将 IMU 系统显式建模为一个包含多种类型节点和边的异构图 $\mathcal{G}=(\mathcal{V},\mathcal{E})$,从而在空间维度上捕捉其内在的物理耦合关系。在异构图 $\mathcal{G}=(\mathcal{V},\mathcal{E})$ 中,节点 $v \in \mathcal{V}$ 代表

系统内的不同物理实体,边 $e \in \mathcal{E}$ 则表示这些实体间的特定物理影响关系。

根据系统的物理构成,节点类型集合 $\mathcal{T}_v$ 被定义为

$$\mathcal{T}_v = \{\text{gyro},\text{accel},\text{temp},\text{vibration},\text{shock}\} \tag{15}$$

分别对应陀螺仪(gyro)、加速度计(accel)、温度传感器(temp)、振动传感器(vibration)和冲击传感器(shock)。基于先验物理知识,模型定义了 4 种有向的耦合关系用以描述环境因素对传感器的影响模式,其关系类型集合 $\mathcal{T}_\varepsilon$ 表达式为

$$\mathcal{T}_\varepsilon = (\text{temp},\text{affects},\text{gyro}),(\text{temp},\text{affects},\text{accel}),(\text{vibration},\text{affects},\text{gyro}),(\text{vibration},\text{affects},\text{accel}) \tag{16}$$

该集合明确地建立了温度和振动两种环境应力分别对陀螺仪和加速度计两种核心传感器性能产生影响的物理路径。需要注意的是,在异构图构建中,仅将温度和振动这两种连续性环境因素作为边的源节点,在架构上对不同物理效应进行了区分处理:连续性的状态耦合由 HGNN 在空间维度上建模,而瞬时性的冲击事件则由 PINN-NODE 模块在时间演化维度上进行捕捉,从而实现对不同物理过程的针对性建模。

模型从该异构图中自动提取并融合由多元耦合关系所产生的空间特征,其具体构建过程如下。

3.1　节点特征初始化与映射

异构图中的不同类型节点源于不同的传感器或环境因素,其初始特征向量维度各不相同。设节点类型 $t \in \mathcal{T}_v$ 的初始特征为 $\boldsymbol{x}_t$,其维度为 d_t。为在后续的卷积网络中进行统一维度的信息传递,模型首先通过一组类型特定的线性变换层,将各类型节点的初始特征统一映射至一个 d_{hidden} 维的隐藏特征空间。

对于任意节点类型 t,其第 0 层的特征表示 $\boldsymbol{h}_t^{(0)}$ 定义为

$$\boldsymbol{H}_t^{(0)} = \text{ReLU}(\boldsymbol{W}_t^{\text{in}}\boldsymbol{x}_t + \boldsymbol{b}_t^{\text{in}}) \tag{17}$$

式(17)中:$\boldsymbol{x}_t$ 为类型节点 t 的初始特征矩阵;$\boldsymbol{W}_t^{\text{in}} \in \mathbf{R}^{d_{\text{hidden}}\times d_t}$ 和 $\boldsymbol{b}_t^{\text{in}} \in \mathbf{R}^{d_{\text{hidden}}}$ 分别为节点类型的输入层权重矩阵和偏置向量;ReLU(·)为修正线性单元激活函数,用于引入非线性表达能力。

3.2　异构图卷积与特征传播

网络的核心由 L 个异构图卷积层堆叠而成,每一层的输出作为下一层的输入,逐层传播并融合图的结构信息。每一层均包含一组针对特定关系类型的图卷积算子。对于网络中的任意中间层 l,设任意目标节点类型 $d \in \mathcal{T}_v$,其特征矩阵 $\boldsymbol{H}_d^{(l)}$ 是基于上一层(第 $l-1$ 层)所有与它相关的源节点特征计算得出的。完整的更新过程分为消息传递、跨关系聚合和激活更新 3 个步骤。其具体计算过程定义如下。

