

基于时空信息联合嵌入和离散融合学习的 涡扇发动机剩余寿命预测

杨晓祺¹, 李福海², 张德民², 王均磊², 马杰¹,
陈 铎¹, 杨凯旋¹, 刘 扬¹, 赵 振¹

(1. 青岛科技大学 信息科学技术学院, 山东 青岛 266061;

2. 青岛淄柴博洋柴油机股份有限公司, 山东 青岛 266701)

摘要: 针对现有的发动机剩余寿命预测方法对发动机多传感器数据利用率不足以及高维冗余数据特征难以提取的问题, 提出了一种基于时空信息联合嵌入和离散融合学习的发动机剩余寿命预测模型; 设计了时空信息联合嵌入网络, 通过对多传感器数据进行时空信息编码, 以有效地嵌入时间序列信息和空间特征信息, 协助模型更充分地理解数据内部的关联性; 构建了基于注意力的离散融合变分自编码网络, 以无监督的方式将时空信息嵌入特征通过码书映射进行量化, 进一步通过上下层融合注意力实现并行融合; 通过双向时序记忆剩余寿命预测网络综合关键退化特征的前向和后向的语义信息得到预测结果; 在航空涡扇发动机数据集上的实验结果表明, 所提出的方法能够有效提高发动机的剩余寿命预测精准度, 明显优于现有的其他方法。

关键词: 剩余寿命预测; 时空信息联合嵌入; 离散融合; 码书映射; 故障特征

Prediction of Turbofan Engine RUL Based on Spatio-temporal Information Joint Embedding and Discrete Fusion Learning

YANG Xiaoqi¹, LI Fuhai², ZHANG Demin², WANG Junlei², MA Jie¹,
CHEN Xin¹, YANG Kaixuan¹, LIU Yang¹, ZHAO Zhen¹

(1. School of Informance Science, Qingdao University of Science and Technology, Qingdao 266061, China;

2. Qingdao Zichai Boyang Diesel Engine Co., Ltd., Qingdao 266701, China)

Abstract: Aiming at the insufficient utilization of multi-sensor data and difficult extraction of high-dimensional redundant data features in existing engine residual life prediction methods, an engine remaining useful life (RUL) prediction model based on spatio-temporal information joint embedding and discrete fusion learning is proposed. A spatio-temporal information joint embedding network is designed to effectively embeds time series information and spatial feature information by encoding the spatio-temporal information of multi-sensor data, and help the model better understand the correlations within the data. A discrete-fusion variational self-coding network based on attention is constructed, which quantifies the embedded features of spatio-temporal information through code-book mapping in an unsupervised way, and further realizes parallel fusion through upper and lower fusion attention. The prediction results are obtained by combining the forward and backward semantic information of key degradation features in the bidirectional temporal memory residual life prediction network. Through experiments on the dataset of the aircraft turbofan engine, the results show that the proposed method can effectively improve the accuracy of engine RUL prediction, which is significantly better than other existing methods.

Keywords: RUL prediction; joint embedding of spatio-temporal information; discrete fusion; codebook mapping; fault characterization

收稿日期:2024-06-04; 修回日期:2024-08-28。

基金项目:国家自然科学基金(62201314;62201571);强链计划(23-1-2-qdjh-18-gx)。

作者简介:杨晓祺(1997-),男,硕士研究生。

刘 扬(1988-),男,博士研究生,副教授。

通讯作者:赵 振(1982-),男,博士研究生,副教授。

引用格式:杨晓祺,李福海,张德民,等. 基于时空信息联合嵌入和离散融合学习的涡扇发动机剩余寿命预测[J]. 计算机测量与控制, 2025, 33(9): 36-46.

0 引言

随着社会的不断发展和交通工具的广泛应用,发动机作为其驱动力的核心组件扮演着至关重要的角色。然而,通过预测性维护的方法对发动机进行健康管理(PHM, prognostics and health management)^[1-2]一直是工程界面临的关键挑战之一。发动机寿命的精准预测对于优化维护计划以及减少维修成本具有重要意义。因此,对发动机寿命进行准确的预测已成为工程领域中备受关注的研究方向之一。

发动机剩余寿命预测(RUL, remaining useful life)分为基于物理模型的方法和基于数据驱动的方法。基于物理模型的方法通过借助物理退化模型^[3-4]进行建模分析,例如文献[5]利用线弹性力学 Forman 裂纹扩展规律建立发动机中滚动轴承振动的物理模型进行寿命预测。文献[6]提出一种基于设备状态动态监测时序信息和发动机内部轴承退化的物理模型寿命预测方法,利用粒子滤波模型对滚动轴承后期运行趋势进行递推预测。文献[7]从理论研究和实践工程应用中对发动机轮盘低循环疲劳的使用剩余寿命进行了深入研究,并利用改进后的模型,结合多危险部位修正公式,对发动机涡轮盘的低循环疲劳寿命进行了评估。虽然基于物理模型的方法具有较高的可靠性和预测精度,但是物理模型确立后其参数难以修改,因此,基于物理模型的方法在实际复杂环境下无法满足对设备剩余使用寿命预测的准确性和实时性的要求^[8]。基于数据驱动的方法^[9]利用反映设备运行状态的监测数据建立系统数学模型,能够解决复杂环境下不同参数变动影响预测结果的问题。数据驱动的方法又可以进一步划分为基于机器学习^[10-11]的方法和基于深度学习的方法,机器学习方法主要包括支持向量机、随机森林等方法,例如文献[12]提出了一种基于 LS-SVM 的发动机在翼寿命预测方法,通过对影响发动机在翼寿命的性能参数进行分析,采用贝叶斯推断理论优化 LS-SVM 建模过程,以获取最优建模参数,从而对发动机在翼寿命方面进行精准预测。文献[13]提出了一种结合支持向量机的发动机寿命预测方法,该方法参照发动机的失效时间建立退化轨迹模型,能够在仅有少量失效信息的情况下实现寿命预测。文献[14]提出一种改进回归型支持向量机的发动机内部机械件的寿命预测方法,通过主成分分析将特征指标融合成综合指标,然后构建数据集并建立回归型支持向量机模型用于发动机内部机械件的寿命预测,该方法相较于其他的支持向量机模型有更高的预测精度。由于发动机系统运行机理复杂,需要考虑除振动外的温度和油耗等多种类型数据,而机器学习方法在处理具有多维特征的复杂数据上存在局限性。与传统机器学习相比,深度学

