



基于贝叶斯图注意力Transformer的航空发动机剩余使用寿命概率预测

胡艳艳 白雅婷

Probabilistic prediction of aero engine remaining useful life based on Bayesian graph attention transformer

HU Yanyan, BAI Yating

引用本文:

胡艳艳, 白雅婷. 基于贝叶斯图注意力Transformer的航空发动机剩余使用寿命概率预测[J]. 北科大: 工程科学学报, 2025, 47(2): 374–388. doi: 10.13374/j.issn2095–9389.2024.05.30.003

HU Yanyan, BAI Yating. Probabilistic prediction of aero engine remaining useful life based on Bayesian graph attention transformer[J]. *Chinese Journal of Engineering*, 2025, 47(2): 374–388. doi: 10.13374/j.issn2095–9389.2024.05.30.003

在线阅读 View online: <https://doi.org/10.13374/j.issn2095–9389.2024.05.30.003>

您可能感兴趣的其他文章

Articles you may be interested in

航空发动机阻燃钛合金力学性能预测及成分优化

Predicting the mechanical properties and composition optimization of a burn-resistant titanium alloy for aero-engines
工程科学学报. 2022, 44(6): 1036 <https://doi.org/10.13374/j.issn2095–9389.2020.10.12.001>

基于集成神经网络的剩余寿命预测

Remaining useful life prediction based on an integrated neural network
工程科学学报. 2020, 42(10): 1372 <https://doi.org/10.13374/j.issn2095–9389.2019.10.10.005>

基于NARX动态神经网络的锂离子电池剩余寿命间接预测

An indirect remaining useful life prediction of lithium-ion batteries based on a NARX dynamic neural network
工程科学学报. 2022, 44(3): 380 <https://doi.org/10.13374/j.issn2095–9389.2020.10.22.005>

基于深度学习的装备剩余寿命区间预测研究进展

Research progress on remaining useful life interval prediction of equipment based on deep learning
工程科学学报. 2024, 46(4): 723 <https://doi.org/10.13374/j.issn2095–9389.2023.06.19.003>

基于改进GWOSVR算法的锂电池剩余寿命预测

Remaining useful life prediction for lithium-ion batteries based on an improved GWOSVR algorithm
工程科学学报. 2024, 46(3): 514 <https://doi.org/10.13374/j.issn2095–9389.2023.05.31.002>

等效循环电池组剩余使用寿命预测

Investigation of RUL prediction of lithium-ion battery equivalent cycle battery pack
工程科学学报. 2020, 42(6): 796 <https://doi.org/10.13374/j.issn2095–9389.2019.07.03.003>

基于贝叶斯图注意力 Transformer 的航空发动机剩余使用寿命概率预测

胡艳艳[✉], 白雅婷

北京科技大学智能科学与技术学院, 北京 100083

[✉]通信作者, E-mail: huyanyan@ustb.edu.cn

摘要 航空发动机作为飞机的心脏, 其健康状态对飞机的安全飞行至关重要. 深度学习强大的数据挖掘能力, 为通过海量历史数据预测航空发动机的剩余使用寿命提供了新方法. 然而, 传统基于深度学习的方法大都关注于挖掘数据在时间上的关联, 而忽略了多个传感器监测数据之间复杂的非欧氏空间关系. 此外, 少有研究考虑数据或者预测过程本身具有的不确定性, 缺乏对预测结果可靠性的评估. 为解决上述问题, 本文提出了一种基于贝叶斯网络和图注意力 Transformer 的航空发动机剩余使用寿命概率预测方法. 将图注意力机制融入 Transformer 的时间多头注意力模块, 结合图注意力网络在空间特征提取上的优势和 Transformer 模型在时间特征提取的优势, 实现数据特征时空关系的联合提取. 同时, 利用改进的贝叶斯网络度量预测不确定性, 在得到剩余使用寿命预测点值的同时给出相应的置信区间. 最后, 通过在公开航空发动机数据集上的实验, 证明了所提模型的有效性和先进性.

关键词 航空发动机; 剩余使用寿命; 图注意力 Transformer; 贝叶斯网络; 概率预测

分类号 TG142.71

Probabilistic prediction of aero engine remaining useful life based on Bayesian graph attention transformer

HU Yanyan[✉], BAI Yating

School of Intelligence Science and Technology, University of Science and Technology Beijing, Beijing 100083, China

[✉]Corresponding author, E-mail: huyanyan@ustb.edu.cn

ABSTRACT The aero engine is crucial for the safe flight of aircraft. Predicting its remaining useful life allows for timely maintenance, thereby preventing potential flight accidents. Deep learning's powerful data mining capabilities provide a novel approach to predicting the remaining useful life of aero engines using vast amounts of historical data. However, traditional deep learning methods often only analyze temporal data correlations, overlooking the complex non-Euclidian spatial relationship between multiple sensor data. In addition, they seldom address the uncertainties in data or the prediction process, which impacts the reliability of their results. To solve these problems, we propose a probabilistic prediction method for aero engines that leverages Bayesian networks and the graph attention transformer. First, sensor data undergo preprocessing using a convolutional denoising autoencoder. Then, to extract the complex non-Euclidian spatial relationships between sensors, we construct a graph convolution network. In this network, sensor signal features serve as node characteristics, and the relationships between sensors are measured by cosine similarity. An attention mechanism assigns different weights to sensor nodes to improve the expressive ability of the graph convolution network. In this paper, the multi-head attention is integrated into the graph convolution network. Following the integration, node characteristics are aggregated with the

收稿日期: 2024-05-30

基金项目: 国家自然科学基金资助项目(62273038, U21A20483)

assigned weights in the proposed graph attention network. Furthermore, to achieve joint extraction of the spatiotemporal relationships of sensor data, the graph attention mechanism is integrated into the transformer's temporal-multi-attention module. This integration combines the spatial feature extraction strengths of the graph attention transformer with the temporal feature extraction abilities of the transformer model. The extracted spatiotemporal joint features are often utilized to predict the remaining useful life of the aero engine. At the same time, a Bayesian network quantifies the prediction uncertainty of the model using Gaussian mixture distribution and variational inference. Optimal approximate distribution parameters are obtained by minimizing the Kullback–Leibler divergence between the real posterior and approximate distributions. Consequently, the loss function of the proposed model network consists of two parts: minimum mean square error, which reflects the distance between the predicted remaining useful life and the actual remaining useful life, and distribution approximation error measured by Kullback–Leibler divergence. Unlike traditional point value predictions, our probabilistic prediction method yields not only an estimated remaining useful life but also a corresponding confidence interval, which provides a more reliable foundation for subsequent maintenance and decision-making. In addition, we validated the proposed method using an aero engine experimental dataset, comparing its performance against other methods through both comparative and ablation experiments. The results demonstrate the effectiveness of the proposed method and its superiority over existing methods.

KEY WORDS aero engine; remaining useful life; graph attention transformer; Bayesian neural network; probabilistic prediction

航空发动机作为飞机的动力装置,其健康状况对保证飞机的安全飞行至关重要.由于航空发动机结构复杂,且长期在高温高压高速的恶劣环境下工作,极易发生故障.如果得不到及时的维护或更换,将会造成重大飞行安全事故.剩余使用寿命预测(Remaining useful life, RUL)是设备预防性维护中的关键问题,因此航空发动机的RUL预测具有重要意义.

目前,国内外对于航空发动机RUL预测的研究已经取得了很多成果,主要的预测方法可分为两大类:基于模型的方法和数据驱动的方法^[1-3].基于模型的RUL预测方法在很大程度上依赖于设备的运行退化机制,以此来建立物理预测模型^[4-5].然而,对于航空发动机这样的复杂大型装备,很难建立准确的物理预测模型.因此,基于物理模型的方法在航空发动机RUL预测中的应用受到了诸多限制^[6].与基于模型的方法相比,数据驱动的方法不需要了解系统的内部机制和操作原理,只需要使用相关技术挖掘历史退化数据与RUL之间的关系,即可实现对设备RUL进行预测的目的.近年来,随着深度学习技术的迅猛发展,基于深度学习的数据驱动RUL预测方法已成为航空发动机RUL预测的主流.

