

涡扇发动机剩余使用寿命估计：一种基于深度学习的滑动时间窗方法

高睿哲, 宋浩宇*

东南大学物理学院, 南京 211189, 江苏, 中国

摘要：系统退化是航空航天领域中普遍且不可避免的过程。为避免复杂工业系统发生非预期停机，人们采用预测与健康管理技术，借助大量传感器评估系统的健康状态及其剩余使用寿命（RUL）。已有众多研究者利用深度学习方法，依据传感器数据估计 RUL，其中多数工作只用单一深度神经网络（DNN）模型求解该问题。本文基于多个 DNN 模型构建了一种新的涡扇发动机 RUL 预测器。该方法采用时间窗技术准备样本，增强了 DNN 提取特征与学习涡扇发动机退化规律的能力。此外，本文用公认的模型评价指标验证了所提方法的有效性。实验结果表明，在四种不同的 DNN 中，基于长短期记忆网络（LSTM）的预测器在独立测试集上取得了更好的成绩：均方根误差为 15.30，平均绝对误差为 2.03，决定系数为 0.4354，优于此前报道的涡扇发动机 RUL 估计方法。

关键词：C-MAPSS；卷积神经网络；深度特征；预测与健康管理；循环神经网络；剩余使用寿命预测；涡扇发动机

Remaining Useful Life Estimation of Turbofan Engine: a Sliding Time Window Approach Using Deep Learning

RuiZhe Gao, HaoYu Song*

School of Physics, Southeast University, Nanjing 211189, Jiangsu, China

Abstract: System degradation is a common and unavoidable process that frequently occurs in aerospace sector. Thus, prognostics is employed to avoid unforeseen breakdowns in intricate industrial systems. In prognostics, the system health status, and its remaining useful life (RUL) are evaluated using numerous sensors. Numerous researchers have utilized deep-learning techniques to estimate RUL based on sensor data. Most of the studies proposed solving this problem with a single deep neural network (DNN) model. This paper developed a novel turbofan engine RUL predictor based on several DNN models. The method includes a time window technique for sample preparation, enhancing DNN's ability to extract features and learn the pattern of turbofan engine degradation. Furthermore, the effectiveness of the proposed approach was confirmed using well-known model evaluation metrics. The experimental results demonstrated that among four different DNNs, the long short-term memory (LSTM)-based predictor achieved the better scores on an independent testing dataset with a root-mean-square error of 15.30, mean absolute error score of 2.03, and R-squared score of 0.4354, which outperformed the previously reported results of turbofan RUL estimation methods.



Keywords: CMAPSS; Convolutional neural network; Deep features; Prognostics; Recurrent neural networks; RUL prediction; Turbofan engine

一、引言

预测与健康管理 (PHM) 是一门新兴学科, 其首要目标是预测给定系统未来的健康状况、定位潜在故障, 并促成及时的维护干预, 从而提高系统的可靠性与运行可用性[1]。随着航空航天、汽车和制造等现代工程系统的复杂度不断上升, 对能够处理海量数据并给出精确预测的先进 PHM 方法的需求也日益迫切[2-3]。过去数十年间, 为提升系统可靠性、安全性与效率的需要推动了 PHM 概念的演进[4]。PHM 最初主要用于航空航天工业, 以监测航空发动机的健康状态并预测其剩余使用寿命[5]。随着传感器技术、数据分析与机器学习算法的进步, PHM 的适用范围已扩展至其他领域[6], 如今被广泛应用于风力机[7]、医疗器械和基础设施系统[8]等场景。

尽管 PHM 具有诸多固有优势, 但仍须正视若干挑战。首要的挑战在于该学科尚缺乏标准化实践, 这使得不同 PHM 方法之间的横向比较变得复杂[9]。另一个障碍在于训练预测模型需要获取大量高质量数据, 而这一过程往往成本高昂、耗时漫长。此外, PHM 需要跨学科的专业知识, 而这类知识并非总能随时获得。深度学习 (DL) 作为机器学习的一个分支, 凭借其理解输入特征与预测结果之间复杂关联的能力, 在 PHM 领域展现出显著潜力。近年来, 卷积神经网络 (CNN)、循环神经网络 (RNN) 和自编码器等源自 DL 的方法, 已在 PHM 研究中得到广泛应用。