3.2.1　关系特定的消息计算

假设图中的每一种边关系 $\boldsymbol{r} = (s,p,d) \in \mathcal{T}_\varepsilon$,其中,$s$ 为源节点类型,d 为目标节点类型,模型采用一个专属的图卷积算子 $\boldsymbol{G}_r^{(l)}$ 来计算从 s 类型邻居节点传递到 d 类型目标节点的消息,消息集合 $\boldsymbol{M}_{(d\leftarrow s)}^{(l)}$ 可表示为

$$\boldsymbol{M}_{(d\leftarrow s)}^{(l)} = \boldsymbol{G}_r^{(l)}[\boldsymbol{H}_s^{(l-1)}, \boldsymbol{A}_{s,d}] \tag{18}$$

式(18)中:$\boldsymbol{H}_s^{(l-1)}$ 为所有 s 类型节点在第 $l-1$ 层的特征矩阵;$\boldsymbol{A}_{s,d}$ 为描述 s 与 d 类型节点间连接关系的邻接结构;$\boldsymbol{G}_r^{(l)}$ 用以捕获关系 r 特有的特征变换模式。

3.2.2　节点特征跨关系聚合

在计算完所有关系类型的消息后,目标节点 d 的新特征 $\boldsymbol{h}_d^{(l)}$ 通过聚合所有指向它的、源自不同关系的消息集合而形成。本文模型采用求和作为跨关系类型的聚合函数 AGG。因此,d 类型节点的特征更新规则如下。

$$\boldsymbol{h}_d^{(l)} = \text{AGG}(\{\boldsymbol{M}_{(d\leftarrow s)}^{(l)} \mid \forall (s,p,d) \in \mathcal{T}_\varepsilon\}) = \sum_{(s,p,d)\in\mathcal{T}_\varepsilon} \boldsymbol{M}_{(d\leftarrow s)}^{(l)} \tag{19}$$

3.2.3　激活更新

对于中间层,聚合后的消息将通过一次非线性激活函数。其完整的单层更新规则表示为

$$\boldsymbol{H}_d^{(l)} = \text{ReLU}\Big\{\sum_{(s,p,d)\in\mathcal{T}_\varepsilon} \boldsymbol{G}_{(s,p,d)}^{(l)}[\boldsymbol{H}_s^{(l-1)}, A_{s,d}]\Big\},\quad \forall l \in \{1,2,\cdots,L-1\} \tag{20}$$

对于最后一层,输出在送入下一阶段前不再经过激活函数,表达式为

$$\boldsymbol{H}_d^{(L)} = \sum_{(s,p,d)\in\mathcal{T}_\varepsilon} \boldsymbol{G}_{(s,p,d)}^{(L)}[\boldsymbol{H}_s^{(L-1)}, \boldsymbol{A}_{s,d}] \tag{21}$$

通过 L 层的迭代计算,模型为每种节点类型学习到了融合了多阶邻域信息的深层语义特征 $\boldsymbol{H}_t^{(L)}$。

3.3　输出映射与特征向量整合

为了生成面向最终预测任务、维度更精简的特征表示,模型通过一个类型特定的线性输出层,将各节点类型在第 L 层学习到的 d_{hidden} 维特征,分别映射至一个 d_{out} 维的最终输出空间,表达式为

$$\boldsymbol{h}'_t = \boldsymbol{W}_t^{\text{out}}\boldsymbol{H}_t^{(L)} + \boldsymbol{b}_t^{\text{out}} \tag{22}$$

式(22)中:$\boldsymbol{W}_t^{\text{out}} \in \mathbf{R}^{d_{\text{out}}\times d_{\text{hidden}}}$ 和 $\boldsymbol{b}_t^{\text{out}} \in \mathbf{R}^{d_{\text{out}}}$ 为 t 类型节点的输出层参数。