卷积神经网络(Convolutional neural network, CNN)是一种被广泛应用于特征提取的深度学习网络.基于CNN的RUL预测方法主要利用感受野学习传感器数据与RUL之间的关系,以得到RUL预测结果.Li等^[7]利用CNN在高级抽象特征方面的突出能力,提出了一种应用于航空发动机RUL预测的深度卷积神经网络(Deep CNN, DCNN)模

型.Xu等^[8]首先构建并行的一维CNN模型和相应的池化层,从多路信号中进行特征提取和融合,进而利用具有残差连接和注意力机制的扩张卷积处理来自池化层的特征,并设计回归层实现RUL的预测.Ma等^[9]提出了一种基于多尺度高效通道注意力CNN和GRU网络的混合架构,并构造了震动信号Gram角度差场(GADF)图像,利用图像识别方案完成RUL预测.CNN虽然可以用于深层特征的提取,但是无法有效兼顾历史数据之间的关联,因此并不擅长处理时间序列问题.

时间卷积网络(Temporal convolutional networks, TCN)在传统卷积神经网络的基础上引入膨胀卷积和因果卷积,具有更灵活的感受野和更稳定的梯度.Yu等^[10]使用变分自编码器(Variational auto-encoder, VAE)从原始传感器数据中提取低维特征,然后使用TCN捕获历史退化信息,最终预测航空发动机的RUL.Chen等^[11]提出了一种新的基于贝叶斯优化的对抗性TCN,将TCN嵌入对抗性训练框架作为生成器,以减少RUL预测的误差.Xu等^[12]提出了一种结合多尺度时间卷积网络和自注意力及全局融合注意力的端到端框架,用于提高RUL预测的准确性.Guo等^[13]提出了一种基于TCN和卷积双向门控循环单元与多时间窗口的堆叠集成的方法用于RUL预测,该方法具有更小的集成维度和更强的可靠性与适应性.Yao等^[14]设计了一种基于卷积神经网络构建的新型PatchTCN层模型,该模型能够将时间序列分割成补丁级子序列,并充分提取这些补丁之间和内部的潜在退化语义信息,从而显著提高模型RUL预测能力.虽然TCN相比于CNN更关注多尺度信息提取,但由

于其是在 CNN 基础上进行的改进, 因此仍存在感受野受限和梯度爆炸等问题。

循环神经网络 (Recurrent neural network, RNN) 的记忆能力使其在处理时间序列问题上具有独特的优势。在 RUL 预测领域中, 常用的 RNN 包括长短期记忆网络 (Long short-term memory, LSTM) 和门控循环单元 (Gated recurrent unit, GRU)。Wang 等^[15]提出了一种新的基于双向 LSTM 网络的 RUL 预测方法, 该方法可以充分挖掘传感器数据的时序信息, 实现双向提取特征。Liu 等^[16]融合了 LSTM 和聚类分析的优点, 提出了一种改进的多阶段 LSTM 模型, 用于航空发动机 RUL 预测。郭晓静等^[17]构建了一种注意力机制与 LSTM 融合的深度学习方法。分析多元高维的运行参数与 RUL 之间的协方差相关性, 实现数据降维并利用运行参数的时序退化特性提高模型的回归预测效果。与 LSTM 相比, GRU 拥有更简单的结构, 特征提取能力也并不逊于 LSTM。Zhang 等^[18]针对航空发动机 RUL 预测中操作条件改变引起的变工况问题, 提出了一种基于密度聚类和 GRU 网络的变工况 RUL 预测框架。其中, 基于密度的聚类算法作为分类器用于以无监督的方式对操作条件进行聚类 and 识别, 进而将传感器数据特征和工况特征相结合, 利用 GRU 网络实现 RUL 预测。Zhong 等^[19]利用 GRU 对于航空发动机的废气温度进行预测, 然后通过废气温度与航空发动机 RUL 之间的关系实现 RUL 的预测。虽然 GRU 和 LSTM 在剩余使用寿命预测中得到了大量应用, 但在长时间序列相关性提取能力上仍显不足。

Transformer 网络使用自注意力机制提取序列的时间信息, 有效缓解了梯度爆炸等问题, 近年来受到广泛关注。Zhang 等^[20]提出一种面向航空发动机 RUL 预测的自适应剪枝 Transformer。该方法使用范数信息来评估模型中每个元素对输出的贡献, 然后利用结构化修剪来消除不重要的冗余元素, 以综合考虑 RUL 预测的准确性和效率。Li 等^[21]提出一种 Transformer 深度可分离卷积神经网络预测模型, 在所提出的方法中, 建立了一种具有 Value 分支卷积变换的概率稀疏自注意力机制, 更好的提取数据特征。

如上所述, 虽然已有工作将 Transformer 模型成功应用于航空发动机 RUL 预测, 但是这些方法基本上是将多传感器之间空间关系建模为欧氏空间简单的线性关系, 难以有效反映多传感器之间复杂的相互影响。此外, 已有工作较少考虑数据中

的噪声或者预测过程本身的不确定性, 缺乏对预测结果可靠性的评估^[22-23]。为解决上述问题, 本文提出了一种基于贝叶斯神经网络和图注意力 Transformer 的 RUL 概率预测方法。本文创新点主要包括:

(1) 将图注意力网络 (Graph attention network, GAT) 融入 Transformer 的时间多头注意力模块, 构建数据的时空融合图, 同时分析数据时间关系和非欧氏空间关系, 实现数据特征时空关系的联合提取。

(2) 利用改进的贝叶斯神经网络对不确定性进行分析, 在获得 RUL 预测点值的同时给出相应的置信区间, 从而为后续决策提供更加可靠的依据。

(3) 利用公开数据集对所提出的方法进行了验证, 并与其他几种先进模型进行了对比。对比实验和消融实验结果验证了所提出方法的有效性和相比于其他模型的优越性。

1 模型整体框架

以往的研究中通常将不同传感器数据建模为欧氏空间简单的线性关系, 从而制约着预测精度。基于此, 本文创新性地将 GAT 与 Transformer 模型相结合。借助 GAT 网络建模不同传感器间的非欧氏空间依赖性, 并将 GAT 融入 Transformer 的时间多头注意力模块, 得到 GAT-Transformer 架构, 实现数据特征时空关系的联合提取。同时, 利用改进的贝叶斯网络对预测地不确定性进行度量, 并通过将贝叶斯网络的单一高斯先验分布变为混合高斯分布提高网络的分布拟合能力, 进一步提升了预测精度。本文所提出的基于贝叶斯网络 GAT-Transformer 的 RUL 概率预测模型框架如图 1 所示。

如图 1 中所示, 考虑到数据对 RUL 预测结果的影响, 我们在模型中增加了数据预处理模块。首先, 使用卷积自编码器 (Convolutional denoising autoencoder, CDAE)^[24]来降低数据的噪声。CDAE 将传统自编码器的全连接层转化为卷积层, 更助于提取大量数据的深度特征, 提高网络表达能力, 提高数据处理的可靠性。其次, 采用最小-最大归一化方法对数据进行处理, 以消除奇异数据对 RUL 预测带来的影响。然后, 将所有传感器数据划分为多个滑动时间窗口数据以减少信息丢失。最后, 通过一维卷积初步提取特征, 得到输入特征矩阵。

2 GAT 网络构建

图神经网络^[25](Graph neural network, GNN) 由于能够将数据构造成图的形式提取数据特征之间




图1 基于贝叶斯 GAT-Transformer 的剩余使用寿命概率预测框架

Fig.1 Remaining useful life probability prediction framework based on the Bayesian network and GAT-Transformer

的非欧氏空间等复杂关系,近年来得到了广泛的应用.图卷积网络(Graph convolutional network, GCN)在普通图网络的基础上进行了改进,引入卷积操作提取深层次特征,提高了图网络的性能. GAT是在 GCN 基础上的又一次改进,引入注意力机制不仅能够建立不同特征之间的关系,还能为不同特征分配不同权重,提高网络的表征能力. GAT 中每个节点的状态更新会考虑到其邻居节点的状态,计算每个节点与其邻居节点之间的注意力权重,根据这个权重来更新节点的状态,构造新的输入数据.