习具有更深层次的网络结构和更多的权值。这一特点使得深度学习能够实现对多层特征的表达,并能够自适应于复杂特征的分布。近年来,基于深度学习的发动机剩余使用寿命预测方法引起了研究者的极大兴趣,例如文献[15]提出一种改进一维卷积神经网络的涡扇发动机剩余寿命预测方法,通过一维卷积提取局部特征,然后利用贝叶斯优化后的 LSTM 对提取的局部特征实现剩余寿命预测。然而仅使用一维卷积作为特征提取器,无法对特征的长期依赖关系进行建模,从而降低发动机寿命预测的精度。为此,文献[16]提出一种基于时间注意力机制的剩余寿命预测方法,通过在通道上对关键特征赋予权重,从而捕捉机械设备的全局特征,但是该方法对发动机全寿命数据中复杂的非线性退化过程的建模能力较差,导致模型泛化能力有限。为进一步提高泛化能力,文献[17]提出一种通过对变分自编码网络进行卷积融合改进的预测方法,利用融合后的全卷积网络来降低模型复杂度并提高编码网络对特征的学习效率,从而增强泛化能力。文献[18]提出一种将变分自编码器融合到双判别器对抗结构的特征提取模型。其中,变分自编码器作为对抗生成模型来形成双重嵌套结构,实现对退化时域信息进一步挖掘提取。上述研究方法主要分析基于提取多传感器的深层特征对发动机剩余寿命预测结果的影响,但是针对多个传感器监测分析的结果来看,部分传感器数据在发动机完整的退化曲线中相关性并不高,会导致无法全面学习和利用各个传感器中隐含的故障信息,降低对多传感器监测数据的利用率。最近,文献[19]为解决在预测发动机剩余寿命中多传感器数据利用率不足的问题,提出基于时空信息嵌入模块,分别将多传感器数据进行独热编码与位置编码以得到空间编码向量和时间编码向量作为输入特征,通过不同维度提取原始数据中的故障特征,最终的预测结果以及数据利用率上的评估结果表明利用时空信息特征可以有效避免部分传感器监测数据中退化趋势不明显对预测精度的影响,提升对多传感器数据的利用率。因此,本文从时空特征的角度开展对发动机剩余寿命预测方法的研究。

针对实际发动机复杂工况下导致多传感器监测数据多样化,在噪声影响下高维冗余数据掩盖关键信息导致特征难以提取的问题尤为突出。如何在高维冗余数据的情况下,有效提取深层次特征,以提升发动机剩余寿命的预测精度,是本文要解决的一个关键问题。文献[20]为解决发动机剩余寿命预测中如何避免高维冗余数据对结果的影响,提出基于变分编码注意力融合网络充分挖掘多维度故障信息中的时序特征,通过对多维度监测数据降维后进行时序特征的提取获得长期时序故障

信息,最终提升预测网络的特征提取能力。因此,本文从融合注意力的变分自编码网络对高维冗余数据降维去噪的角度开展对发动机剩余寿命预测方法的研究。

本文提出了一种基于时空信息联合嵌入和离散融合学习(STA-DF, spatio-temporal attention and discrete fusion learning)的发动机剩余寿命预测方法。首先,设计时空信息联合嵌入网络实现对关键特征的提取,其中空间特征信息提取模块^[21]通过在输入的多传感器时序数据中的不同空间位置上分配唯一的空间编码向量,捕捉局部突出的故障信号,提高模型对局部的发动机复杂退化信息的区分性和泛化能力;时间序列信息提取模块通过时间卷积网络(TCN, temporal convolutional network)和时间模式注意力机制(TPA, temporal pattern attention)为不同时间步长赋予注意力权重,使模型不仅能够提取全局特征,同时感知不同位置间的相对顺序,进一步捕获时序数据中不同位置之间的依赖性;然后,构建基于注意力的离散融合变分自编码网络(DFVAE, discrete fusion variational autoencoder of attention)融合来自时空并行提取的退化特征,以进一步学习深层退化信息,从而提高模型整体的预测性能;最后,利用双向长短时记忆网络捕获融合后的退化特征中的长期依赖关系,通过全连接层预测数据的剩余使用寿命。在航空涡扇发动机数据集(CMAPSS, commercial modular aero-propulsion system simulation)的FD001、FD002、FD003和FD004中,对STA-DF进行了验证,相较于当前最先进的方法, RMSE和Score值分别提升了0.4%和1.86%。

1 基于时空信息联合嵌入和离散融合学习的网络模型

1.1 模型介绍

基于时空信息联合嵌入和离散融合学习的发动机

RUL预测模型包含时空信息联合嵌入网络、基于离散融合学习的变分自编码网络和双向时序记忆RUL预测网络3个部分。如图1所示。

引入时空信息联合嵌入网络在建模时序数据时能够自动地根据时间步骤和特征的重要性来赋予不同的权重,聚焦于重要的退化时间点和特征,从而有效地捕捉多传感器数据中的关键模式和变化。另一方面,为了融合提取后不同维度的退化特征构建基于注意力的离散融合变分自编码网络,通过学习时空特征的潜在分布,利用码书映射融合退化特征中的潜在联系。接着,通过多层全连接的双向长短时记忆网络,以获取综合历史和将来的时序关系,这样就可以对剩余寿命进行更精准的预测。

1.2 时空信息联合嵌入网络

1.2.1 时间序列信息提取模块

如图2所示,时间序列信息提取模块结合时间卷积网络和时间模式注意力机制,能够有效地学习时间序列中的重要特征,并通过不同时间步的差异化权重分配实现全局时序特征的提取。