至此,模型获得了代表各类物理实体在耦合关系下的特征嵌入集合 $\{\boldsymbol{h}'_{\text{gyro}}, \boldsymbol{h}'_{\text{accel}}, \cdots\}$。为形成一个统一的系统级空间特征向量,将这些特征嵌入按

照预定义的节点类型顺序进行拼接(concatenation),表达式为

$$\boldsymbol{h}_{\text{spatial}} = \text{Concat}(\boldsymbol{h}'_{\text{gyro}}, \boldsymbol{h}'_{\text{accel}}, \boldsymbol{h}'_{\text{temp}}, \boldsymbol{h}'_{\text{vibration}}, \boldsymbol{h}'_{\text{shock}}) \tag{23}$$

最终得到的 $\boldsymbol{h}_{\text{spatial}}$ 向量,维度为 $|\mathcal{T}_v| \times d_{\text{out}}$,它全面地编码了 IMU 系统在当前时刻由多元物理因素耦合所形成的空间特征,并作为空间维度建模模块的最终输出,供后续时空融合模块使用。

4 时空特征融合与预测

在通过 PINN-NODE 模块和 HGNN 模块分别提取了时间演化特征 $\boldsymbol{h}_{\text{temporal}}$ 和空间耦合特征 $\boldsymbol{h}_{\text{spatial}}$ 后,模型将这两种特征融合,并通过一个预测头来将融合后的高维特征映射为最终的健康指数预测值。

4.1 时空特征融合机制

采用分阶段的特征提取和融合策略。首先,从 PINN-NODE 模块获得时间演化特征向量 $\boldsymbol{h}_{\text{temporal}}$,从 HGNN 模块获得所有节点拼接后的空间耦合特征向量 $\boldsymbol{h}_{\text{spatial}}$。将时间演化特征向量和空间耦合特征向量在特征维度上进行拼接,得到组合特征向量为

$$\boldsymbol{h}_{\text{combined}} = \text{Concat}(\boldsymbol{h}_{\text{temporal}}, \boldsymbol{h}_{\text{spatial}}) \tag{24}$$

为学习时空特征之间深层次的非线性交互关系,将 $\boldsymbol{h}_{\text{combined}}$ 输入一个多层感知机(MLP)中进行初步融合。MLP 作为一种通用的非线性函数逼近器,能够学习到时空特征之间复杂的、非线性的交互关系,从而生成更具判别力的融合特征。该模块由一个全连接层、一个 ReLU 激活函数和一个 Dropout 层构成。其过程可表示为

$$\boldsymbol{f}_{\text{fused}} = \text{Dropout}[\text{ReLU}(\boldsymbol{W}_{\text{f}} \boldsymbol{h}_{\text{combined}} + \boldsymbol{b}_{\text{f}})] \tag{25}$$

式(25)中:$\boldsymbol{f}_{\text{fused}}$ 为经过初步非线性融合后得到的融合特征向量;$\boldsymbol{W}_{\text{f}}$ 和 $\boldsymbol{b}_{\text{f}}$ 分别为融合层的权重矩阵和偏置向量;ReLU(·)为修正线性单元激活函数,用于引入非线性,增强模型的表达能力;Dropout(·)以 0.1 的概率随机失活部分神经元,作为正则化手段防止过拟合。

4.2 健康指数预测

最终的健康指数预测由一个专门设计的预测头完成。该预测头是一个包含两层全连接层的多层感知机(MLP),负责将高维的融合特征 $\boldsymbol{f}_{\text{fused}}$ 映射到单一的健康指数标量值。其详细结构和数学定义如下。

首先,融合特征向量 $\boldsymbol{f}_{\text{fused}}$ 经过第一个全连接层和 ReLU 激活,并再次通过 Dropout 进行正则化,表达式为

$$\boldsymbol{h}_{\text{hidden}} = \text{Dropout}[\text{ReLU}(\boldsymbol{W}_1 \boldsymbol{f}_{\text{fused}} + \boldsymbol{b}_1)] \tag{26}$$