GAT 网络的构建是应用 GAT 网络的核心,本文中 GAT 网络的构建过程如图 2 所示,图中圆形代表传感器节点.

首先,截取滑动长度的数据分别构造 GAT 网络.假设输入数据由 S 个传感器节点组成,每个传感器节点有 D 维特征,输入特征矩阵 $\mathbf{Z} = \{z_1, z_2, \dots, z_S\}$, $\mathbf{Z} \in \mathbf{R}^{S \times D}$,传感器节点 i 和 j 特征之间的余弦相似度计算如下:

$$s_{i,j} = \frac{z_i^T z_j}{\|z_i\| \cdot \|z_j\|}, i, j \in S \quad (1)$$

其中, $s_{i,j}$ 代表余弦相似度, z_i 和 z_j 是特征矩阵值.当两个节点之间的余弦相似度值大于 0,认为这两个节点是有关联的,并依此确定每个传感器节点的邻居节点.

其次,使用注意力机制为不同邻居节点分配不同权重.为了提高注意力机制的表达能力,本文中使用了多头注意力机制.多头注意力机制是利用自注意力机制从不同的角度对输入数据进行独立的注意力学习,最后将多个注意力头获得的特征进行拼接得到最终的输出,如图 2 所示.图中自注意力机制的整体计算公式如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}}\right)\mathbf{V} \quad (2)$$

其中, \mathbf{Q} 为查询矩阵, \mathbf{K} 为键矩阵, \mathbf{V} 为值矩阵, d 为输入模型的维度.

多头注意力机制是在多个注意头上获取权重信息后,再将多个注意头进行拼接得到最终注意力系数,如式 (3) 和式 (4) 所示:

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_m)\mathbf{W} \quad (3)$$

$$\text{head}_i = \text{Attention}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) \quad (4)$$

其中, \mathbf{W} 表示多头注意力机制的参数矩阵, m 指多头注意力机制的头数.

利用 GAT 网络聚合邻居节点特征的具体过程如图 3 所示.以某一输入层为例,假设该层输入特征矩阵为 $\mathbf{h} = \{h_1, h_2, \dots, h_S\}$,其中 $h_i \in \mathbf{R}^D$ 表示第 i 个节点的特征.网络的聚合过程需要对每个传感器节点逐个计算其邻域中所有节点的注意力系数.具体地,将节点 i 及其邻域中的节点 j 的特征使用




图 2 GAT 网络构建过程

Fig.2 GAT network's construction process




图 3 注意力分数计算原理图

Fig.3 Schematic diagram of attention score calculation

一个共享的可学习变换矩阵 W 进行变换, 并将其拼接形成一个高维特征向量, 最后将拼接后的高维特征通过可学习向量 a 映射到一个实数上, 上述过程如下式所示:

$$e_{i,j} = a([Wh_i || Wh_j]), i, j \in S \quad (5)$$

其中, $[\cdot || \cdot]$ 表示将变换后的特征进行拼接, $a(\cdot)$ 表示相应的高维特征映射. 然后, 使用非线性激活函

数 LeakyReLU 处理 $e_{i,j}$, 得到注意系数. 同时为了方便不同节点间的系数进行比较, 使用 softmax 函数对系数进行归一化, 归一化后的注意系数 $\alpha_{i,j}$ 为:

$$\alpha_{i,j} = \frac{\exp(\text{LeakyReLU}(e_{i,j}))}{\sum_{k \in U_i} \exp(\text{LeakyReLU}(e_{i,k}))} \quad (6)$$

最后, 将归一化后的注意系数作为权值, 计算

邻域 U_i 中所有特征的加权和, 作为更新后节点的最最终输出特征. 如式 (7) 所示.

$$\vec{h}_i = \sigma \left(\sum_{j \in U_i} \alpha_{i,j} \mathbf{W} \mathbf{h}_j \right) \quad (7)$$

其中, \vec{h}_i 是经过注意力机制处理后的新特征, $\sigma(\cdot)$ 指的是激活函数.

3 GAT-Transformer 结构设计

Transformer 模型擅长挖掘数据的时间关联性, 处理长时间序列问题. Transformer 中的自注意力机制使得网络不会像 RNN 那样梯度爆炸或者梯度消失, 但 Transformer 在空间特征提取上无能为力. 而 GAT 网络可以有效地掌握邻居节点的局部信息, 得到新的聚合特征, 但是多层 GAT 网络叠加也仍然存在梯度爆炸等问题. 因此本文将 GAT 和 Transformer 结合使用, 利用两者各自的优势, 联合提取数据的时间关联性和空间相关性, 全面挖掘数据与 RUL 之间的关系, 实现更精准的预测.

典型的 Transformer 模型包含编码器和解码器两部分, 本文仅使用了 Transformer 的编码器部分作为特征提取器. 不同于传统 Transformer 编码器, 为了全面的提取数据的时间和空间信息, 使用 GAT 网络建模多传感器之间的非欧氏空间依赖性, 并融入 Transformer 多头注意力机制中, 从而实现数据的时空关系全面提取.

所提出的 GAT-Transformer 结构如图 1 中间模块所示. 首先, 使用层归一化将每一层输入都进行归一化处理, 这有助于改善特征分布提高训练速度. 其次, 通过 GAT 网络对传感器数据结构进行空间特征的提取. 需要注意的是, 由于使用滑窗的方式构建一段时间序列作为输入数据, 因此在 GAT 网络中仍存在序列的时间特性, 网络也可学习到序列的时间关系. 再次, 为保证 GAT 输出与网络输入的维度匹配, 本文设计了一个修正网络处理 GAT 网络输出数据, 即利用线性变换的方式将输出维度变换为与网络输入相同, 并使用残差连接加速网络传播, 解决梯度消失等问题. 最后, 模型通过前馈神经网络的学习获得编码器输出.

由于 Transformer 网络并不能像 RNN 网络那样自动学习数据的位置关系, 而在航空发动机传感器数据中不同的时间窗口数据包含互相依赖关系, 因此所提出模型仍然保留 Transformer 中的位置编码结构以实现为窗口数据进行编码.

4 改进的贝叶斯神经网络

Bayesian 神经网络^[26-27] 是一个不确定性估计框架, 通过将神经网络中确定的权重和偏差替换为服从一定分布的权重和偏差, 估计模型中存在的各种不确定性. 贝叶斯概率的基本思想是通过先验概率知识和观察到的似然知识来获得后验概率, 然后利用模型预测未知样本, 后验概率公式如下:

$$P(\omega|X, Y) = \frac{P(Y|X, \omega)P(\omega)}{P(Y|X)} \quad (8)$$

其中, X 表示变量, Y 表示标签, $P(Y|X, \omega)$ 为模型似然函数, $P(\omega)$ 为模型先验分布, $P(Y|X)$ 为条件分布, ω 为模型参数.

对于一个新的输入数据 x , 贝叶斯框架可以根据历史数据 $\{X, Y\}$ 预测输出变量 y 的概率分布, 如下式所示:

$$P(y|x, X, Y) = \int P(y|x, \omega)P(\omega|X, Y)d\omega \quad (9)$$

在高维数据中, 后验分布 $P(\omega|X, Y)$ 的获得往往需要借助马尔可夫链蒙特卡洛 (MCMC)^[28] 和变分推理 (VI)^[29] 两种方法近似得到.

