

航空航天装备

# 基于Transformer小样本多源数据融合的装备剩余寿命预测评估

陈凯诺, 张福光, 韩建立, 尹延涛, 杜光传

(海军航空大学, 山东 烟台 264001)

**摘要:** 目的 解决某类高可靠性航空装备在贮存延寿过程中因失效数据稀缺、样本量不足导致剩余寿命预测精度不高的问题。方法 提出一种基于Transformer的迁移学习和多源数据融合方法。该方法利用多头注意力机制, 对装备在贮存、使用和延寿科研等不同阶段获取的多源异构数据进行融合, 挖掘数据内在联系, 提高信息综合利用水平。在此基础上, 引入迁移学习策略, 通过在相关领域数据上预训练模型, 并采用特征对齐和语义对齐技术, 缓解源域和目标域的分布差异, 从而提高模型在目标任务上的适应性和判别能力。结果 与传统方法相比, 在剩余寿命预测的准确性和实用性方面均取得了显著提升, 证明了模型在小样本情况下具有理想的预测精度和鲁棒性。结论 该方法为高可靠性装备剩余寿命的预测提供了一个有效的解决方案, 具有重要的实际应用价值。

**关键词:** 贮存延寿工程; 剩余寿命; Transformer; 多源数据融合; 迁移学习; 源域; 目标域

中图分类号: TJ760.1

文献标志码: A

文章编号: 1672-9242(2024)11-0065-09

DOI: 10.7643/issn.1672-9242.2024.11.009

## Equipment Residual Life Prediction and Evaluation with Transformer Small Sample Multi-source Data Fusion

CHEN Kainuo, ZHANG Fuguang, HAN Jianli, YIN Yantao, DU Guangchuan

(Naval Aviation University, Shandong Yantai 264001, China)

**ABSTRACT:** The work aims to address the low accuracy in residual life assessments caused by the scarcity of failure data and the small sample size in storage life extension of certain high-reliability aviation equipment. A method utilizing Transformer architecture for transfer learning and multi-source data fusion was proposed. This method effectively integrated sensor data from various stages (such as storage, use and life extension) and types of equipment tests using a multi-head attention mechanism, to explore the internal relation of data and improve the level of comprehensive utilization of information. On this basis, the transfer learning strategy was introduced to mitigate the distribution difference between the source domain and the target domain by pre-training the model on relevant domain data and using feature alignment and semantic alignment techniques, so as to improve

收稿日期: 2024-07-15; 修订日期: 2024-08-01

Received: 2024-07-15; Revised: 2024-08-01

基金项目: 国家自然科学基金(62371465); 山东省青创团队(2022kj084); 山东省自然科学基金(ZR2020QF010)

Fund: The National Natural Science Foundation of China (62371465); Shandong Province Youth Innovation Team(2022kj084); Shandong Provincial Natural Science Foundation(ZR2020QF010)

引文格式: 陈凯诺, 张福光, 韩建立, 等. 基于Transformer小样本多源数据融合的装备剩余寿命预测评估[J]. 装备环境工程, 2024, 21(11): 65-73.

CHEN Kainuo, ZHANG Fuguang, HAN Jianli, et al. Equipment Residual Life Prediction and Evaluation with Transformer Small Sample Multi-source Data Fusion[J]. Equipment Environmental Engineering, 2024, 21(11): 65-73.

the adaptability and discrimination ability of the model on target tasks. Compared with traditional methods, this method significantly improved the accuracy and practicability of the residual life prediction, which proved that the model had ideal prediction accuracy and robustness in the case of small-sample scenarios. This method provides an effective solution for predicting the residual life of high reliability equipment and has important values for practical application.

**KEY WORDS:** life extension engineering; residual life; transformer; multi-source data fusion; transfer learning; source domain; target domain

装备贮存延寿工程中的剩余寿命预测评估是其核心内容之一。该评估基于贮存延寿过程中产生的数据，运用科学方法求取装备的实际剩余寿命值<sup>[1]</sup>。某类航空产品具有长期贮存、一次使用、高价值、高可靠性等特点，其剩余寿命（Residual Life）是衡量贮存期间可靠度的重要指标。对这一指标的精确评估，有助于深入了解产品的技术状态，并为贮存延寿工作提供可靠的决策支持。在装备延寿科研阶段，由于受限于经费和时间节点，以及需保证装备的在位率，不可能对所有在役装备进行大规模的可靠性试验。经典的寿命预测方法通常依赖大样本数据，目前对小样本数据的容量范围尚无明确界定，工程上一般认为样本容量大于 30 划分为大样本，样本容量小于 30 划分为小样本。当试验数据较少时，经典寿命评估方法的置信度显著降低。

### 1 贮存延寿工程中的小样本问题

本文关注的小样本问题源于研究对象的特性。这类装备造价高、制造复杂、贮存期长且使用频次低，每次试验需取得有意义结果，因此无法进行大规模抽样试验。此外，装备服役期跨越数十年，长期跟踪试验难度大。在有限的经费和时间内，每次试验需获取有效信息，避免重复低效试验，用最少样本获取最有价值数据，因此研究方法必须在小样本条件下提供高置信度预测结果。

在实践中，贮存延寿工程结合定性和定量分析，依赖历次延寿结论、技术勘验数据和试验数据进行预测评估。然而，高可靠性产品在服役期间故障数据稀缺，使小样本条件下寿命预测面临挑战。为克服这些

困难，需要综合运用多源数据，如战备值班、贮存环境数据、装备性能退化数据和关键部件故障时间数据等，这些数据的多阶段、多类型和多模态增加了数据融合复杂性。多源数据融合旨在整合多种传感器和测量工具的信息，以提供更完整、可靠的寿命预测。然而，在处理小样本时，现有方法常遇到过拟合和高不确定性问题<sup>[2]</sup>。