首先,将发动机多传感器数据通过归一化到 $[-1, 1]$ 区间获得 $X^T = (x_1, \dots, x_T)$,作为时空信息联合嵌入网络的输入。然后,利用TCN对长期和短期的时间依赖关系进行处理,通过扩张因果卷积进一步捕获时间序列数据中的全局时序特征,并生成中间表示的关键全局特征信息,公式如下:

$$F_d(x_T) = \sum_{k=1}^K f_k \cdot x_{T-(K-k)d} \quad (1)$$

其中: f_k 为卷积核的权重, K 为卷积核的大小, d 为扩张因子,且选择ReLU函数作为卷积块的激活函数防止模型过拟合。为了充分利用原始数据分布中的所有特征提高模型的泛化能力,在每个卷积层的输出和输入




图1 基于时空信息联合嵌入和离散融合学习的网络模型结构图




图 2 时间序列信息提取模块结构图

之间引入了一个跨层的跳跃连接，为捕捉到时间序列中的长期依赖关系添加浅层的边缘信息，公式如下：

$$h = \text{Activation}[x_T + F_d(x_T)] \quad (2)$$

其中：\$h\$ 为 TCN 模块的输出值。随后将 TCN 输出的隐藏状态向量构成一个隐藏状态 \$H = \{h_{t-w}, h_{t-w+1}, \dots, h_t\}\$ 作为 TPA 的输入，这里 \$h_t\$ 是在 \$t\$ 时刻的状态，其中，\$w\$ 表示注意力机制对时间序列长度的影响。

如图 3 所示，TPA 模块是一种融合了 CNN 特征提取功能的网络模型，通过对隐藏状态矩阵 \$\mathbf{H}^C\$ 的行向量的卷积运算来产生时序模式矩阵，计算公式为：

$$\mathbf{H}_{i,j}^C = \sum_{l=1}^w \mathbf{H}_{i,(t-w-l+1)} \times C_{j,(T-w+l)} \quad (3)$$

\$j\$ 是具有 \$T\$ 长的第 \$j\$ 个滤波器，\$\mathbf{H}_{i,j}^C\$ 是由第 \$j\$ 个滤波器对 \$\mathbf{H}^C\$ 第 \$i\$ 行卷积后获得的时序模式矩阵。




图 3 时间模式注意力机制结构图

其次，利用记分函数来评价时序特征，从而得到注意力权重。记分函数 \$f\$ 为：

$$f(\mathbf{H}_i^C, \mathbf{h}_t) = (\mathbf{H}_i^C)^T \mathbf{W}_a \mathbf{h}_t \quad (4)$$

其中：\$\mathbf{h}_t\$ 为时间步 \$t\$ 时 TCN 模块输出的隐藏状态向量，\$\mathbf{W}_a\$ 表示权重矩阵。接下来，对获得的评分特征向量进行激活以得到注意力权重，其中时序模式矩阵第 \$i\$ 行的注意力权重 \$\alpha_i\$ 的计算公式如下：

$$\alpha_i = \text{sigmoid}[f(\mathbf{H}_i^C, \mathbf{h}_t)] \quad (5)$$

随后，将 \$\alpha_i\$ 用于对 \$\mathbf{H}^C\$ 每行加权的总和，从而获得如公式 (6) 所示的向量 \$\mathbf{v}_t\$：

$$\mathbf{v}_t = \sum_{i=1}^n \alpha_i \mathbf{H}_i^C \quad (6)$$

最后，在 \$t\$ 时刻对上下文变量 \$\mathbf{v}_t\$ 和隐藏状态 \$\mathbf{h}_t\$ 进行线性对应，然后将它们相加，并通过 Softmax 函数处理，以得到时间注意力权重矩阵 \$\mathbf{I}^T\$，最终，时间序列信息提取模块的输出 \$FT_{out}\$ 表示如下：

$$FT_{out} = \mathbf{X}^T * \mathbf{I}^T = \mathbf{X}^T * \mathbf{W}_{h'} (\mathbf{W}_h \mathbf{h}_t + \mathbf{W}_v \mathbf{v}_t) \quad (7)$$

其中：\$\mathbf{W}_{h'}, \mathbf{W}_h, \mathbf{W}_v\$ 表示对应特征的权重矩阵。

1.2.2 空间特征信息提取模块

如图 4 所示，空间特征信息提取模块首先利用自注意力机制实现重要特征区域定位操作，通过一维卷积提取特征，然后利用跳跃连接与浅层边缘特征实现点乘融合，从而减少特征之间距离的影响，提高局部特征的提取效果。

首先，3 个线性层被用来对数据 \$\mathbf{X}^T = (x_1, \dots, x_T)\$ 处理得到查询矩阵 \$\mathbf{Q}\$、键矩阵 \$\mathbf{K}\$ 以及值矩阵 \$\mathbf{V}\$；然后，在计算注意力权重矩阵时，需要将 \$\mathbf{Q}\$ 与 \$\mathbf{K}\$ 进行转置相乘，同时除以缩放因子 \$d_k\$，再经过 Softmax 函数处理将得到自注意力权重矩阵和 \$\mathbf{V}\$ 相乘，得到如下公式 (8) 所示的自注意力加权后的结果 \$\mathbf{S}^T = (s_1, \dots, s_T)\$：

$$\mathbf{S}^T = \text{Softmax} \cdot \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}} \right) \mathbf{V} \quad (8)$$