为了平衡计算精度和成本, 本文使用 VI 方式近似, 即使用假设的先验概率去拟合真实后验概率. 为了更加精准的拟合不确定性因素的分布, 本文对传统的贝叶斯神经网络进行了改进, 不再使用单一高斯分布, 而是使用混合高斯分布作为先验. 相比于单一高斯分布, 混合型分布能包含更加丰富的分布信息, 有助于得到更为准确的后验分布. 混合高斯分布如下式所示:

$$Q(\omega|\theta) = \sum_i^K \rho_i N(\omega|\mu_i, \sigma_i^2) \quad (10)$$

式中, $\rho = \{\rho_1, \rho_2, \dots, \rho_K\}$ 为混合分布的比例, $N(\cdot)$ 为高斯分布, K 是高斯混合分布的个数, $\theta = \{\mu_1, \mu_2, \dots, \mu_K, \sigma_1, \sigma_2, \dots, \sigma_K\}$ 为高斯混合分布的参数集.

此外, 使用 Kullback-Leibler (KL) 散度来衡量两个概率分布的相似度. 本文设计的模型网络损失函数由两部分组成: 一是均方误差 (Mean square error, MSE) 测量的真实 RUL 值与预测的 RUL 值之间的网络损失, 另一是 KL 散度测量的不确定性估计损失. 最终模型损失函数定义为:

$$\text{Loss} = \text{MSELoss}(Y_{\text{true}}, \hat{Y}) + \text{KL}(Q(\omega|\theta)||P(\omega|X, Y)) \quad (11)$$

其中, MSELoss 是模型损失函数, Y_{true} 是数据集的 RUL 真实标签, \hat{Y} 是模型预测的 RUL.

最后, 使用改进的贝叶斯网络将 GAT-Transformer 网络中确定性权重和偏差变成服从一定分

布的权重和偏差, 进行不确定性因素的考量和分析.

5 实验与分析

本节使用美国航空航天局 NASA 提供的航空发动机 CMAPSS 和 NCMAPSS 公开数据集对算法进行验证.

5.1 评价指标

选取常用的 4 个性能指标对所提出方法的效果进行分析和验证, 包括: 均方根误差 (Root mean square error, RMSE)、平均绝对误差 (Mean absolute error, MAE)、对称平均绝对百分比误差 (Symmetric mean absolute percentage error, SMAPE) 和评分函数 (Score). 这些指标的定义如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_{\text{true}_i} - \hat{Y}_i)^2} \quad (12)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |Y_{\text{true}_i} - \hat{Y}_i| \quad (13)$$

$$\text{SMAPE} = \frac{100\%}{n} \sum_{i=1}^n \frac{|\hat{Y}_i - Y_{\text{true}_i}|}{(|\hat{Y}_i| + |Y_{\text{true}_i}|)/2} \quad (14)$$

$$\text{Score} = \begin{cases} \sum_{i=1}^n e^{-\frac{\hat{Y}_i - Y_{\text{true}_i}}{13}} - 1, & \hat{Y}_i - Y_{\text{true}_i} < 0 \\ \sum_{i=1}^n e^{-\frac{\hat{Y}_i - Y_{\text{true}_i}}{10}} - 1, & \hat{Y}_i - Y_{\text{true}_i} \geq 0 \end{cases} \quad (15)$$

其中, n 为测试样本数. RMSE 反映预测 RUL 与真实 RUL 之间的偏差, MAE 对异常值更鲁棒, SMAPE 可以表示模型的质量, Score 是 2008 年 PHM 管理数据挑战中使用的评分.

5.2 CMAPSS 数据集实验

5.2.1 数据集介绍

CMAPSS 数据集^[30]是 RUL 预测领域中流行的基准数据集. 该数据集是 NASA 阿姆斯研究中心诊断与预测小组通过美国国家航空航天局的商用模块化航空推进仿真系统 (Commercial modular aero-propulsion system simulation, CMAPSS) 获得. 模拟了 90000 磅推力级的涡扇发动机从海平面到

42 千英尺的高度, 0~0.9 马赫的速度以及从 60 到 100 油门杆角度的关键部件的性能退化过程. 它由四个数据子集组成, 每个数据子集又被进一步划分为训练集和测试集且每个数据子集包含不同的工况条件和故障模式, 具体如表 1 所示. 数据集中共有 21 个传感器监控发动机的运行状态, 如表 2 所示. 经观察发现传感器 S1、S5、S6、S10、S16、S18、S19 从运行到故障始终保持恒定值, 这意味着来自这些传感器的数据不能表征发动机的性能退化. 因此, 将其余 14 维传感器数据用于 RUL 预测.

此外, 在发动机的早期运行阶段, 不需要考虑发动机的性能下降, 因此 RUL 应该保持一个不变的值, 只有在某个时间步长发生故障时, 发动机的性能才会开始下降. 在本文中, 参考 Arias 等^[31]的研究, 在早期运行阶段将发动机的最大 RUL 限制在 125 个生命周期, 使退化呈现分段函数趋势.

5.2.2 实验结果

将所提出的模型在 CMAPSS 数据集上进行了实验. 由于空间有限, 随机选取了一部分引擎的 RUL 预测结果进行可视化, 分别如图 4~图 7 所示. 图中黑色直线代表真实的退化剩余使用寿命, 绿色曲线代表预测的剩余使用寿命结果, 绿色区域代表预测得到的 95% 置信区间. 从图中可以看到模型预测的均值能够较为精准的拟合退化曲线, 同时得益于贝叶斯网络的概率预测能力, 模型能够给出预测结果的置信区间, 且 95% 预测区间可以基本覆盖预测结果均值和真实 RUL 存在偏差的部分, 说明了本文方法出色的性能表现; 同时观察到, 置信区间随着时间推移逐渐缩小, 并具有更佳的预测准确性, 说明模型在设备的中后期具有更佳的预测能力, 符合设备中后期更需频繁维护的实际需求. 模型在工况和故障模式更加复杂的 FD002 和 FD004 数据集上的预测置信区间相较于 FD001 和 FD003 明显更大, 但仍然能够保证足够的预测精度, 置信区间仍基本覆盖了真实值曲线, 结果较为平稳, 且同样随着时间推移预测越发准确, 说明了模型在面对复杂运行条件时的鲁棒性.

表 1 CMAPSS 数据集描述

Table 1 CMAPSS dataset description

Dataset	Training engine units	Testing engine units	Fault modes	Operating conditions	Number of training samples	Number of testing samples
FD001	100	100	1	1	20631	13097
FD002	260	259	1	6	53759	33991
FD003	100	100	2	1	24720	16596
FD004	249	248	2	6	61249	41214

表 2 CMAPSS 数据集传感器数据描述

Table 2 Sensor data description of the CMAPSS dataset

Sensor Number	Symbol	Description	Unit
S1	T2	Total temperature at the fan inlet	K
S2	T24	Total temperature at the low pressure compressor outlet	K
S3	T30	Total temperature at the high pressure compressor outlet	K
S4	T50	Total temperature at the low pressure turbine outlet	K
S5	P2	Pressure at the fan inlet	Pa
S6	P15	Total pressure in the bypass duct	Pa
S7	P30	Total pressure at the high pressure compressor outlet	Pa
S8	NF	Physical fan speed	$r \cdot s^{-1}$
S9	NC	Physical core speed	$r \cdot s^{-1}$
S10	EPR	Engine pressure ratio (P50/P2)	
S11	PS30	Static pressure at the HPC outlet	Pa
S12	PHI	Ratio of fuel flow to PS30	
S13	NRF	Corrected fan speed	$r \cdot s^{-1}$
S14	NRC	Corrected core speed	$r \cdot s^{-1}$
S15	BPR	Bypass ratio	
S16	FARB	Burner fuel-air ratio	
S17	HT_BLEED	Bleed Enthalpy	
S18	NF_DMD	Demanded fan speed	$r \cdot s^{-1}$
S19	PCNFR_DMD	Demanded corrected fan speed	$r \cdot s^{-1}$
S20	W31	HPT coolant bleed	$kg \cdot s^{-1}$
S21	W32	LPT coolant bleed	$kg \cdot s^{-1}$