为解决上述问题，本文提出了基于 Transformer 的多源数据融合方法。Transformer 最初用于自然语言处理<sup>[3-4]</sup>，但其强大的序列建模能力在深度学习的各个领域也表现出色<sup>[5-15]</sup>。本文借鉴 Transformer 架构的多头注意力机制<sup>[16]</sup>，该机制能够自适应捕捉不同数据源中的关键信息，挖掘数据内在联系，增强模型在小样本场景下的预测能力。同时，本文引入迁移学习<sup>[17]</sup>和小样本学习策略。迁移学习通过跨领域知识转移，提高目标领域学习性能或减少所需标注样本数量。小样本学习从有限数据中提取最大化信息，提高模型泛化能力。本文提出的方法整体框架如图 1 所示。针对装备剩余贮存寿命的预测问题，探究出一种适合处理该问题的数据融合方法，即通过多头注意力机制与迁移学习实现多种数据类型的有效融合和精准评估。在这一框架下，利用延寿立项论证阶段统计工作得到的装备贮存和值班阶段通用质量特性相关数据、延寿科研阶段的技术阵地勘验数据以及多种类型试验数据，模型能够捕捉并整合来自不同数据源的关键信息。通过上述方法，不仅提升了小样本数据条件下的装备剩余寿命预测的精度，还为装备贮存延寿工程实践提供了有效的技术支撑。通过本研究，在有限数据条件下可以实现装备剩余寿命的准确评估，延长装备的有效服役期，减少不必要的维修成本。

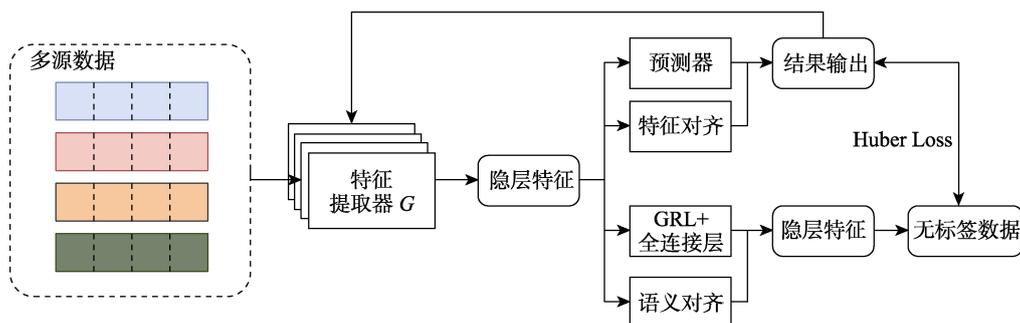


图 1 模型整体框架  
Fig.1 Overall Model Framework

## 2 小样本多源数据融合模型

本节正式定义剩余寿命预测评估问题。设  $X = \{x_1, x_2, \dots, x_n\}$ , 其中  $x_i \in \mathbb{R}^d$ , 表示时间步  $i$  的  $d$  维输入特征 (通常是特定应用场景下的各种传感器读数);  $Y = \{y_1, y_2, \dots, y_n\}$ , 其中  $y_i$  是表示时间步  $i$  的剩余寿命的标量。本文的任务是找到映射  $f$ , 使得  $f(X) = Y$ 。对于跨领域的剩余寿命评估, 本文定义源领域  $D_S = \{x_s, y_s\}$ , 其中  $x_s$  是属于源分布  $P(x_s)$  的输入数据,  $y_s$  是相应的标签。类似地, 本文有目标领域  $D_T = \{x_T\}$ , 其中只有来自目标分布  $P(x_T)$  的未标记训练数据  $x_T$  可用。具体来说, 对于领域自适应的剩余寿命评估任务, 本文从时间序列建模的角度解决挑战, 因此源域和目标域中的输入数据是长度为  $q$  的特征序列, 即  $x_s \in \mathbb{R}^{q \times d}$ ,  $x_T \in \mathbb{R}^{q \times d}$ 。

### 2.1 Transformer

本文采用的 Transformer 架构由一系列的编码器和解码器组成。编码器通过自注意力机制从输入数据中提取序列关系, 并将输入编码成隐藏特征。解码器则将这些隐藏特征转换为期望的评估结果<sup>[17-22]</sup>。

1) 位置编码。为了使模型能够显式地学习相对位置对结果的影响, Transformer 在输入序列中加入了位置编码 (Position Encoding,  $P_E$ ) 信息, 这使得模型能够自适应地学习装备数据中的时序模式。 $P_E$  的计算公式:

$$P_E(p_{os}, 2i) = \sin\left(\frac{P_{os}}{10\,000^{2i/d}}\right) \quad (1)$$

$$P_E(p_{os}, 2i+1) = \cos\left(\frac{P_{os}}{10\,000^{2i/d}}\right) \quad (2)$$

式中:  $p_{os}$  是序列中当前元素的相对位置;  $i$  表示所有  $d$  维度中的第  $i$  个维度。

2) 多头自注意力机制。Transformer 的核心是多头自注意力机制, 多头注意力块传参数化了 3 个主要矩阵, 即  $W_q \in \mathbb{R}^{d_q \times d}$ 、 $W_k \in \mathbb{R}^{d_k \times d}$  和  $W_v \in \mathbb{R}^{d_v \times d}$ , 以获取 Query、Key 和 Value 向量, 分别表示为  $Q$ 、 $K$  和  $V$ 。给定键  $K$  和对应的值  $V$ , 对于每个查询  $Q$ , 注意力机制旨在计算它应该将多少注意力 (权重) 放在每个值  $V_i$  上。公式为 (3)、(4):

$$\text{MH Attention}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O \quad (3)$$

$$\begin{aligned} \text{head}_i &= \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \\ &= \text{Softmax}\left(\frac{QW_i^Q(KW_i^K)^T}{\sqrt{d_k}}\right)VW_i^V \end{aligned} \quad (4)$$

式中,  $W^O \in \mathbb{R}^{h d_v \times d}$ , 所有向量分别通过全连接层传递, 应用激活函数引入非线性。考虑到装备数据中不同传感器信息之间的复杂相互作用, 需要对多头