然后，为计算空间特征权重矩阵 \$\mathbf{I}^S\$ 使用一维卷积




图 4 空间特征信息提取模块结构图

核尺寸为 7×1 的卷积计算，再利用 sigmoid 函数对 I^S 进行激活。按照如下公式 (9) 计算空间注意力：

$$I^S = \text{sigmoid}[\text{conv}^{7 \times 1}(S^T)] \quad (9)$$

最终，对具有 7×1 尺寸的卷积进行运算，获得空间特征信息提取模块表达式 (10)：

$$FS_{\text{out}} = I^S * X^T \quad (10)$$

1.3 基于注意力的离散融合变分自编码网络

对于时空信息联合嵌入网络处理后的重要特征，利用基于注意力融合的离散变分自编码网络对其进行处理，首先，给定输入数据为时空信息联合嵌入网络的输出数据特征 FT_{out} 和 FS_{out} ，编码器计算隐含特征向量 z ， $x \rightarrow z$ 是变分编码过程，记为 $q_\varphi(z|x)$ 。其中，解码器根据 z 重构 $\hat{x}$ ， $z \rightarrow \hat{x}$ 为 DFVAE 的变分解码过程，记为 $p_\theta(\hat{x}|z)$ 。对于输入数据 FT_{out} 和 FS_{out} 进行迭代训练，得到隐变量 z 的均值 μ 和标准差 σ ，并在此基础上随机抽样参数 ϵ ，经过重采样生成 z ，从而解决神经网络学习过程中出现梯度消失问题：

$$z = \mu + \epsilon^* \sigma \quad (11)$$

为了融合时空联合嵌入网络输出的并行特征，利用 DFVAE 对潜在变量进行离散化，对于模型输入数据 $x \in (FT_{\text{out}}, FS_{\text{out}})$ ，通过编码器输出 $z_e(x)$ ，分布 $q_\varphi(z|x)$ 概率计算如下：

$$q_\varphi(z = k | x) = \begin{cases} 1; k = \text{argmin}_j \|z_e(x) - e_j\|_2 \\ 0; \text{其他} \end{cases} \quad (12)$$

其中， $z_e(x)$ 为编码器的输出， e_j 为编码中第 j 个基向量。

将 $\log p_\theta(x)$ 与 $E(q)$ 绑定，此时 $q_\varphi(z=k|x)$ 是确定的，通过在 z 上定义简单的均匀先验获得 KL 散度常数并等于 $\log k$ ，DFVAE 计算公式如下：

$$z(\theta, \varphi; x) = \log p_\theta(x | z_\varphi(x)) + \|sg[z_e(x)] - e\|_2^2 + \beta \|z_e(x) - sg[e]\|_2^2 \quad (13)$$

式中， $z(\theta, \varphi; x)$ 由三部分组成，第一部分为重建损失利用对数似然损失来优化编码器和解码器参数。第二个部分为编码空间损失用于优化编码空间。第三部分为承诺损失来迫使编码器在编码空间附近生成特征表示。 sg 为正向计算时被定义为标识的停止梯度运算符，具有零偏导数。

如图 5 所示，通过上下层融合注意力融合并行特征 $z_e(x)$ ，目的是融合两段时空信息经过离散编码空间处理后的退化特征。




图 5 上下层融合注意力结构图

具体地，对于第 i 个注意力头中的输入特征，首先被投影到查询 (Q_i)，键 (K_i) 和值 (V_i) 的张量上：

$$Q_i, K_i, V_i = z_e(x) W_i^Q, z_e(x) W_i^K, z_e(x) W_i^V \quad (14)$$

其中， W_i^Q, W_i^K, W_i^V 为第 i 个头中的线性映射权重矩阵。然后，利用 H 个独立的注意力头并行计算自注意，同时采用上下层的特征向量聚合 (MTA) 方法来优化计算效率，促进不同尺度上的情绪信息的融合。该方法通过设置下采样率 b_i 的方式来对同一个注意力层中的不同注意力头的 K_i 和 V_i 进行长度裁减与扩充，使得同一自注意力层上，注意力头的大小不相同且长度在不同尺度信息的不同头中变化。当 b 值变大时，合并了 K_i, V_i 中部分的特征图，使 K_i, V_i 的长度减少，从而降低了计算成本，但仍然保持了对主要特征的捕获能力。相反，当 b_i 值减小时会保留更多细节信息，但会增加计算成本。将不同的 b_i 值集成到一个自注意力层中使其拥有能够融合多尺度信息的特性，对于由 i 值索引的不同注意力头部，键 K_i 和值 V_i 被下采样到不同尺度的大小：

$$K_i^d, K_i^s = \text{MTA}(K_i, b_i^d), \text{MTA}(K_i, b_i^s) \quad (15)$$

其中： b_i^d 和 b_i^s 代表两种不同的内核大小和步长。 K_i^d 和 K_i^s 代表了第 i 个头的 b_i^d 和 b_i^s 降采样率后的键值，分别为密集局部键 K_i^d 与稀疏全局键 K_i^s 。相应地，在 b_i^d 和 b_i^s 的降采样率下，密集局部值 V_i^d 和稀疏全局值 V_i^s 的公式如下：

$$V_i^d, V_i^s = \text{MTA}(V_i, b_i^d) W_i^V, \text{MTA}(V_i, b_i^s) \quad (16)$$

其中： V_i^d 和 V_i^s 分别表示第 i 个头的 b_i^d 和 b_i^s 降采样率后的值。由于变量 b_i 存在于注意头部的每个注意层中，因此键和值可以捕获每个自注意层中不同的尺度特征。然后，将修改后的 V_i^d 和 V_i^s 与经过深度可分离卷积块 (DSC) 后的初始 V_i 的结果相加，实现局部增强，分别记为 $V_i^{d,a}$ 和 $V_i^{s,a}$ ，其公式如下：

$$V_i^{d,a}, V_i^{s,a} = V_i^d + LE(V_i), V_i^s + LE(V_i) \quad (17)$$

式中， $\text{MTA}(\cdot, b_i)$ 表示以 b_i 下采样率采样， $LE(\cdot)$

是通过深度可分离卷积对 V_i 值的 MTA 结果进行局部增强, 以保留了更多细粒度和低层次的细节信息获得高质量的退化特征。然后, 计算密集局部注意力图 F_M^d 和稀疏远距离注意力图 F_M^s 如下:

$$F_M^d, F_M^s = \text{Softmax}\left[\frac{Q_i(K_i^d)^T}{\sqrt{d_h}}\right] V_i^{d,a}, \text{Softmax}\left[\frac{Q_i(K_i^s)^T}{\sqrt{d_h}}\right] V_i^{s,a} \quad (18)$$