图 4 FD001 数据集 RUL 预测结果. (a) 引擎 34; (b) 引擎 44; (c) 引擎 68

Fig.4 FD001 dataset RUL prediction results: (a) engine 34; (b) engine 44; (c) engine 68

5.2.3 对比实验

为了进一步证明所提出模型(BGATT)的有效性, 本文将其与其他几种先进的模型在 CMA-PSS 数据集的四个子集上分别进行了对比实验. 对比模型包括贝叶斯编码器深度置信网络 (BDAE-DBN)、贝叶斯 CNN(BCNN)、贝叶斯双向 GRU(BBi-GRU)、贝叶斯带注意力 TCN(BTCN-attention) 和贝叶斯 CNN-LSTM(BCNN-LSTM). 实验性能指标对比如表 3 ~ 表 6 所示, 图 8 给出了对比实验结果的直观展示. 从中可以看出, BDAE-DBN 由

于缺乏时序与空间关系的先验设计, 难以对输入序列的先后时序性进行建模, 学习能力受到严重影响, 预测性能在所对比的模型中最差; 基础的 BCNN 网络受限于卷积模型的感受野问题, 其特征提取过程的灵活性差, 特征尺度单一, 预测性能也不理想; BBiGRU 则忽略了建模过程中的参数间空间依赖关系, 难以构建动态的时空双维度特征, 与 BCNN 性能接近; 而带有时间注意力的 BTCN-attention 强化了时间维度的特征提取能力, 具备更优的时序建模结构, 但仍然缺乏空间关系建模能




图 5 FD002 数据集 RUL 预测结果. (a) 引擎 42; (b) 引擎 97; (c) 引擎 210

Fig.5 FD002 dataset RUL prediction results: (a) engine 42; (b) engine 97; (c) engine 210




图 6 FD003 数据集 RUL 预测结果. (a) 引擎 67; (b) 引擎 88; (c) 引擎 95

Fig.6 FD003 dataset RUL prediction results: (a) engine 67; (b) engine 88; (c) engine 95




图 7 FD004 数据集 RUL 预测结果. (a) 引擎 78; (b) 引擎 154; (c) 引擎 201

Fig.7 FD004 dataset RUL prediction results: (a) engine 78; (b) engine 154; (c) engine 201

表 3 FD001 数据集对比实验结果

Table 3 Comparison of experimental results with the FD001 dataset

Model	RMSE	MAE	Score	SMAPE/%
BDAE-DBN	11.103	8.208	12.946	19.811
BCNN	10.025	7.845	12.327	13.520
BBiGRU	9.913	7.064	11.963	10.094
BTCN-attention	5.642	4.291	11.454	9.372
BCNN-LSTM	4.903	3.891	6.732	8.805
BGATT	2.045	1.612	4.890	4.913

表 4 FD002 数据集对比实验结果

Table 4 Comparison of experimental results with the FD002 dataset

Model	RMSE	MAE	Score	SMAPE/%
BDAE-DBN	16.771	13.644	19.095	28.910
BCNN	15.049	12.793	18.441	24.500
BBiGRU	14.526	11.882	17.890	20.603
BTCN-attention	9.059	8.655	15.335	18.176
BCNN-LSTM	7.685	6.971	13.362	15.441
BGATT	5.441	4.056	10.553	10.605

力, 导致其性能弱于 BCNN-LSTM. 相比于 BCNN-LSTM, 本文方法更加注重不同传感器数据之间的非欧氏空间关系和序列时间关系, 实现了数据时空关系的联合提取, 因此效果最优.

从实验结果可以看出, 本文所提出的模型在四个数据子集上均具有最小的指标数值, 这意味

着所提出模型具有最低的预测误差和最好的 RUL 预测性能, 验证了所提出的方法的优越性和强大的网络学习能力.

5.3 NCMAPSS 数据集实验

5.3.1 数据集介绍

为了进一步说明所提模型的有效性, 本文也

表5 FD003 数据集对比实验结果

Table 5 Comparison of experimental results with the FD003 dataset

Model	RMSE	MAE	Score	SMAPE/%
BDAE-DBN	14.257	12.039	14.883	13.641
BCNN	12.684	9.091	13.266	11.937
BBiGRU	10.025	7.770	12.139	10.429
BTCN-attention	6.034	4.882	11.351	9.546
BCNN-LSTM	4.374	2.928	8.663	8.921
BGATT	2.824	1.818	5.560	5.607

表6 FD004 数据集对比实验结果

Table 6 Comparison of experimental results with the FD004 dataset

Model	RMSE	MAE	Score	SMAPE/%
BDAE-DBN	20.053	17.984	24.091	30.200
BCNN	18.115	15.064	22.842	26.802
BBiGRU	16.868	13.173	19.262	20.116
BTCN-attention	10.970	9.143	17.834	18.466
BCNN-LSTM	8.352	7.691	13.972	15.837
BGATT	6.012	4.091	10.670	11.213

在 NCMAPSS 数据集上进行了实验. NCMAPSS 数据集^[29]由 8 个子集组成, 拥有更加真实的运行条件和更丰富的传感器监测数据, 其中 DS02-006.h5 通常用于研究航空发动机剩余使用寿命预测. 该子集记录了 9 台机组发动机的完整运行轨迹. 分别设有 6 个训练单元 (2、5、10、16、18 和 20) 和 3 个测试单元 (11、14 和 15). NCMAPSS 数据集模拟了近 100 台发动机在更复杂的运行条件下的运行数据, 得到的数据更加真实, 提供了更多维、更丰富的传感器数据. 传感器的具体描述如表 7 所示.

5.3.2 实验结果

RUL 的预测结果如图 9 所示, 图中黑色直线代表真实的退化剩余使用寿命, 红色曲线代表预测的剩余使用寿命结果, 粉色区域代表预测得到

的 95% 置信区间. 从图中可以看出, 预测区间几乎可以涵盖住所有的真实 RUL 退化, 表明了预测的可靠性, 可以为航空发动机健康管理提供更精准的决策方案.

5.3.3 对比实验

为了验证该模型的有效性, 实验选择了几种先进的网络模型与提出的方法在三个测试引擎上分别进行了对比实验, 对比结果如表 8、表 9、表 10 和图 10 所示. 从表中和图中可以清晰地看出所提模型各项指标相比于其他模型均有明显下降, 这也意味着所提出模型在剩余使用寿命预测方面具有最好的预测误差, 进一步展示出该模型在剩余使用寿命预测方面的优势所在, 证明了该模型提出的必要性和可行性. 为了保证实验的公平