注意力机制进行特别设计。针对多源异构传感器数据的处理, 本研究提出了分组特化多头注意力 (Grouped Specialized Multi-Head Attention, GSMHA) 机制。GSMHA 首先将  $m$  类传感器数据分组, 并将  $h$  个注意力头按重要性分配给各组。对每组数据  $i$ , 通过特化注意力计算  $\text{HEAD}_i = \text{Attention}(Q_iW_i^Q, K_iW_i^K, V_iW_i^V)$  获取初步特征, 其中  $Q_i$ 、 $K_i$ 、 $V_i$  为该组的查询、键、值矩阵,  $W_i^Q$ 、 $W_i^K$ 、 $W_i^V$  为相应权重矩阵。随后, 每组内的注意力头输出经连接和线性变换, 形成组级表示  $\text{GROUP}_i = \text{Concat}(\text{HEAD}_{i1}, \dots, \text{HEAD}_{ih})W_i^O$ ,  $W_i^O$  为组内融合权重矩阵。为捕捉不同类型数据间的相互作用, 引入跨组注意力  $\text{CROSS} = \text{CrossAttention}(\text{GROUP}_1, \dots, \text{GROUP}_m)$ 。最终, 将各组输出与跨组注意力结果连接并经线性变换, 得到输出  $\text{OUTPUT} = \text{Concat}(\text{GROUP}_1, \dots, \text{GROUP}_m, \text{CROSS})W^F$ , 其中  $W^F$  为最终权重矩阵。这种设计的优势在于: 它允许模型针对不同类型的传感器数据学习特定的注意力模式; 通过组内信息融合, 模型可以更好地理解同类传感器数据的局部相关性; 跨组注意力机制确保了不同类型传感器数据之间的信息交互, 捕捉长期依赖关系; 这种结构保持了计算效率, 同时显著提高了模型对多源异构数据的处理能力。

### 2.2 特征提取器和预测器

特征提取器  $G$  是模型的核心部分, 其主要任务是从原始的时间序列数据中提取关键特征。这些数据一般由长度为  $l$ 、维度为  $d$  的序列构成, 包含从各种传感器收集的信息, 其中有时序和非时序数据。本研究使用加速寿命试验数据和统计工作中环境剖面数据。加速寿命试验通过提升环境应力, 加速产品的失效过程, 从而在较短时间内获得装备的寿命和退化信息。而环境剖面数据则提供了装备在实际贮存环境中的可靠性数据, 包括温度、湿度和振动等参数, 帮助理解装备在真实使用条件下的退化情况和性能变化。环境载荷对剩余寿命预测具有重要影响。环境剖面数据提供了装备在不同贮存条件下的退化趋势。通过将环境载荷数据与加速寿命试验数据融合, 可以更准确地反映装备在实际使用条件下的性能变化, 从而提高剩余寿命预测的精度。本研究充分认识到环境载荷对装备剩余寿命的重要影响。虽然模型没有直接建模环境载荷, 但通过融合环境剖面数据, 间接地考虑了环境因素的影响。具体而言, 环境剖面数据包含了温度、湿度、振动等参数, 这些参数反映了装备在实际使用过程中所承受的环境载荷。通过提出的多源数据融合方法, 模型能够自适应地学习这些环境参数与装备退化过程之间的复杂关系。

由于加速寿命试验条件下的数据变异性较大, 预测其剩余寿命变得复杂。结合不同来源和类型的数

据,模型能够更好地理解和适应这些变异性,特别是在分析装备如何响应不同贮存和值班环境时,提供更全面和准确的预测评估。这些数据均为时序数据,处理时需保留元素之间的时序关系。本研究引入位置编码,以帮助模型理解序列中各元素的时间位置关系。经过位置编码处理后的序列被传递到采用 Transformer 架构的编码器层,利用 GSMHA 捕捉序列中的长期依赖关系。单独依赖加速寿命试验数据或自然贮存环境剖面数据都可能导致评估不准确,结合两者,从不同角度补充装备退化信息,可提高模型在不同环境和条件下的适用性和泛化能力。加速寿命试验数据有助于识别加速退化和潜在故障模式,而环境剖面数据提供了正常使用条件下的退化趋势和环境影响。分析这两类数据,可以发现复杂的退化模式和故障机制,从而实现更精确的剩余寿命评估。

预测器  $P$  的职责是基于特征提取器  $G$  提取的特征进行最终的剩余寿命预测。为了避免过拟合,并提高模型的泛化能力,在模型设计和训练过程中采取了多种措施。通过引入 L2 正则化和 Dropout 技术,前者在损失函数中添加权重平方和项,惩罚过大的权重值,从而防止模型过拟合;后者则在训练过程中随机丢弃部分神经元,有效防止神经元之间的共适应性。此外,在训练过程中采用了早停策略,在每个训练周期后评估模型在验证集上的表现,一旦验证集上的性能不再提升,立即停止训练,从而提高模型的泛化能力。通过应用适当的激活函数, $P$  将这些高维特征转换为最终的剩余寿命预测值。这一预测值是一个标量,代表了预测评估的剩余寿命。在本模型中,特征提取器  $G$  与预测器  $P$  的协同工作, $G$  负责深入挖掘并编码输入数据中的关键信息, $P$  则基于这些信息进行精确的剩余寿命预测评估。测试表明,本研究提出的模型在进行小样本剩余寿命预测时能够实现更高的准确性和鲁棒性。

## 2.3 特征领域判别器和语义领域判别器

为了实现从大样本设备数据集到小样本装备数据集的有效迁移学习,本研究采用了特征对齐和语义对齐的策略。2个领域判别器的结构和任务相似,都由一个隐藏层和 Sigmoid 激活函数的多层感知器组成。特征级判别器使用从数据中提取的特征进行判别,而语义级领域判别器使用模型的预测输出进行判别。对于剩余寿命预测任务,期望不同域之间的预测输出应相似。本文的目标是使2个域上的输出曲线无法区分,这恰好符合语义级判别器的原则。