其中: d_h 表示维数, Q_i 表示第 i 头的初始查询张量。总体而言, 注意力图 F_M 的计算方法如下:

$$F_M = \text{Cat}(F_M^d, F_M^s) \quad (19)$$

其中: $\text{Cat}()$ 表示对输入的多个注意力图在通道维度上进行拼接。

1.4 双向时序记忆 RUL 预测网络

将 DFVAE 中提取的关键退化特征输入双向长短时记忆网络 (BILSTM) 中。通过 BILSTM 的两个方向的 LSTM 单元处理输入序列, 以同时获取前后向上的信息, 提升模型对上下文中关键退化特征的提取效率。BILSTM 能够自适应地调整前向和后向 LSTM 单元的門控状态, 并利用其中的神经网络参数来控制信息的传递和记忆。

LSTM 的计算公式为:

$$\begin{cases} i_t = f_s[B_f \cdot (k_{t-1}, z_t) + b_i] \\ \tilde{C}_t = \tanh[B_z \cdot (k_{t-1}, z_t) + b_c] \end{cases} \quad (20)$$

$$f_t = f_s[B_g \cdot (k_{t-1}, z_t) + b_z] \quad (21)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t \quad (22)$$

$$\begin{cases} o_t = f_s[B_o \cdot (k_{t-1}, z_t) + b_o] \\ k_t = o_t \otimes \tanh(C_t) \end{cases} \quad (23)$$

$$k_t = \text{LSTM}(z_t, k_{t-1}) \quad (24)$$

对于 LSTM 细胞单元, 记作 C_t ; z_t 和 k_t 表示细胞单元在当前时刻的状态; sigmoid 激活层记作 f_s , B_f , B_z , B_g , B_o , b_i , b_c , b_z , b_o 分别代表各个門或状态的权重矩阵和偏置项, 从而完成对单元间的乘法运算。其中, 公式 (20) ~ (24) 可得 t 时刻输出 k_t 与当前时刻 t 输入 z_t 和上一时刻 $(t-1)$ 输出 (k_{t-1}) 的函数。

在前向层中输入 z_t , 从 0 时刻起到 t 时刻, 求出向前向层的输出向量 k_f ; 然后, 继续在反向层输入 z_t , 在 t 时刻到 0 时刻, 得到隐层的输出 k_b 。整个网络在 t 时刻的输出 k_t 为:

$$k_t = W_f k_f + W_b k_b + b_k \quad (25)$$

式中, W_f 与 W_b 表示当前前向 LSTM 和后向 LSTM 的权重, b_k 是输出层的偏置因子。

最后, 通过回归预测网络对 BILSTM 模块的输出 k_t 进行回归预测, 其中包含两个全连接层, 第一层负责从输入特征向量中提取重要特征, 第二层负责特征的维度变换并输出最终的预测结果:

$$\text{Loss} = \alpha z(\theta, \varphi; x) + (1 - \alpha) \sqrt{\frac{1}{N} \sum_{i=1}^N (k_i - z_i)^2} \quad (26)$$

式中, N 为样本总个数, α 是平衡离散融合学习的变分自编码网络与双向时序记忆 RUL 预测网络损失的权重比。

2 实验结果及分析

2.1 实验数据介绍

航空涡扇发动机数据集^[22]是由美国宇航局生成的, 用来模拟航空涡扇发动机性能的劣化情况。其中, 该发动机数据集包括 4 个子集, 每一个子集都覆盖了一个不同的失效模式、运行条件以及多台涡扇发动机的数据。FD001 子集包括了涡扇发动机在某一工况下的 100 台发动机全部工作状态, 包括从正常工作到失效全过程, 只包括一种失效模式。FD002 子集包含了各种工况及失效模式, 为了解各种工况下的发动机工作特性及失效机理提供了重要的参考依据。FD003 子集与 FD002 相似, 能够对多种工况及失效模式进行更全面的分析, 从而为了解各种工况下发动机的工作状态及故障特性奠定基础。FD004 子集中数据的运行工况及失效模式将为航空发动机的运行特征与失效机理研究提供更丰富的数据支撑。表 1 展示了 CMAPSS 数据集中的发动机和子样本数的相关信息。其中包括了来自 21 个传感器的退化信息, 涵盖了温度、压力、速度等多方面的数据。

表 1 航空发动机数据集

数据状况	FD001	FD002	FD003	FD004
训练集发动机台数	100	260	100	249
测试集发动机台数	100	259	100	248
操作模式	1	6	1	6
故障模式	1	1	2	2
训练样本	20 630	53 759	24 720	61 249
测试样本	13 095	33 991	16 595	41 214

2.2 实验设置

2.2.1 传感器相关性分析

在对 FD001 子集的发动机性能退化模拟分析时, 观察到部分传感器的数据在整个仿真周期内保持恒定, 这表明这些传感器的输出不随发动机状态的变化而变化, 因此在进行剩余使用寿命预测时, 这些数据对模型的训练和预测精度提升无显著帮助。如图 6 所示, 编号为 1、5、6、10、16、18 和 19 的传感器数据在所有时间点上几乎没有变化, 表明这些传感器输出的是噪声数据或常数, 不适宜用于预测模型。为确保模型预测的效率和精度, 对所有数据集的训练过程中排除这些无变化的传感器数据, 仅使用符合训练标准的传感器的信号作




图 6 FD001 子集不同传感器监测数据直方图

为模型输入。这样的处理不仅可以减少模型训练的计算负担, 还可以避免模型在训练过程中过多关注无关特征, 从而提高运算效率和预测精度。

具体来说, 保留的传感器包括 T24 (低压压气机出口温度)、T30 (高压压气机出口温度)、T50 (低压涡轮出口温度)、P30 (高压压气机出口压力)、Nf (物理风扇速度)、Nc (物理核心速度)、Ps30 (高压压气机出口静压)、phi (燃油流量比)、NRf (校正风扇速度)、NRc (校正核心速度)、BPR (旁通比)、htBleed (漏气焓)、W31 (高压涡轮冷却剂泄漏)、W32 (低压涡轮冷却剂泄漏)。通过对多个传感器监测数据进行进一步的重要性排序和筛选, 可以为深度学习模型提供最优的输入特征组合, 进一步提升模型对发动机剩余使用寿命的预测能力。