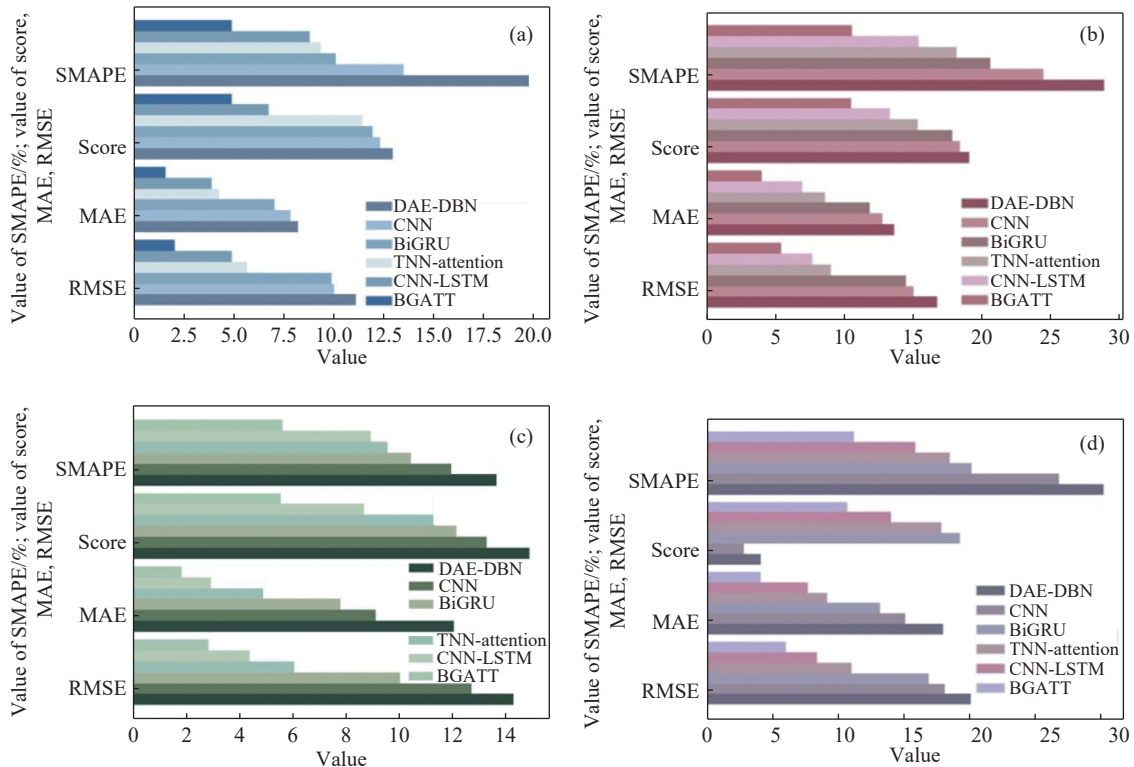


图8 CMAPSS 数据集对比实验结果. (a) FD001; (b) FD002; (c) FD003; (d) FD004

Fig.8 Comparison of experimental results with the CMAPSS dataset: (a) FD001; (b) FD002; (c) FD003; (d) FD004

表 7 NCMAPSS 数据集传感器数据描述

Table 7 Sensor data description of the NCMAPSS dataset

Sensor	Symbol	Description	Unit
S1	T2	Total temperature at the fan inlet	K
S2	T24	Total temperature at the LPC outlet	K
S3	T30	Total temperature at the HPC outlet	K
S4	T48	Total temp. at the burner outlet	K
S5	T50	Total temperature at the HPT outlet	K
S6	P15	Total pressure in the bypass duct	Pa
S7	P2	Pressure at the fan inlet	Pa
S8	P21	Total pressure at the fan outlet	Pa
S9	P24	Total pressure at the LPC outlet	Pa
S10	PS30	Static Pressure at the HPC outlet	Pa
S11	P40	Total pressure at the burner outlet	Pa
S12	P50	Total pressure at LPT outlet	Pa
S13	Nf	Physical fan speed	$r \cdot s^{-1}$
S14	Nc	Physical core speed	$r \cdot s^{-1}$
S15	Wf	Fuel flow	$kg \cdot s^{-1}$
S16	T40	Total temp. at burner outlet	K
S17	P30	Total pressure at the HPC outlet	Pa
S18	P45	Total pressure at the HPT outlet	Pa
S19	W21	Fan flow	$kg \cdot s^{-1}$
S20	W22	Flow out of LPC	$kg \cdot s^{-1}$
S21	W25	Flow into HPC	$kg \cdot s^{-1}$
S22	W31	HPT coolant bleed	$kg \cdot s^{-1}$
S23	W32	LPT coolant bleed	$kg \cdot s^{-1}$
S24	W48	Flow out of HPT	$kg \cdot s^{-1}$
S25	W50	Flow out of LPT	$kg \cdot s^{-1}$
S26	SmFan	Fan stall margin	
S27	SmLPC	LPC stall margin	
S28	SmHPC	HPC stall margin	
S29	phi	Ratio of fuel flow to PS30	$kg \cdot s^{-1}$




图 9 NCMAPSS 数据集 RUL 预测结果. (a) 引擎 11; (b) 引擎 14; (c) 引擎 15

Fig.9 NCMAPSS dataset RUL prediction results: (a) engine 11; (b) engine 14; (c) engine 15

性, 实验中的预测性能指标结果均取 5 次实验的平均值.

5.3.4 消融实验

为证明所提出模型各个模块的有效性和必要性,

表 8 引擎 11 对比实验结果

Table 8 Comparative test results for engine 11

Model	RMSE	MAE	Score	SMAPE
BDAE-DBN	1.248	1.078	0.113	0.214
BCNN	1.043	0.986	0.105	0.186
BBiGRU	1.000	0.966	0.101	0.173
BTCN-attention	0.854	0.845	0.078	0.149
BCNN-LSTM	0.691	0.735	0.074	0.104
BGATT	0.290	0.156	0.013	0.053

表 10 引擎 15 对比实验结果

Table 10 Comparative test results for engine 15

Model	RMSE	MAE	Score	SMAPE
BDAE-DBN	1.174	1.021	0.112	0.119
BCNN	0.968	0.853	0.087	0.104
BBiGRU	0.971	0.821	0.079	0.106
BTCN-attention	0.851	0.602	0.061	0.099
BCNN-LSTM	0.637	0.477	0.056	0.096
BGATT	0.292	0.247	0.020	0.051

表 9 引擎 14 对比实验结果

Table 9 Comparative test results for engine 14

Model	RMSE	MAE	Score	SMAPE
BDAE-DBN	1.148	1.171	0.139	0.157
BCNN	1.027	0.936	0.096	0.104
BBiGRU	1.018	0.935	0.094	0.099
BTCN-attention	0.998	0.702	0.083	0.083
BCNN-LSTM	0.994	0.698	0.079	0.084
BGATT	0.417	0.382	0.032	0.067

消融实验都显示出该模型具有更小的预测评价指标, 并且去掉其中的任意模块都会造成性能指标的上升, 这些意味着所提模型并不是一些模块的简单堆叠, 而是每一部分都有其重要意义所在. 例如, 缺少降噪编码器可能造成数据有噪声影响预测结果, 去掉 CNN 可能造成特征提取不够充分, 去掉 GAT 就是传统的 Transformer 模型忽略了传感器数据的空间特性, 去掉 Transformer 则只剩下简单的 GAT, 其在处理长时间序列问题上逊色于 Transformer 网络. 因此, 消融实验的结果再次证明所提出模型在剩余使用寿命方面存在一定的优越性和各个模块对预测模型效果的有效性.

本节通过删减或改变某些模块的方式在 NCM-APSS 数据集上进行了消融实验. 实验结果如表 11、表 12、表 13 和图 11 所示.