### 2.3.1 特征对齐判别器

本研究中特征对齐的核心在于调整特征提取器  $G$ ,以适应装备数据的特有分布特征。在对各类数据分别进行特征提取后,通过多头注意力机制将这些特征进行融合,生成综合特征向量。这种方法不仅能够

捕捉各数据源之间的内在联系,还能提高特征表示的丰富性和鲁棒性。在数据融合过程中,特别关注数据的异质性和不确定性,引入最大平均差异 (Maximum Mean Discrepancy, MMD) 方法来对齐源域和目标域特征,确保模型在处理异构数据时能够保持稳定性和一致性。MMD 通过衡量源域和目标域特征分布的差异,并在训练过程中最小化这一差异,从而实现特征对齐。这一系列措施显著提高了模型在装备剩余寿命预测中的性能,既避免了过拟合问题,又提升了对小样本、多源数据的处理能力,确保了预测结果的准确性和可靠性。在  $G$  的结构优化过程中,采用网格搜索方法确定最优的编码层数  $L$  和自注意力头数  $H$ ,搜索范围分别设置为  $L \in \{2, 4, 6, 8\}$  和  $H \in \{4, 8\}$ ,通过在验证集上评估各组合的性能,选取最优结构配置,形成最终的提取器  $G_{\text{Trans}}$ ,以此提高模型对装备数据特定模式和特征的适应能力。 $G_{\text{Trans}}$  的输出特征  $f$  可表示为:

$$f = G_{\text{Trans}}(x; L^*, H^*, \theta_{G_{\text{Trans}}}) \quad (5)$$

式中:  $x$  为输入数据;  $L^*$  和  $H^*$  分别为通过搜索得到的最优编码层数和自注意力头数;  $\theta_{G_{\text{Trans}}}$  为模型参数。

为了进一步对齐源域和目标域的特征,本文设计了基于生成对抗网络 (GAN) 的自适应映射机制。在这个设置中,GAN 的生成器  $G_{\text{GAN}}$  被用来转换源域特征,使其分布接近目标域特征的分布。判别器  $D$  为一个包含 3 层全连接网络且激活函数为 ReLU 的模型,用来区分转换后的源域特征与目标域特征。判别器的损失函数和生成器的损失函数分别定义如下:

$$\mathcal{L}_D = -\mathbb{E}_{x_s \sim \mathcal{D}_s} [\log D(f_s)] - \mathbb{E}_{x_t \sim \mathcal{D}_t} \{\log [1 - D(f_t)]\} \quad (6)$$

$$\mathcal{L}_G = -\mathbb{E}_{x_t \sim \mathcal{D}_t} [\log D(f_t)] \quad (7)$$

为了稳定 GAN 训练,还引入了梯度惩罚项:

$$\lambda_{\text{GP}} \mathbb{E}_{f \sim P_f} \left\{ \left[ \left\| \nabla_f D(f) \right\|_2 - 1 \right]^2 \right\} \quad (8)$$

$$k(f_i, f_j) = \exp \left( -\frac{\|f_i - f_j\|^2}{2\sigma^2} \right) \quad (9)$$

综上,特征对齐的总损失可以定义为:

$$\mathcal{L}_{\text{feat}} = \lambda_{\text{GP}} \mathcal{L}_{\text{GP}} + \lambda_{\text{MMD}} \mathcal{L}_{\text{MMD}} \quad (10)$$

式中:  $\lambda_{\text{GP}}$  和  $\lambda_{\text{MMD}}$  是调节对应损失项影响的权重系数。

特征对齐的流程如图 2 所示。

### 2.3.2 语义对齐判别器

语义对齐的目的是确保模型在处理源域和目标域数据时,能够生成语义上一致的输出。本研究引入了装备领域的本体 (Ontology),通过与领域专家合作构建,定义了装备的关键组成部分和故障模式等概念。语义对齐关注于确保模型在源域和目标域生成语义上一致的输出,语义对齐的流程如图 3 所示。

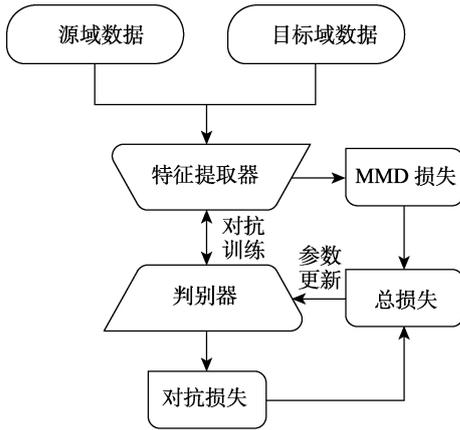


图 2 特征对齐流程  
Fig.2 Feature Alignment Process

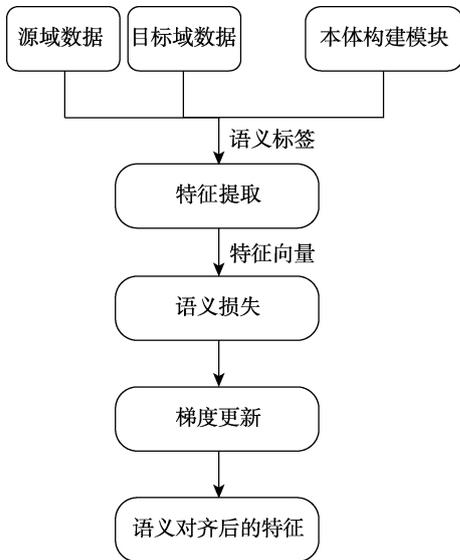


图 3 语义对齐流程  
Fig.3 Semantic Alignment Process

语义对齐的损失函数设计为:

$$\mathcal{L}_{\text{semi}} = -\sum_{i=1}^K \mathbb{I}(Y_s = c_i) \log p(c_i | \mathbf{x}_s) - \sum_{j=1}^K \mathbb{I}(Y_t = c_j) \log p(c_j | \mathbf{x}_t) \quad (11)$$