式(26)中:$\boldsymbol{W}_1$ 和 $\boldsymbol{b}_1$ 分别为预测头隐藏层的权重矩阵和偏置向量;$\boldsymbol{h}_{\text{hidden}}$ 为输出的隐藏层特征。

接着,隐藏层特征 $\boldsymbol{h}_{\text{hidden}}$ 被送入第二个全连接层(输出层),得到一个原始的输出值 $\boldsymbol{z}_{\text{output}}$。最后,该原始输出值通过 Sigmoid 激活函数,生成最终的健康指数预测值 $\hat{y}$。

$$\boldsymbol{z}_{\text{output}} = \boldsymbol{W}_2 \boldsymbol{h}_{\text{hidden}} + \boldsymbol{b}_2 \tag{27}$$

$$\hat{y} = \sigma(\boldsymbol{z}_{\text{output}}) = \frac{1}{1 + \text{e}^{-\boldsymbol{z}_{\text{output}}}} \tag{28}$$

式中:$\boldsymbol{W}_2$ 和 $\boldsymbol{b}_2$ 分别为预测头输出层的权重矩阵和偏置向量;$\sigma(\cdot)$ 为 Sigmoid 激活函数。

综上,通过有效融合时空特征并利用一个带有 Sigmoid 输出层的深度预测头,模型将从时间和空间两个维度提取的复杂退化信息,转化为一个符合物理直觉且范围合理的健康指数预测值。

4.3 模型整体训练流程

为了有效优化模型参数,设计了一套包含复合损失函数、梯度裁剪和早停机制的综合训练方法,确保模型获得最优的泛化性能。该训练流程的详细步骤如算法 1 所示。

算法 1 端到端统一训练流程

输入:训练数据加载器 train_loader,验证数据加载器 val_loader,模型实例 model,训练周期数 num_epochs,学习率 lr,物理损失权重 physics_weight

输出:优化后的模型参数 model.state_dict(·)

```
初始化优化器 optimizer ← AdamW(model.parameters(),lr=lr)
初始化主损失函数 criterion←MSELoss()
初始化早停机制 early_stopper←EarlyStopping(patience=7)
for epoch =1 to num_epochs do
model.train() //切换到训练模式
for each batch (x_batch, y_batch) in train_loader do
// ---步骤 A:时间特征提取(PINN-NODE 内部流程)---
initial_obs←x_batch[:,0,:obs_dim]// 提取序列初始时刻的观测特征
env_cond_seq ← x_batch[:,:,obs_dim]// 提取整个序列的环境条件特征
pinn_latent_traj ← ODESolve(initial_obs,env_cond_seq) // 求解神经常微分方程,获得潜在状态轨迹
physics_loss ← CalculatePhysicsLoss(pinn_latent_traj,...)//基于轨迹计算物理约束损失
temporal_features ← pinn_latent_traj[:,-1,:] //提取最后一个时间步的潜在状态作为时间特征
// ---步骤 B:空间特征提取(HGNN 内部流程)---
current_time_features ←x _batch [:,-1,:]// 提取序列最后一个时间步的全部原始特征
hgnn_input_data ← PrepareHGNNInputs(current_time_features) // 构建异构图数据对象
spatial_features_dict ← HGNNModule(hgnn_input_data) // HGNN 前向传播,获得各节点类型特征
spatial_features_flat ← Concat(spatial_features_dict.values()) // 拼接得到最终空间特征
// ---步骤 C:时空融合与预测---
```