从表和折线图中可以发现, 在三个引擎上的

5.3.5 参数影响分析

由于 NCMAPSS 数据集的数据过于庞大, 因此

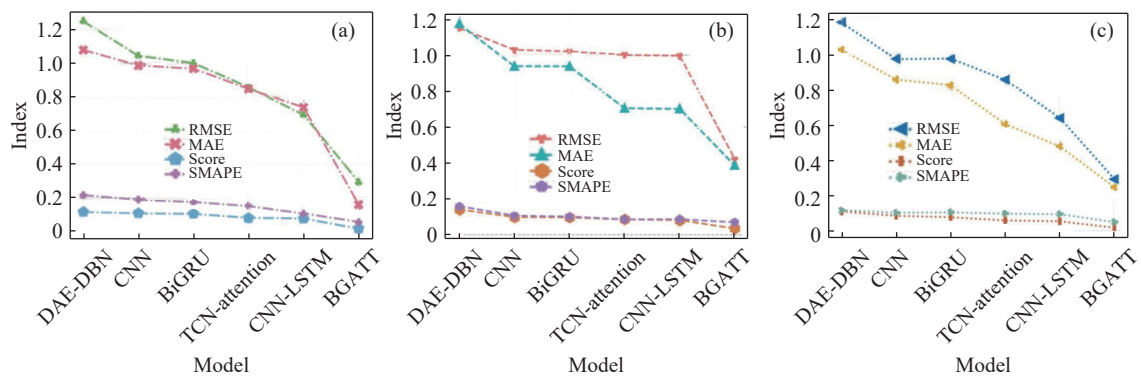


图 10 NCMAPSS 数据集对比实验结果. (a) 引擎 11; (b) 引擎 14; (c) 引擎 15

Fig.10 Comparison of experimental results with NCMAPSS datasets: (a) engine 11; (b) engine 14; (c) engine 15

表 11 引擎 11 消融实验结果

Table 11 Ablation results for engine 11

Model	RMSE	MAE	Score	SMAPE
Remove CDAE	0.330	0.171	0.021	0.083
Remove CNN	0.326	0.168	0.019	0.076
Remove GAT	0.397	0.176	0.028	0.092
Remove Transformer	0.402	0.183	0.031	0.095
GAT-Transformer	0.290	0.156	0.013	0.053

表 12 引擎 14 消融实验结果

Table 12 Ablation results for engine 14

Model	RMSE	MAE	Score	SMAPE
Remove CDAE	0.488	0.403	0.039	0.075
Remove CNN	0.475	0.420	0.041	0.079
Remove GAT	0.524	0.519	0.047	0.083
Remove Transformer	0.537	0.523	0.050	0.086
GAT-Transformer	0.417	0.382	0.032	0.067

表 13 引擎 15 消融实验结果

Table 13 Ablation results for engine 15

Model	RMSE	MAE	Score	SMAPE
Remove CDAE	0.334	0.256	0.025	0.085
Remove CNN	0.329	0.239	0.020	0.079
Remove GAT	0.400	0.304	0.029	0.097
Remove Transformer	0.404	0.309	0.032	0.095
GAT-Transformer	0.292	0.247	0.020	0.051

一般采用跨步滑窗的方式来降低训练数量, 节约资源和时间. 为了解滑窗和步长对实验结果产生的影响, 本文对不同的滑窗和步长进行了实验比较, 比较结果如表 14、表 15、表 16 和图 12 所示. 从表和图中可以看出, 当滑窗长度设置为 50, 步长采用 10 时, 实验结果在三个引擎上的性能指标均最小, 即偏差最小, 效果最好. 因此, 在该实验中选择滑窗大小为 50, 步长为 10 进行数据划分.

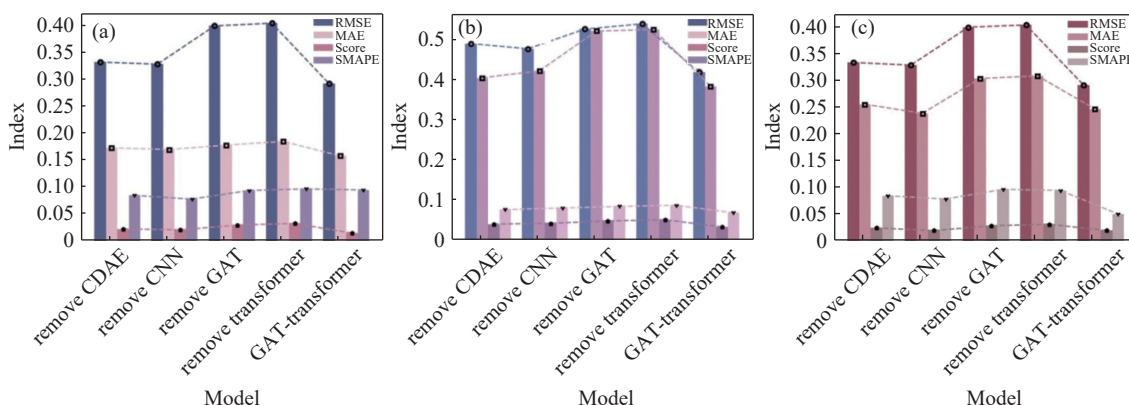


图 11 NCMAPSS 数据集消融实验结果. (a) 引擎 11; (b) 引擎 14; (c) 引擎 15

Fig.11 NCMAPSS dataset ablation results: (a) engine 11; (b) engine 14; (c) engine 15

表 14 引擎 11 滑窗实验结果

Table 14 Sliding window test results on engine 11

(Window, Stride)	RMSE	MAE	Score	SMAPE
(30,10)	0.405	0.399	0.040	0.059
(30,20)	0.492	0.420	0.035	0.120
(40,10)	0.451	0.411	0.038	0.074
(40,20)	0.389	0.432	0.039	0.092
(50,10)	0.290	0.156	0.013	0.053
(50,20)	0.355	0.445	0.037	0.069
(60,10)	0.462	0.500	0.042	0.051
(60,20)	0.563	0.571	0.046	0.082

表 16 引擎 15 滑窗实验结果

Table 16 Sliding window test results on engine 15

(Window, Stride)	RMSE	MAE	Score	SMAPE
(30,10)	0.425	0.399	0.089	0.059
(30,20)	0.395	0.308	0.084	0.053
(40,10)	0.310	0.305	0.075	0.040
(40,20)	0.306	0.299	0.072	0.038
(50,10)	0.292	0.247	0.051	0.020
(50,20)	0.317	0.269	0.060	0.025
(60,10)	0.366	0.276	0.065	0.032
(60,20)	0.370	0.300	0.073	0.035

表 15 引擎 14 滑窗实验结果

Table 15 Sliding window test results on engine 14

(Window, Stride)	RMSE	MAE	Score	SMAPE
(30,10)	0.480	0.395	0.100	0.039
(30,20)	0.520	0.468	0.074	0.047
(40,10)	0.424	0.472	0.075	0.041
(40,20)	0.465	0.469	0.077	0.044
(50,10)	0.417	0.382	0.067	0.032
(50,20)	0.508	0.516	0.065	0.045
(60,10)	0.540	0.511	0.063	0.040
(60,20)	0.821	0.755	0.099	0.060

6 总结与展望

本文提出了一种基于贝叶斯网络和 GAT-Transformer 的剩余使用寿命概率预测的方法. 将 GAT 融入 Transformer 的时间注意力模块. 一方面利用 GAT 充分建立传感器数据之间复杂的非欧氏空间关系, 另一方面使用多头注意力机制充分挖掘长序列之间的时间特性. 同时, 使用改进贝叶斯神经网络衡量预测过程中存在的各种不确定性, 以同时得到剩余使用寿命预测的点值和相应的置信区间. 通过在两个公开的航空发动机数据集上分别

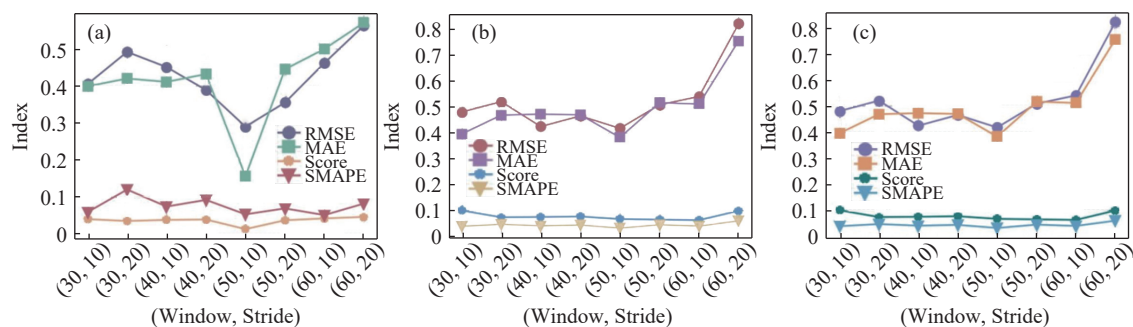


图 12 NCMAPSS 数据集滑窗实验结果. (a) 引擎 11; (b) 引擎 14; (c) 引擎 15

Fig.12 NCMAPSS dataset sliding window experiment results: (a) engine 11; (b) engine 14; (c) engine 15

进行实验,验证了该模型强大的学习能力和可靠的预测能力.对比实验和消融实验也进一步说明所提模型的有效性和优越性.