综上所述, 总的损失函数为:

$$\mathcal{L} = \mathcal{L}_{\text{feat}} + \gamma \mathcal{L}_{\text{semi}} \quad (12)$$

语义对齐模块利用领域本体知识, 通过对源域和目标域样本进行语义标注和对齐, 促进模型在目标域上的泛化能力。特征对齐模块则通过对抗训练和 MMD 损失, 学习域不变的特征表示, 减少源域和目标域之间的分布差异。语义对齐和特征对齐的引入, 有效地解决了小样本问题带来的挑战。一方面, 语义对齐利用本体知识作为先验, 为样本提供了额外的语义信息, 缓解了标注数据不足的问题。另一方面, 特征对齐通过对抗训练和 MMD 损失, 显著减少了源域和目标域之间的分布差异, 使得模型能够更好地适应目标域数据, 提高了在目标域上的预测性能。根据小

样本数据的特性, 也对全连接层和自注意力层的参数进行了优化, 包括调整权重初始化方法和学习率策略。由于小样本的特性, 引入早停 (Early Stopping)、L2 正则化和 Dropout, 以避免模型在小样本数据上过度拟合。上述一系列的策略有助于模型更好地理解 and 适应领域特性, 有效提升了预测性能。

### 3 仿真实验

#### 3.1 数据集设置

本研究采用了迁移学习的方法, 以 NASA 的 CMAPSS ( Commercial Modular Aero-Propulsion System Simulation )和其新版本 N-CMAPSS 数据集作为模型评估的源域基准。这 2 个数据集分别描述了大型商用涡轮风扇发动机模拟直至失效的运行数据和基于真实飞机数据生成的高保真度数据。CMAPSS 数据集被广泛用于学术研究, 根据不同的运行条件和故障类型, 它被划分为 4 个子集, 每个子集包含数百台发动机单元的 24 种不同传感器测量数据。N-CMAPSS 则在同样的建模策略下, 加入了新的保真度级别和更多的传感器维度, 提供了更接近实际应用的数据分析环境。

在装备剩余寿命预测研究中, 特别关注陀螺仪等关键电子部件的性能退化。以陀螺仪为例, 作为装备导引系统的核心部件, 其性能直接关系到导航的准确性和任务的成败。在长期贮存和使用过程中, 陀螺仪不可避免地受到各种外界因素 (如随机振动和冲击) 的影响, 从而加速性能退化。而电子芯片设备作为装备关键信息的传输和处理核心, 其失效将严重影响装备的作战效能。因此, 有效迁移航空发动机领域的知识到装备系统领域至关重要。考虑到 2 个系统在运行条件和性能退化机制上的本质差异, 本研究在模型设计和特征工程中充分考虑了这些差异, 以确保迁移学习能够精准适应装备系统的特定需求。为此, 本研究构建了包含陀螺仪、各部位电压电流等多个关键节点采样的多源异构数据。这些数据有助于全面分析装备在不同环境和条件下的性能退化, 从而提高剩余寿命预测的准确性和可靠性。

本研究使用的数据集来源于某型号高可靠性航空装备, 包含环境数据和关键电位数据两大类。数据采集跨度为装备的贮存期 10 a, 具体构成如下:

1) 环境数据。主要包括温度和湿度信息, 采样频率为每天 1 次, 累计 3 650 条记录。这些数据反映了装备在不同时间点所处的环境状况, 为分析环境因素对装备性能的影响提供了基础。

2) 关键电位数据。每半年采集 1 次, 每次在装备的数个关键点进行测量。10 年内共进行了 20 次采样, 累计获得约 110 个数据点。这些数据直接反映了装备在特定时间点的工作状态和性能指标。

为了有效利用这2类数据,在预处理阶段采取了插值方法对关键电位数据进行时间对齐,以实现与环境数据的融合。确保了不同来源数据的时间一致性,为后续的特征提取和模型训练奠定了基础。

由于训练集和测试集的数据规模存在明显差异,即源域和目标域的尺度不同,为了减小域间差异,并使训练过程更平滑,采用了 min-max normalization 方法将数据缩放至(0,1)。具体到 NASA-CMAPSS 数据集,其中  $x_i$  为第  $i$  个传感器的读数,  $x_{\max,i}$  和  $x_{\min,i}$  分别为第  $i$  个传感器读数的最大值和最小值,对于数据集中的缺失值,直接设置为 0。为了从原始数据中提取有效数据,本研究采取滑动窗口构造输入序列。由于 Transformer 处理长序列能力较为突出,但随着序列长度的增加,观察到模型开始更多地依赖于序列中的位置信息,即更倾向于从序列中元素的相对位置去直接推断结果,这违背了希望模型能够深入挖掘传感器数据背后深层次退化模式的初衷。因此,在选择序列长度时,需要选取的序列既能够展示出丰富的退化模式,又不会让模型仅仅将位置信息与预测结果简单地直接关联起来。经过一系列实验后,结合 CMAPSS 和 N-CMAPSS 数据集中建议的平均循环次数,本研究使用的序列长度为 50 和 25。滑窗长度可以确保模型能够学习到影响剩余寿命的关键因素的同时,避免过度依赖其他噪声信息。