19. combined_vec ← Concat(temporal_features, spatial_features_flat) // 拼接时间和空间特征
20. fused_vector ← FusionMLP(combined_vec) // 通过 MLP 进行特征融合
21. prediction ← PredictionHead(fused_vector) // 通过预测头得到最终预测值
22. // - - - 步骤 D: 复合损失计算与优化 - - -
23. loss_m ← criterion(prediction, y_batch) // 计算数据拟合损失
24. combined_loss ← loss_m + physics_weight × physics_loss // 计算加权总损失
25. optimizer.zero_grad( )
26. combined_loss.backward( ) // 反向传播计算梯度
27. clip_grad_norm_(model.parameters( ), max_norm = 1.0) // 梯度裁剪防止爆炸
28. optimizer.step( ) // 更新模型参数
29. end for
30. // - - - 步骤 E: 验证与早停 - - -
31. 在验证集上评估模型, 计算验证集总损失 total_val_loss
32. early_stopper(total_val_loss, model) // 检查是否满足早停条件并保存最佳模型
33. if early_stopper: early_stop is True then break
34. end for
35. return 加载并返回由 early_stopper 保存的最佳模型参数

5　实验验证与评估分析

5.1　实验设置

实验采用 20 个 IMU 生命周期数据,输入序列长度设为 50,批量大小为 64。输入特征为 9 维向量(陀螺仪 3 轴、加速度计 3 轴、温度、振动、冲击)。为消除量纲影响,采用 MinMaxScaler 进行数据归一化。模型配置为:PINN-NODE 的潜在状态维度为 16,HGNN 隐藏通道数为 16、输出通道数为 8,融合模块的隐藏维度为 64。

为了定量评估模型的预测性能,采用均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE)作为主要评价指标。两者均值越小,表示模型的预测精度越高。

$$\mathrm{RMSE}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i-\hat{y}_i)^2} \tag{29}$$

$$\mathrm{MAE}=\frac{1}{N}\sum_{i=1}^{N}|y_i-\hat{y}_i| \tag{30}$$

5.2　实验结果与分析

为了系统性地验证所提出的创新模型及其各关键组件的有效性,设计了以下 4 个模型进行对比,所有实验均在相同的软硬件环境和数据集划分下进行。

(1)Base LSTM Model(基准模型)。一个标准的 LSTM 网络,直接处理 9 维输入特征,用于建立传统时间序列预测方法的性能基准。

(2)Innovative Model(完整创新模型)。所提出的创新模型包含了完整的 PINN-NODE、HGNN 和融合模块,并启用物理约束损失。

(3)No PINN Physics 消融实验模型。在完整模型的基础上,将物理约束权重设为 0,以验证物理约束损失项的有效性。

(4)No HGNN 消融实验模型。在完整模型的基础上禁用 HGNN 模块,不进行空间特征提取,用于评估 HGNN 在建模传感器间耦合关系上的贡献。

在测试集中对上述模型进行评估,得到的性能指标如表 1 所示。

表 1　模型性能对比结果

Table 1　Model performance comparison results

序号	模型配置	RMSE	MAE	相对改进(RMSE)/%
1	Innovative Model	0.090 3	0.070 2	56.43
2	Ablation (No PINN Physics)	0.097 2	0.073 0	53.11
3	Ablation (No HGNN)	0.139 3	0.114 7	32.80
4	Base LSTM	0.207 3	0.169 8	—

实验结果表明,所提出的新模型取得了最佳性能,其 RMSE(0.090 3)和 MAE(0.070 2)均为最低。与传统的 Base LSTM 模型相比,RMSE 降低了约 56.43%,MAE 降低了约 58.65%,证明了研究所提出的时空协同、物数融合框架相对于传统方法的优越性。

移除 HGNN 模块对性能影响最大,表明模型无法捕捉传感器间的耦合关系,从而严重影响了预测精度。验证了异构图神经网络在建模传感器间复杂耦合关系方面的重要作用。

物理约束项的引入在数值指标上看提升有限,但其能够在数据拟合的基础上进一步约束和优化模型参数,使其预测更贴近真实的物理退化过程。物理约束更重要的价值在于提升模型的物理可解释性,避免模型产生违反物理直觉的预测结果,从而增强模型在复杂或未知工况下的泛化能力和可靠性,特别是在数据稀少的长期预测场景中表现更为稳定。