未来工作中,可以从以下几个方面改进模型以期进一步提升 RUL 预测性能:研究更精准的不确定性估计网络,探索小样本数据或者缺失样本数据下的 RUL 预测方法,或尝试利用无监督数据进行预训练来提升模型性能.

参 考 文 献

- [1] Zhao C Y, Huang X Z, Li Y X, et al. A novel cap-LSTM model for remaining useful life prediction. *IEEE Sens J*, 2021, 21(20): 23498
- [2] Duan Y H, Li H H, He M Q, et al. A BiGRU autoencoder remaining useful life prediction scheme with attention mechanism and skip connection. *IEEE Sens J*, 2021, 21(9): 10905
- [3] Pillai S, Vadakkepat P. Deep learning for machine health prognostics using Kernel-based feature transformation. *J Intell Manuf*, 2022, 33(6): 1665
- [4] Zhu H Q, Huang Z Y, Lu B L, et al. Bearing remaining useful life prediction of fatigue degradation process based on dynamic feature construction. *Int J Fatigue*, 2022, 164: 107169
- [5] Zhang B W, Zheng J F, Hu C H, et al. Missing data generation method based on flow model and its application in remaining life prediction. *Acta Autom Sin*, 2023, 49(1): 185
(张博玮, 郑建飞, 胡昌华, 等. 基于流模型的缺失数据生成方法在剩余寿命预测中的应用. *自动化学报*, 2023, 49(1): 185)
- [6] Liang P F, Li Y, Wang B, et al. Remaining useful life prediction via a deep adaptive transformer framework enhanced by graph attention network. *Int J Fatigue*, 2023, 174: 107722
- [7] Li X, Ding Q, Sun J Q. Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliab Eng Syst Saf*, 2018, 172: 1
- [8] Xu X W, Li X, Ming W W, et al. A novel multi-scale CNN and attention mechanism method with multi-sensor signal for remaining useful life prediction. *Comput Ind Eng*, 2022, 169: 108204
- [9] Ma P, Li G F, Zhang H L, et al. Prediction of remaining useful life of rolling bearings based on multiscale efficient channel attention CNN and bidirectional GRU. *IEEE Trans Instrum Meas*, 2024, 73: 2508413
- [10] Yu K, Wang D G, Li H X. A prediction model for remaining useful life of turbofan engines by fusing broad learning system and temporal convolutional network // 2021 8th International Conference on Information, Cybernetics, and Computational Social Systems (ICCSS). Beijing, 2021: 137
- [11] Chen Q, Liu Y B, Ge M F, et al. A novel bayesian-optimization-based adversarial TCN for RUL prediction of bearings. *IEEE Sens J*, 2022, 22(21): 20968
- [12] Xu Z Q, Zhang Y J, Miao Q. An attention-based multi-scale temporal convolutional network for remaining useful life prediction. *Reliab Eng Syst Saf*, 2024, 250: 110288
- [13] Guo J, Li D P, Du B G. A stacked ensemble method based on TCN and convolutional bi-directional GRU with multiple time windows for remaining useful life estimation. *Appl Soft Comput*, 2024, 150: 111071
- [14] Yao D C, Tang B, Yang J W, et al. Multiscale PatchTCN-mixer: A new method for extracting spatial and temporal degradation information in remaining useful life prognosis. *IEEE Sens J*, 2024, 24(15): 23537
- [15] Wang J J, Wen G L, Yang S P, et al. Remaining useful life estimation in prognostics using deep bidirectional LSTM neural network // 2018 Prognostics and System Health Management Conference (PHM-Chongqing). Chongqing, 2018: 1037
- [16] Liu J Q, Lei F, Pan C L, et al. Prediction of remaining useful life of multi-stage aero-engine based on clustering and LSTM fusion. *Reliab Eng Syst Saf*, 2021, 214: 107807
- [17] Guo Z J, Yun Y J, Xu X H. Prediction model of aero-engine remaining useful life based on deep learning method. *Journal of Vibration, Measurement & Diagnosis*, 2024, 44(2): 330
(郭晓静, 贡玉晶, 徐晓慧. 基于深度学习方法的航空发动机寿命预测模型. *振动, 测试与诊断*, 2024, 44(2): 330)
- [18] Zhang Z Y, Chen X H, Zio E. A framework for predicting the remaining useful life of machinery working under time-varying operational conditions. *Appl Soft Comput*, 2022, 126: 109164
- [19] Zhong S S, Li Z, Lin L, et al. Aero-engine exhaust gas temperature prognostic model based on gated recurrent unit network // 2018

- IEEE International Conference on Prognostics and Health Management (ICPHM)*. Seattle, 2018: 1
- [20] Zhang X, Sun J K, Wang J X, et al. PAOLTransformer: Pruning-adaptive optimal lightweight Transformer model for aero-engine remaining useful life prediction. *Reliab Eng Syst Saf*, 2023, 240: 109605
- [21] Li R Z, Zhan H F, Yu J H, et al. A lightweight transformer and depthwise separable convolution model for remaining useful life prediction of turbofan engines. *Meas Sci Technol*, 2024, 35(2): 025020
- [22] Chen C, Li X F, Shi J T. Research progress on remaining useful life interval prediction of equipment based on deep learning. *Chin J Eng*, 2024, 46(4): 723
(陈闯, 李先锋, 史建涛. 基于深度学习的装备剩余寿命区间预测研究进展. 工程科学学报, 2024, 46(4): 723)
- [23] Yao X J, Zhu J J, Jiang Q S, et al. RUL prediction method for rolling bearing using convolutional denoising autoencoder and bidirectional LSTM. *Meas Sci Technol*, 2024, 35(3): 035111
- [24] Wang L, Cao H R, Xu H, et al. A gated graph convolutional network with multi-sensor signals for remaining useful life prediction. *Knowl Based Syst*, 2022, 252: 109340
- [25] Pei H, Si X S, Hu C H, et al. Prognostic method of remaining useful life for degraded equipment under zero life label. *Acta Electron Sin*, 2023, 51(7): 1939
(裴洪, 司小胜, 胡昌华, 等. 零寿命标签下退化设备剩余寿命预测方法. 电子学报, 2023, 51(7): 1939)
- [26] Ren C, Li H Q, Li T M, et al. Equipment remaining useful life prediction method with dynamic calibration of degradation model. *Acta Aeronaut Astronaut Sin*, 2023, 44(19): 171
(任超, 李慧琴, 李天梅, 等. 基于退化模型动态校准的设备剩余寿命预测方法. 航空学报, 2023, 44(19): 171)
- [27] Zaidan M A, Mills A R, Harrison R F, et al. Gas turbine engine prognostics using Bayesian hierarchical models: A variational approach. *Mech Syst Signal Process*, 2016, 70: 120
- [28] Pei H, Si X S, Hu C H, et al. Bayesian deep-learning-based prognostic model for equipment without label data related to lifetime. *IEEE Trans Syst Man Cybern Syst*, 2023, 53(1): 504
- [29] Liu H, Liu Z Y, Jia W Q, et al. Remaining useful life prediction using a novel feature-attention-based end-to-end approach. *IEEE Trans Ind Inform*, 2021, 17(2): 1197
- [30] Wen L, Dong Y, Gao L. A new ensemble residual convolutional neural network for remaining useful life estimation. *Math Biosci Eng*, 2019, 16(2): 862
- [31] Arias Chao M, Kulkarni C, Goebel K, et al. Aircraft engine Run-to-failure dataset under real flight conditions for prognostics and diagnostics. *Data*, 2021, 6(1): 5