## 3.2 评估指标

为了全面评估所提出的基于迁移学习的模型在装备剩余寿命预测评估中的性能,本研究采用均方根误差  $\delta_{\text{RMSE}}$  (Root Mean Square Error, RMSE) 和核密度估计作为主要的评估指标。RMSE 是预测评估精度评估中常用的标准,它能够量化模型预测值与实际值之间的偏差。在本研究的背景下, RMSE 特别适用于衡量预测的剩余寿命与真实剩余寿命之间的差异,其计算公式为:

$$\delta_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

式中:  $n$  代表样本总数;  $y_i$  是第  $i$  个样本的实际剩余寿命值;  $\hat{y}_i$  是对应的预测值。  $\delta_{\text{RMSE}}$  的值越小,表明模型的预测评估精度越高,误差越小。这一指标不仅反映了预测评估误差的平均水平,也能够通过其平方根形式直观地展现误差的实际大小,使得评估结果更易于理解和解释。本研究使用 RMSE 对模型进行评估,计算网络在不同测试子集 (CMAPSS 和装备寿命数据) 上的表现,以确保模型在各种运行条件和故障类型下均具有良好的泛化能力和预测评估准确性。

核密度估计<sup>[23-25]</sup> (Kernel Density Estimation, KDE) 是一种非参数的方式来估计随机变量的概率密度函数。在核密度堆积图中,横轴表示剩余寿命的值,纵轴表示相应值的概率密度。图中的曲线显示了预测

剩余寿命值在不同区间的密度,可以帮助理解模型预测值的变异性和集中趋势。在核密度估计图中的纵轴代表的是概率密度,具体来说,它表示在某个特定的剩余寿命值附近,数据点出现的密度有多高。这里的“密度”不是数据点的绝对数量,而是在考虑数据分布范围的情况下,数据点在该区域集中的程度。

## 3.3 实验设置与结果

实验平台的设置为 Python 3.10 及 PyTorch 1.12.1,硬件系统为 Intel i7-12700 与 NVIDIA GeForce RTX 3070。注意力头数量为 4,分别处理来自不同源数据的特征,而后汇总到一个层中。在演化过程中,对梯度进行归一化处理,使用 Adam 进行参数学习,其学习率设定为 0.001,并且使用梯度裁剪来避免梯度爆炸。最后,在回归分析阶段,使用一个单层的带偏置 MLP 进行最终剩余寿命的预测评估。

### 3.3.1 消融实验

为了评估对齐模块在本文提出的剩余寿命预测模型中的有效性和必要性,设计了一系列消融实验。通过比较完整模型和不同的消融模型在测试集上的性能表现,可以量化对齐模块对模型性能的贡献,并验证其在特征对齐和信息传递方面的作用。本研究采用以下方案:

1) 基准模型 (完整模型)。使用本文提出的完整模型进行剩余寿命预测,包括 Transformer 编码器、解码器和对齐模块。

2) 消融模型 1 (移除特征对齐模块)。在完整模型的基础上,移除特征对齐模块,直接将编码器的输出传递给解码器。

3) 消融模型 2 (移除语义对齐模块)。在完整模型的基础上,将语义对齐模块替换为简单的特征拼接 (Concatenation) 操作。

4) 消融模型 3 (随机对齐)。在完整模型的基础上,将对齐模块中的注意力权重替换为随机生成的权重矩阵。

所有模型都使用与完整模型相同的训练集和测试集,并采用相同的超参数设置和训练策略。使用平均绝对误差 (MAE) 和均方根误差 (RMSE) 作为评估指标,衡量模型在测试集上的预测性能,比较两组配对样本之间的均值差异是否显著。

完整模型与 3 个消融变体在测试集上的性能对比见表 1。实验结果显示,完整模型在 MAE 和 RMSE 指标上均优于其他变体,充分证实了特征对齐模块和语义对齐模块对模型性能的显著贡献。具体分析每个实验,移除特征对齐模块,导致 MAE 和 RMSE 分别增加 88.4% 和 69.4%。这一显著差异表明特征对齐模块在捕获和融合多源异构数据特征方面起到了关键作用,特别是在处理加速寿命试验数据和环境剖面数据的融合时,该模块的贡献尤为突出。移除语义对齐

模块, 使 RMSE 增加 41.4%, 虽然影响程度低于特征对齐模块, 但仍然证实了其在提升模型性能, 特别是在保证预测结果语义一致性方面的重要性。采用随机对齐策略的模型表现最差, MAE 和 RMSE 分别增加 259%和 231%。这一结果说明了本文提出的基于注意力机制的对齐方法在特征融合过程中的必要性和有效性。随机对齐无法有效捕获不同数据源之间的内在关联, 导致模型性能急剧下降。

表 1 消融实验结果  
Tab.1 Ablation Study Results

模型	MAE	RMSE
完整模型	6.83	7.98
移除特征对齐模块	12.87	13.52
移除语义对齐模块	10.69	11.28
随机对齐	24.55	26.46

这组实验结果不仅验证了所提方法各组件在处理某类高可靠性航空装备数据时的有效性, 还为进一步优化模型结构提供了重要依据。特征对齐模块的突出作用表明, 在小样本场景下, 有效的特征提取和融合对于提高预测精度至关重要。同时, 语义对齐模块的贡献也不容忽视, 它确保了模型在不同数据域之间保持语义一致性, 这对于模型的泛化能力和可解释性具有重要意义。上述消融实验表明, 对齐模块在剩余寿命预测任务中发挥了关键作用, 能够有效地融合不同传感器的特征信息, 提高预测的准确性。

完整模型对小样本装备数据的预测评估结果如图 4 所示, 本文提出的模型在剩余寿命预测评估任务上取得了显著的成果。模型预测评估的均方根误差 (RMSE) 达到了 7.98, 最小绝对误差为 0.33, 预测评估结果与真实值之间展现出了较高的吻合度, 这不仅验证了模型在理论上的正确性, 也体现了其在实际应用场景中的可行性。说明模型网络对数据特征的充分学习以及对跨域知识迁移能力的有效利用, 本文提出的模型展现出了较高的性能。