6　结论

针对惯性测量单元(IMU)性能退化预测过程中,传统数据驱动方式缺乏物理机理约束、无法捕捉多组件耦合关系的问题,提出了基于 PINN-NODE-HGNN 的性能退化预测框架。深度整合物理先验知识与深度学习模型后,很大程度上提升了 IMU 全生命周期性能预测的准确性。主要贡献如下。

(1)构建了时空协同、物数融合的预测模型。该模型通过两个并行的特征提取分支,在时间与空间两个维度上协同分析退化过程。PINN-NODE 能够保证时间维度上的物理一致性预测,HGNN 能很好地捕捉空间耦合关系。实验证明该模型优于传统的时间序列模型。

(2)验证了多维度物理先验的有效性。相比移除 HGNN 模块的模型,完整模型的 RMSE 降低了 35.2%(从 0.139 3 降至 0.090 3),证明了物理耦合关系建模对提高预测精度的必要性。物理约束损失项的加入增强了模型的可解释性,并提高了在复杂工况下的泛化能力。

研究显示,将物理机理同数据驱动方法相结合,能够明显改善复杂系统性能预测,为 IMU 及其他传感器系统的健康管理提供了新的解决途径。

参 考 文 献

[1] 刘振宇, 惠泽宇, 郭旭, 等. 基于滑动窗口优化的激光雷达惯性测量单元紧耦合同时定位与建图算法[J]. 科学技术与工程, 2022, 22(21): 9167-9175.
Liu Zhenyu, Hui Zeyu, Guo Xu, et al. Tightly coupled simultaneous localization and mapping algorithm for LiDAR inertial measurement unit based on sliding window optimization[J]. Science Technology and Engineering, 2022, 22(21): 9167-9175.

[2] Mi J, Wang Q, Han X. Low-cost MEMS gyroscope performance improvement under unknown disturbances through deep learning-based array[J]. Sensors and Actuators A: Physical, 2024, 368: 115086.

[3] 宁少慧, 戎有志, 董振才. 基于 PCA 和 DRSN-TCN 的滚动轴承的剩余寿命预测[J]. 科学技术与工程, 2025, 25(27): 15096-15104.
Ning Shaohui, Rong Youzhi, Dong Zhencai. Residual life prediction of rolling bearings based on PCA and DRSN-TCN[J]. Science Technology and Engineering, 2025, 25(27): 15096-15104.

[4] He Z Y, Lü W M, Hu W L. Residual life prediction of rate gyroscope based on Wiener process and Kalman correction[J]. Journal of Ordnance Equipment Engineering, 2019, 40(8): 53-58.

[5] Tan T T, Zhang S Y, Yang H Y, et al. Storage life evaluation of MEMS gyroscope based on Wiener process[J]. Equipment Environmental Engineering, 2024, 21(2): 59-64.

[6] 王欣, 孟天宇, 周俊曦. 基于注意力与 LSTM 的航空发动机剩余寿命预测[J]. 科学技术与工程, 2022, 22(7): 2784-2792.
Wang Xin, Meng Tianyu, Zhou Junxi. Remaining useful life prediction for aircraft engine using attention based LSTM[J]. Science Technology and Engineering, 2022, 22(7): 2784-2792.

[7] Li H W, Hao S, Ni Y Q, et al. Hybrid structural analysis integrating physical model and continuous-time state-space neural network model[J]. Computer-Aided Civil and Infrastructure Engineering, 2025, 40(2): 166-180.

[8] Hu Y, Wei R, Yang Y, et al. Performance degradation prediction using LSTM with optimized parameters[J]. Sensors, 2022, 22(6): 2407.

[9] Najera-Flores D A, Hu Z, Chadha M, et al. A physics-constrained Bayesian neural network for battery remaining useful life prediction[J]. Applied Mathematical Modelling, 2023, 122: 42-59.