2.2.2 训练标签设置

CMAPSS 包括了多个工作循环的发动机运行设定以及传感器监控的数据。在数据预处理环节, 剔除发动机老化时未改变的运行参数及传感器参数, 以增强算法的稳定性, 降低噪音的影响, 实现对发动机性能及衰退状态的精确分析与研究。通过使用有效的原始数据, 并将其按照 8:2 的比例分成了训练集和验证集。在初期可以观察到其良好的性能, 因此可以暂时忽略性能退化的影响。在运行过程中发动机的各项指标会较于初期出现衰退的情况, 为了标定运行数据, 将标签设定为总运行周期数与当前运行周期数之差。然而, 这种设定会降低剩余使用寿命的预测效率, 针对这个问题, 采用一种新的分片线性退化模型的 RUL 标记的设计方案^[23]。

在初始阶段, 发动机在平稳工况下, 其剩余寿命基本恒定。在训练集中, RUL 标记被设置为 130 次循环的阈值。当发动机进入衰退期后, 剩余寿命基本上是直线减小的。通过分析, 得出在 130 个运转周期内, 可获得良好的预报结果。这一设置结果如图 7 所示。




图 7 分段线性退化图

2.2.3 参数设置

在训练过程中, 使用 Adam 优化器更新模型参数, 采用早停的正则化训练策略, 以避免模型出现过拟合现

象, 通过这样的训练方式可以更充分地挖掘退化数据, 具体的超参数设置如表 2 所示。

表 2 模型超参数设置

模型参数	描述	值
hidden _s ize	隐藏层大小	200
<i>k</i>	显著周期数	30
<i>lr</i>	学习率	4e ⁻³
batch _s ize	输入数据批量	64
epochs	训练轮数	300

2.2.4 评估指标

在此基础上, 利用均方根误差 (RMSE) 和非对称评分函数 (score) 两种方法, 对 STA-DF 算法的估计效果进行客观分析。RMSE 定义如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{r}_i - r_i)^2}$$
 (27)

式中, *N* 是样本总数, $\hat{r}_i$ 是预测结果, *r_i* 是真实值。较低的 RMSE 代表较低的估计误差和较高的估计精度。非对称评分函数的计算方法如下:

$$score = \begin{cases} \sum_{i=1}^N (e^{\hat{r}_i - r_i/13} - 1), & if(\hat{r}_i - r_i < 0) \\ \sum_{i=1}^N (e^{\hat{r}_i - r_i/10} - 1), & if(\hat{r}_i - r_i \geq 0) \end{cases}$$
 (28)

通常情况下, RUL 预测方法的性能越好所得到的 score 分值就会越低。

2.3 预测结果分析

2.3.1 单个样本预测结果分析

从 CMAPSS 的 4 个子集中随机选取 32、19、54 和 92 号样本, 通过测试得到输出结果如图 8 所示, 实线代表真实值, 虚线代表预测值。随着运行周期的增加, 4 种测试样本的 RUL 预测相较于实际值的波动幅度收敛, 表明设备的退化表征会随着使用时间逐渐显现。所提出的模型能够根据关键的退化时间节点去高效率获取设备的故障特征, 从监测数据中更精准地捕获隐藏的退化信息, 并作出精确的预测。

2.3.2 所有发动机预测结果分析

图 9 展示了针对 FD001、FD002、FD003 和 FD004 四种发动机测试集的剩余寿命预测结果。虽然所使用的数据集中发动机工况各不相同, 但所得到的结果却十分接近真实的 RUL。FD001 和 FD003 两个子集对单个早期工作状态的 RUL 精度不高, 但对发动机后期预测精度较高。在大型设备运行过程中, 对其剩余寿命进行精确的预测, 可以有效地防止或降低因常见或未知故障所造成的损失, 在运行方案上做出更加合理的预防维修决策。在 FD002 和 FD004 两个子集中, 本文方法能够更好地处理不同工况和不同故障的问题, 特别是在设备运行后期可以精准捕获衰退信息。对于设备寿命方面, 很小的预测误差都会造成严重后果, 因此这更适应于实际工




图 8 4 种发动机单个样本 RUL 预测结果




图 9 测试集 RUL 预测结果

程需求。

2.4 消融实验

2.4.1 时空信息联合嵌入网络影响分析

为验证提出的基于时空信息联合嵌入网络的有效性,设计了以下两组消融实验:一组剔除了空间特征信息提取模块,记作 TA-DF;另一组剔除了时间序列信息提取模块,记作 SA-DF。如表 3 所示,本文提出方法与 TA-DF 相比, RMSE 和 Score 评估值在 CMAPSS 数据集上的 4 个子集上分别降低了 3.52% 和 6.51%、1.53% 和 9.37%、6.03% 和 10.50%、8.53% 和 11.03%,验证了本文提出方法的空间特征信息提取模块更关注捕捉特征中的空间关系,提升模型对时序数据中动态特征的处理能力。相对于 SA-DF 方法,本文提出方法的 RMSE 和 Score 评估值分别降低了 10.36% 和

10.19%、5.28% 和 15.17%、6.68% 和 19.18%、10.22% 和 14.53%,验证了本文提出方法中的时间序列信息提取模块可以更好地捕捉时序数据中的依赖关系,提升模型整体的预测结果。通过上述实验分析可以观察到,本文提出方法中所引入的时空信息联合嵌入网络旨在从时空两个维度挖掘退化特性,在各阶段通过对多维数据的空间关联分析,从多维数据中挖掘出与降质信号关联程度较高的关键特征,通过有效地融合时间序列和空间特征信息,模型能够更精准地捕捉数据中的关键退化特性,显著提升了对关联性高的传感器数据的特征提取能力。这些实验结果验证了所提出方法的有效性,表明它能够更好地解决当前发动机剩余寿命预测方法中对多传感器数据利用率不足的问题。