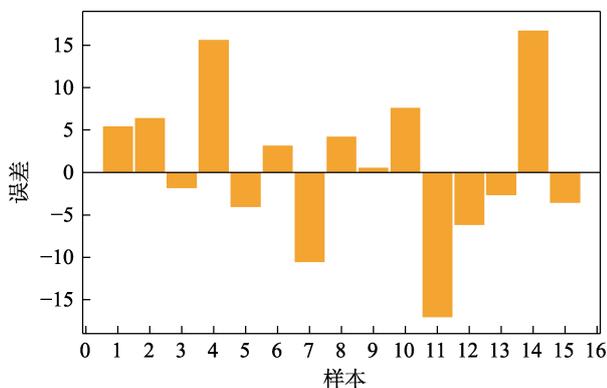


图 4 样本剩余寿命预测评估值的均方根误差  
Fig.4 Root mean square error of residual life prediction estimates for samples

### 3.3.2 不确定性估计

不确定性估计是装备剩余寿命预测中一个重要而又常被忽视的问题。传统的预测模型通常只给出一个确定的预测值, 而忽略了预测结果本身的不确定性。这种不确定性来源于多个方面, 如测量噪声、建模误差、数据质量等, 如果不加以量化和评估, 就无法全面地理解预测结果的可靠性, 从而影响决策的制定。综合分析预测期望值和置信区间, 可以更全面、更客观地评估装备的健康状况和剩余寿命。一方面, 预测期望值为制定维修计划提供了重要依据, 如安排定期检修、部件更换等; 另一方面, 置信区间揭示了预测结果的风险程度, 为决策制定增添了一层风险意识, 以应对预测的不确定性风险。这种基于置信度估计的分析, 有助于制定更稳健、更经济的维护策略, 在保证装备可靠性的同时, 也避免了过度或不足的维修投入。

在核密度堆积图 (图 5) 中, 横轴代表剩余寿命的时间 (h), 纵轴表示相应的概率密度。图中实线反映了剩余寿命的概率分布, 而虚线分别表示了 95% 置信区间 (50.8~135.6 个月) 和剩余寿命的最大密度点 (94.2 个月)。从图 5 中可以看出, 剩余寿命的分布呈现近似正态分布的形态, 其最大密度点位于 94.2 个月, 表明在该预测评估模型中, 大部分的剩余寿命预测评估值集中在此时间点附近。此外, 置信区间的标注提供了预测评估的不确定性范围, 从 50.8~135.6 个月, 这表示在 95% 的置信水平下, 真实的剩余寿命有很大概率会落在这个区间内。

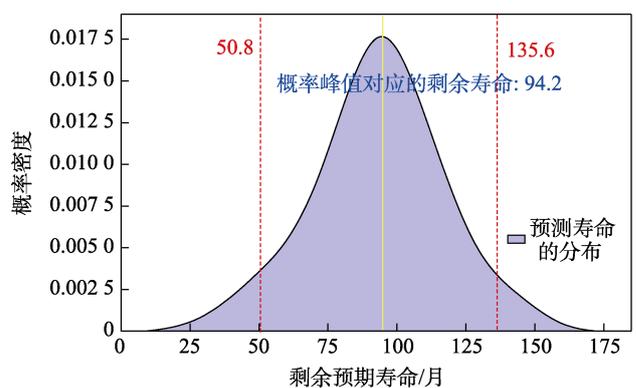


图 5 剩余寿命核密度堆积图  
Fig.5 Residual life kernel density

实际剩余寿命与预测评估剩余寿命值之间的对比曲线如图 6 所示。可以看出, 本研究提出的模型预测评估结果与实际值在大多数点上较为接近, 尤其是在样本 4~8, 预测评估曲线与实际曲线的走势十分吻合。从 RMSE 结果图中可以得到类似的结论。

业界对小样本装备尤其是装备的剩余寿命研究多集中在使用非线性系统、Clayton Copula 函数、Wiener 分布模型或者基础的 LSTM 的方法, 对比这些方法, 本文提出的方法适用性更广, 可以针对不同

的装备进行预测评估，且预测评估精度更高，对比结果见表2。

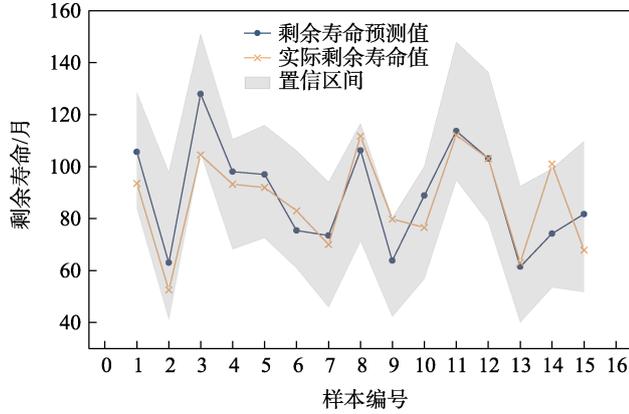


图6 预测评估值与真实值对比曲线

Fig.6 Prediction Evaluation Values vs. True Values Comparison Curve

表2 不同方法的结果对比

Tab.2 Comparison of results from different methods

方法	寿命平均预测值/月	RMSE	绝对最大误差/月	绝对最小误差/月
本文方法	94.2	7.98	19.2	0.2
Copula 函数估计法	87.1	10.49	20.2	1.7
Wiener 分布模型	72.2	13.56	25.4	2.8
非线性系统估计	88.4	10.77	21.9	2.4
Bi-LSTM	75.6	9.02	19.4	0.8

预测置信度估计的结果也为模型的持续改进指明了方向。通过分析置信区间覆盖率、区间宽度等指标，本文可以评估模型在不同工况、不同退化模式下的预测能力。对于置信区间较宽、覆盖率较低的预测结果，往往提示本文现有模型在这些情况下存在不足，需要进一步优化模型结构、引入领域知识，以提高预测的确定性。这种数据驱动模型诊断和改进，可以帮助本文建立更鲁棒、更可靠的预测模型，为装备健康管理提供更有力的支撑。