[10] Yan R, Zhou Z, Shang Z, et al. Knowledge driven machine learning towards interpretable intelligent prognostics and health management: review and case study[J]. Chinese Journal of Mechanical Engineering, 2025, 38(1): 5.

[11] Chao M A, Kulkarni C, Goebel K, et al. Fusing physics-based and deep learning models for prognostics[J]. Reliability Engineering & System Safety, 2022, 217: 107961.

[12] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686-707.

[13] Nagesh C K, Sankaranarayanan S, Kaur R, et al. Taylor-model physics-informed neural networks (PINNs) for ordinary differential equations[C]//Proceedings of the International Conference on Neuro-symbolic Systems. Philadelphia, PA: PMLR, 2025: 621-642.

[14] Cuomo S, Di Cola V S, Giampaolo F, et al. Scientific machine learning through physics-informed neural networks: Where we are and what's next? [J]. Journal of Scientific Computing, 2022, 92(3): 88.

[15] Li X E, Wang J, Sun Y, et al. Physics-informed hybrid neural architecture for coupled degradation modeling and remaining useful life prediction of $LiFePO_4$ batteries[J]. Journal of the Electrochemical Society, 2025, 172(6): 060505.

[16] Falas S, Asprou M, Konstantinou C, et al. Robust power system state estimation using physics-informed neural networks[J]. IEEE Transactions on Industrial Informatics, 2025, 21(10): 8057-8067.

[17] Chen R T Q, Rubanova Y, Bettencourt J, et al. Neural ordinary differential equations[J]. Advances in Neural Information Processing Systems, 2018, 31: 6572-6583.

[18] Karniadakis G E, Kevrekidis I G, Lu L, et al. Physics-informed machine learning[J]. Nature Reviews Physics, 2021, 3(6): 422-440.

[19] Rubanova Y, Chen R T Q, Duvenaud D. Latent ODEs for irregularly-sampled time series[C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. Vancouver, BC: Neural Information Processing Systems, 2019: 5320-5330.

[20] Bonnaffé W, Sheldon B C, Coulson T. Neural ordinary differential equations for ecological and evolutionary time-series analysis[J]. Methods in Ecology and Evolution, 2021, 12(7): 1301-1315.

[21] Fang Z, Long Q, Song G, et al. Spatial-temporal graph ode networks for traffic flow forecasting[C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: Association for Computing Machinery (ACM), 2021: 364-373.

[22] 胡登宇, 王宝华, 刘晋宏. 基于改进图神经网络的含源配电网故障诊断方法及效果[J]. 科学技术与工程, 2025, 25(21): 8936-8944.
Hu Dengyu, Wang Baohua, Liu Jinhong. Fault diagnosis in distribution networks with distributed generation based on improved graph neural network[J]. Science Technology and Engineering,

2025, 25(21): 8936-8944.

[23] Wang X, Ji H, Shi C, et al. Heterogeneous graph attention network[C]//The world Wide Web Conference. San Francisco, CA: ACM, 2019: 2022-2032.

[24] Zhou Z, Basker R, Yeung D Y. Graph neural networks for multivariate time-series forecasting *via* learning hierarchical spatiotemporal dependencies[J]. Engineering Applications of Artificial Intelligence, 2025, 147: 110304.

[25] Jin M, Koh H Y, Wen Q, et al. A survey on graph neural networks for time series: forecasting, classification, imputation, and anomaly detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 10466-10485.

[26] Bing R, Yuan G, Zhu M, et al. Heterogeneous graph neural networks analysis: a survey of techniques, evaluations and applications[J]. Artificial Intelligence Review, 2023, 56(8): 8003-8042.

[27] Ngo Q H, Nguyen B L H, Vu T V, et al. Physics-informed graphical neural network for power system state estimation[J]. Applied Energy, 2024, 358: 122602.

[28] Wang X, Bo D, Shi C, et al. A survey on heterogeneous graph embedding: methods, techniques, applications and sources[J]. IEEE Transactions on Big Data, 2022, 9(2): 415-436.