表 3 时空信息联合嵌入网络消融实验结果								
方法	FD001		FD002		FD003		FD004	
	RMSE	Score	RMSE	Score	RMSE	Score	RMSE	Score
TA-DF	11.92	208.78	16.94	1 497.81	12.93	244.45	19.12	2 553.24
SA-DF	12.83	217.32	17.61	1 600.19	13.02	270.71	19.48	2 657.95
STA-DF	11.50	195.17	16.68	1 357.34	12.15	218.78	17.49	2 271.68

2.4.2 离散融合学习变分网络影响分析

为了验证提出的基于注意力的离散融合变分自编码网络的有效性,设计了以下 3 组消融实验:第一组剔除了 DFVAE 模块和融合注意力模块,记作 STA-BiLSTM;第二组将 STA-DF 中的 DFVAE 模块替换为 VAE,保留融合注意力模块,记作 STA-FAE;第三组剔除了融合注意力模块,保留 DFVAE 模块,记作 STA-DAE。如表 4 所示,本文提出方法与 STA-BiLSTM 相比, RMSE 和 Score 评估值在 CMAPSS 数据集上的 4 个子集上均降低了 12.01%和 15.56%、20.31%和 22.67%、25.50%和 24.77%、22.84%和 24.59%,可以观察到剔除 DFVAE 模块和融合注意力模块的结果明显低于其它 3 组实验的评估值,说明通过离散化学习对并行特征进行融合能够使模型更准确的处理退化数据中的关键信息,因此,相较于未进行融合的方法,本方法在实验中取得了更高的预测精度。相对于 STA-FAE 方法,本文提出方法的 RMSE 和 Score 评估值分别降低了 10.85%和 9.87%、5.54%和 7.90%、17.46%和 16.73%、10.12%和 13.11%,验证了本文提出的编码器在基于注意力的离散融合学习网络中能够更好地捕捉特征分布中关联信息并进行特征融合,相较于 VAE 更适用于处理时序类型数据,其中本文提出方法在数据量较少的 FD003 的实验结果表现较好,结合数据复杂度高的 FD002 和 FD004 的实验结果侧面表明基于注意力的离散融合学习网络对复杂环境下的数据处理结果更优,因此,本文提出方法能够将数据与各个维度间的相关性进行映射,有效地减少数据的过拟合。

表 4 基于离散融合学习消融实验结果

方法	FD001		FD002		FD003		FD004	
	RMSE	Score	RMSE	Score	RMSE	Score	RMSE	Score
STA-BiLSTM	13.07	231.14	20.93	1 755.46	16.31	290.85	22.67	3 012.77
STA-FAE	12.90	216.56	17.66	1 473.92	14.72	262.74	19.46	2 614.47
STA-DAE	12.87	211.95	19.07	1 690.29	13.53	236.87	20.62	2 591.43
STA-DF	11.50	195.17	16.68	1 357.34	12.15	218.78	17.49	2 271.68

相对于 STA-DAE 方法,本文提出方法的 RMSE 和 Score 评估值降低了 10.64%和 7.92%、12.53%和 19.69%、10.19%和 7.64%、15.17%和 12.34%,验

证了本文提出的融合注意力模块通过上下层并行融合的方式,对两段经过离散编码空间处理后的时空退化特征进行有效融合,提升了模型的预测精度。

综上所述, DFVAE 不仅解决了高维冗余数据特征提取困难的问题,还显著提升了发动机剩余寿命预测的准确性和鲁棒性,进一步证明了本文提出方法的有效性和实用性。

3 对比实验

为证明 STA-DF 网络的效能,将本文方法与 CNN^[24]、LSTM^[25]、基于注意力的 LSTM-A 模型^[26]、基于注意力的 BiLSTM-A 模型^[27]、基于注意力的 AGCNN 模型^[28]、基于注意力和残差卷积的 RCNN-ABiLSTM 模型^[29]、TCN^[30]进行对比实验,实验结果如表 5 所示。STA-DF 在相同数据集下 RMSE 和 Score 值相较于目前最优方法降低 1.86%。本文提出的时空信息联合嵌入网络通过时间序列信息提取模块和空间信息特征提取模块分别提取时间序列和空间特征,将它们有效地结合起来,使得模型能够全面捕捉数据中的时序动态和空间关联,并且更好地理解多传感器数据中的内在关系,从而达到充分利用多传感器数据的效果。此外,基于注意力融合的离散变分自编码网络通过引入码书映射和上下层融合注意力机制对复杂的高维数据进行离散化处理,并剔除其中的噪声数据,接着对得到的多尺度退化信息并行融合处理,从而提高了特征提取的精度和效率。

表 5 对比实验结果

方法	FD001		FD002		FD003		FD004	
	RMSE	Score	RMSE	Score	RMSE	Score	RMSE	Score
CNN ^[24]	12.21	240.66	17.90	1 442.41	12.51	338.59	20.74	2 455.78
LSTM ^[25]	12.39	232.22	16.97	1 545.74	12.45	378.45	19.63	2 548.54
LSTM-A ^[26]	12.41	212.33	17.71	1 599.72	13.21	321.57	18.57	2 518.78
TCN ^[27]	12.46	231.14	17.30	1 565.47	13.47	287.12	18.27	2 565.65
BiLSTM-A ^[28]	12.44	244.30	16.90	1 433.24	13.35	321.52	18.93	2 478.47
AGCNN ^[29]	11.81	210.52	17.11	1 525.65	12.62	342.41	18.52	2 451.78
RCNN-ABiLSTM ^[30]	12.33	208.47	17.54	1 378.54	12.47	355.87	18.78	2 597.51
STA-DF	11.50	195.17	16.68	1 357.34	12.15	218.78	17.49	2 271.68

4 结束语

本文介绍了一种基于时空信息联合嵌入和离散融合学习的发动机剩余寿命预测模型,针对缺乏对多传感器信息的有效利用和目前剩余寿命预测方法难以有效地提取出高维冗余数据特征的问题,从时序数据中的时序关系和空间关系、高维数据中退化特征的复杂相关性两个方面进行研究,利用时空信息联合嵌入策略更好地捕捉时序数据间的时空关系突出重要特征区域,然后通过基