### 4 结语

针对某类航空装备的小样本剩余寿命预测评估问题，本文提出了一种基于 Transformer 的多源数据融合预测评估方法。提出的模型能够有效融合设备各部分传感器节点的感知数据，通过多头注意力机制建立多源数据融合模型，从不同传感器工作数据中提取关键信息，并综合处理数据间的关联及演化关系，实现了装备剩余寿命的精准估计。针对装备数据采样较少的问题，本文引入迁移学习方法，利用公开数据集作为输入，通过语义对齐和特征对齐 2 个独特的模块，提高了模型在小样本情况下的预测评估性能。语

义对齐模块通过正则化手段，有效减小了预测评估输出中因特征缩放不当而导致的误差，确保了输出曲线的合理性和准确性。特征对齐模块能够提取既有辨识度又具有跨域一致性的特征，进一步增强了模型的泛化能力和预测评估准确性。通过细致分析预测的期望值和置信区间，本研究不仅全面评估了装备的健康状况和剩余寿命，还为制定科学的维护策略和模型持续优化提供了重要支持。基于真实数据采样的实验结果表明，与现有方法相比，本文提出的方法在小样本情况下显著提升了剩余寿命预测评估的准确性。

### 参考文献:

- [1] GAO J, HUANG D P, LI X B. Overall Solution of Comprehensive Evaluation for Missile Storage Life[J]. Applied Mechanics and Materials, 2015, 724: 307-311.
- [2] PEI H. Review of Machine Learning Based Remaining Useful Life Prediction Methods for Equipment[J]. Journal of Mechanical Engineering, 2019, 55(8): 1.
- [3] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17). Red Hook: Curran Associates Inc, 2017.
- [4] SHAO Y F, GENG Z C, LIU Y T, et al. CPT: A Pre-Trained Unbalanced Transformer for both Chinese Language Understanding and Generation[J]. Science China Information Sciences, 2024, 67(5): 152102.
- [5] ALEXEY D. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale[C]// 9th International Conference on Learning Representations. Virtual Event: ICLR, 2021.
- [6] DONG L H, XU S, XU B. Speech-Transformer: A No-Recurrence Sequence-to-Sequence Model for Speech Recognition[C]//2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Calgary: IEEE, 2018.
- [7] HAN X, ZHANG Z Y, DING N, et al. Pre-Trained Models: Past, Present and Future[J]. AI Open, 2021, 2: 225-250.
- [8] HAN K, WANG Y H, CHEN H T, et al. A Survey on Vision Transformer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(1): 87-110.
- [9] BAI Y, CHEN F, WANG H Q, et al. Transformers as Statisticians: Provable In-Context Learning with In-Context Algorithm Selection[J]. Advances in Neural Information Processing Systems, 2024, 36: 1-93.
- [10] PENG Z L, GUO Z H, HUANG W, et al. Conformer: Local Features Coupling Global Representations for Recognition and Detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(8): 9454-9468.
- [11] CHEN X, WU Y, WANG Z H, et al. Developing Real-Time Streaming Transformer Transducer for Speech

- Recognition on Large-Scale Dataset[C]//ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Toronto: IEEE, 2021.
- [12] PANDEY M, FERNANDEZ M, GENTILE F, et al. The Transformational Role of GPU Computing and Deep Learning in Drug Discovery[J]. *Nature Machine Intelligence*, 2022, 4: 211-221.
- [13] RIVES A, MEIER J, SERCU T, et al. Biological Structure and Function Emerge from Scaling Unsupervised Learning to 250 Million Protein Sequences[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2021, 118(15): e2016239118.
- [14] LI S Y, JIN X Y, XUAN Y, et al. Enhancing the Locality and Breaking the Memory Bottleneck of Transformer on Time Series Forecasting[EB/OL]. 2019: 1907.00235. <https://arxiv.org/abs/1907.00235v3>
- [15] WANG Y, PENG J J, WANG X H, et al. Replacing Self-Attentions with Convolutional Layers in Multivariate Long Sequence Time-Series Forecasting[J]. *Applied Intelligence*, 2024, 54(1): 522-543.
- [16] YI K, ZHANG Q, FAN W, et al. Frequency-Domain MLPs Are More Effective Learners in Time Series Forecasting[C]//Proceedings of the 37th International Conference on Neural Information Processing Systems (NIPS '23). Red Hook:Curran Associates Inc,2024.
- [17] TERVEN J, CORDOVA-ESPARZA D. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS[EB/OL]. 2023: 2304.00501.<https://arxiv.org/abs/2304.00501v7>.
- [18] ZHANG C, ZHANG C J, GUO Y L, et al. MotionTrack: End-to-End Transformer-Based Multi-Object Tracking with LiDAR-Camera Fusion[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Vancouver: IEEE, 2023.
- [19] SUN C, MYERS A, VONDRICK C, et al. VideoBERT: A Joint Model for Video and Language Representation Learning[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019: 7463-7472.
- [20] CHEN J, TAN X, LENG Y, et al. Speech-T: Transducer for Text to Speech and Beyond[J]. *Advances in Neural Information Processing Systems*, 2021, 34: 6621-6633.
- [21] LIANG J, HU D P, FENG J S, et al. Do we Really Need to Access the Source Data? Source Hypothesis Transfer for Unsupervised Domain Adaptation[EB/OL]. 2020: 2002.08546.<https://arxiv.org/abs/2002.08546v6>
- [22] CHEN L, CHEN H A, WEI Z X, et al. Reusing the Task-Specific Classifier as a Discriminator: Discriminator-Free Adversarial Domain Adaptation[C]// 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans: IEEE, 2022.
- [23] WĘGLARCZYK S. Kernel Density Estimation and Its Application[J]. *ITM Web of Conferences*, 2018, 23: 00037.
- [24] GRAMACKI A. Nonparametric Kernel Density Estimation and Its Computational Aspects[M]. Switzerland: Springer International Publishing, 2018: 7-24.
- [25] KIM J S, SCOTT C D. Robust Kernel Density Estimation[J]. *The Journal of Machine Learning Research*, 2012, 13(1): 2529-2565.