于注意力的离散融合变分自编码网络并行融合时序与空间特征,实现对剩余使用寿命的预测。通过在 CMAPSS 数据集上的测试,所提出的 STA-DF 模型比多种主流方法更准确。未来将进一步开展多故障、复杂工作条件下的剩余寿命预测方法研究,并且将综合考虑各种工况条件对设备性能的影响。

参考文献:

- [1] 李彦夫, 韩 特. 基于深度学习的工业装备 PHM 研究综述 [J]. 振动. 测试与诊断, 2022, 42 (5): 835-847.
- [2] 刘国建, 杜 冬, 邢苗英, 等. 基于机器学习的航空发动机剩余寿命预测综述 [J]. 电子技术, 2023, 52 (1): 52-53.
- [3] PREDRAG T, ZELJKO D. Particle filtering for sensor fault diagnosis and identification in nonlinear plants [J]. Journal of Process Control, 2014, 24 (4): 401-409.
- [4] LIONEL B, YOUN T C, NORMAN M W. Electro-rheological damper analysis using an Eyring constitutive relationship [J]. Journal of Intelligent Material Systems and Structures, 2002, 13: 633-639.
- [5] BUZZONI M, DELIA G, COCCONCELLI M. A tool for validating and benchmarking signal processing techniques applied to machine diagnosis [J]. Mechanical Systems and Signal Processing, 2020, 139: 106618.
- [6] 马 波, 翟 斌, 彭 琦, 等. 基于不同退化阶段状态空间模型及粒子滤波的滚动轴承寿命预测 [J]. 北京化工大学学报 (自然科学版), 2017, 44 (3): 81-86.
- [7] 王卫国. 轮盘低循环疲劳寿命预测模型和试验评估方法研究 [D]. 南京: 南京航空航天大学, 2006.
- [8] 张金豹, 邹天刚, 王 敏, 等. 滚动轴承剩余使用寿命预测综述 [J]. 机械科学与技术, 2023, 42 (1): 1-23.
- [9] SHI H J, XUE S D. Degraded data-driven online prediction of equipment remaining life [J]. Computer Engineering and Applications, 2016, 52 (23): 249-254.
- [10] 孙 頌. 基于数据驱动方法的发动机剩余寿命预测研究 [D]. 徐州: 中国矿业大学, 2023.
- [11] 何 群, 李 磊, 江国乾, 等. 基于 PCA 和多变量极限学习机的轴承剩余寿命预测 [J]. 中国机械工程, 2014, 25 (7): 984-989.
- [12] 王 烨, 左洪福, 蔡 景, 等. 基于 Bayesian 推断和 LS-SVM 的发动机在翼寿命预测模型 [J]. 南京理工大学学报, 2013, 37 (6): 955-959.
- [13] 刘帅君. 基于性能退化数据的航空发动机剩余寿命预测 [D]. 成都: 电子科技大学, 2016.
- [14] 徐洲常, 王林军, 刘 洋, 等. 采用改进回归型支持向量机的滚动轴承剩余寿命预测方法 [J]. 西安交通大学学报, 2022, 56 (3): 197-205.
- [15] 李路云, 王海瑞, 朱贵富. 改进 1D-CNN 和 LSTM 的涡扇发动机剩余寿命预测 [J]. 热能动力工程, 2023, 38 (7): 194-202.
- [16] 陈 哲. 基于长时间序列分析的滚动轴承剩余使用寿命预测方法研究 [D]. 石家庄: 石家庄铁道大学, 2023.
- [17] 张继冬, 邹益胜, 蒋雨良, 等. 基于全卷积变分自编码网络 FCVAE 的轴承剩余寿命预测方法 [J]. 振动与冲击, 2020, 39 (19): 13-18.
- [18] 徐硕, 侯贵生. 基于 VAE-D2GAN 的涡扇发动机剩余使用寿命预测 [J]. 计算机集成制造系统, 2022, 28 (2): 417-425.
- [19] LI Y C, LI W X, LEI Y J. Residual life prediction of turbopfan engine based on feature enhancement and spatiotemporal information embedding [J]. Application Research of Computers, 2024, 41 (4): 1001-1007.
- [20] 徐 浩, 王 波, 张 猛, 等. 基于双向门控变分编码回归网络的涡扇发动机剩余寿命预测 [J]. 计算机集成制造系统, 2025, 31 (2): 616-626.
- [21] 杨宜满, 郭群勇. 考虑注意力和时空特征深度学习的网约车行程时间预测 [J]. 福州大学学报 (自然科学版), 2023, 51 (3): 340-346.
- [22] SAXENA A, GOEBEL K, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation [C] // 2008 International Conference on Prognostics and Health Management. Piscataway, NJ: IEEE Press, 2008: 1-9.
- [23] LI X, DING Q, SUN J. Remaining useful life estimation in prognostics using deep convolution neural networks [J]. Reliability Engineering & System Safety, 2018, 172: 1-11.
- [24] 马 忠, 郭建胜, 顾涛勇, 等. 基于改进卷积神经网络的航空发动机剩余寿命预测 [J]. 空军工程大学学报 (自然科学版), 2020, 21 (6): 19-25.
- [25] 王朋凯, 张新燕, 张光昊. 基于 ResNet-Bi-LSTM-Attention 的锂离子电池剩余使用寿命预测 [J]. 储能科学与技术, 2023, 12 (4): 1215-1222.
- [26] 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.
- [27] 杨智勇, 叶玉玺, 周 瑜. 基于 BiLSTM-SA-TCN 时间序列模型在股票预测中的应用 [J]. 南京信息工程大学学报 (自然科学版), 2023, 15 (6): 643-651.
- [28] 赵志宏, 李 晴, 杨绍普, 等. 基于 BiLSTM 与注意力机制的剩余使用寿命预测研究 [J]. 振动与冲击, 2022, 41 (6): 44-50.
- [29] 蔡 勇. 基于 CNN-GRU 的滚动轴承寿命预测 [J]. 机械工程与自动化, 2023, 236 (1): 143-145.
- [30] YAN X J, LIANG W, ZHANG G, et al. Prediction method for mechanical equipment based on RCNN-ABiLSTM [J]. Systems Engineering and Electronics, 1-12.