在故障诊断领域, 深度学习方法通过分析传感器数据, 在识别与归类故障方面发挥了重要作用。CNN 已被证明能够有效地从传感器信号中提取特征, RNN 则被用于捕捉传感器测量值之间的时序依赖关系。自编码器同样被用于故障检测: 先学习系统的正常运行状态, 再检测偏离该状态的异常。在剩余使用寿命 (RUL) 预测方面, DL 模型被用于依据系统当前与既往的健康状态预测其 RUL; CNN 与 RNN 被用于对系统健康的时间演化建模, 自编码器则被用于学习传感器数据的底层特征表示。深度学习在 PHM 中的另一项重要应用是异常检测: DL 模型被用于识别传感器数据中的异常行为, 这类行为可能预示潜在故障; CNN 与自编码器在传感器数据异常检测中同样表现有效。不过, 本研究聚焦于处于 PHM 第三层级的 RUL 预测。

本文旨在对预测领域中用于 RUL 预测的主流深度学习架构作出比较分析, 重点考察 CNN、RNN、LSTM 网络与门控循环单元 (GRU) 模型, 并依据预测精度、计算复杂度以及对未见数据的泛化能力评价这些架构的性能, 以期与实践者与研究者提供关于上述架构及其在 RUL 预测中相对优劣的全面认识。本文方法的有效性通过 NASA 提供的商用模块化航空推进系统仿真 (C-MAPSS) 涡扇航空发动机基准数据集加以验证。

本文其余部分安排如下: 第二节全面综述构成本研究背景的背景与相关文献; 第三节阐述所建议的研究方法; 第四节考察并剖析实验所得结果; 第五节讨论研究发现与分析; 第六节总结本研究的结论, 并指出未来研究的可能方向。

二、相关研究

在航空航天领域, 保障安全性与可靠性是决定运行效率的首要考量。旋转机械在各行各业中都扮演关键角色, 却因运行环境严苛、使用时长过久而易于失效。此类系统一旦发生故障, 将导致运行中断并造成巨大的经济损失。因此, 挖掘设备数据与其 RUL 之间的监测关系, 在数据驱动的预测研究中受到高度关注。研究者已提出众多机器学习算法 (尤其是神经网络方法), 用以揭示所采集的特征数据与预期 RUL 之间的关联。将神经网络用于 PHM 的优势在于: 无须预先掌握系统的物理行为, 即可对复杂、高度非线性的多维结构建模; 原始传感器读数等多种设备数据可直接作为模型输入。然而, 为应用于预测问题的深度神经网络 (DNN) 方法建

立自然的置信区间仍是难题, 尽管基于 DNN 的预测方法已展现出令人鼓舞的结果。

Fentaye 等采用传统的多层感知机 (MLP) 技术, 在实验室测试中预测轴承的 RUL, 其预测性能优于基于可靠性的备选方案。Fink 等提出了一种采用多值神经元的多层神经网络方法, 专门用于应对性能与退化时间序列的预测难题, 并以铁路道岔系统的劣化为对象开展了案例研究。Khawaja 等设计了一种含置信分布节点的置信预测神经网络方法, 以弥补神经网络技术难以为 RUL 预测给出显式置信区间的不足。此外, 若干模糊逻辑方法也被整合进 MLP 网络, 以增强 PHM 的学习能力。在 RNN 方面, Malhi 等提出把 RNN 与竞争学习技术用于机械健康状态的长期预测: 他们先用连续小波变换对取自故障滚动轴承的振动信号作预处理, 再把这些预处理后的指标作为模型输入。有研究者建议将长短期记忆 (LSTM) 方法用于航空发动机的 RUL 预测, 以应对操作高度复杂、故障混合、噪声水平显著的场景, 其能力超出常规 RNN。Zhao 等把 LSTM 网络用于刀具磨损健康监测任务, 并在方法中同时融合了频域与时域特征。Ren 等提出了一种经过优化的深度学习技术, 用于多个轴承 RUL 的协同估计, 并通过真实数据集上的数值评估证实了该方法的可行性与优越性。Liao 等提出了一种用于表示学习的新型受限玻尔兹曼机来确定机器的 RUL, 其中引入了新的正则化项和一种无监督自组织映射算法。Zhang 等提出了多目标深度信念网络 (DBN) 集成方法, 把进化算法与常规 DBN 训练方法相结合, 同时构建多个兼顾精度与多样性的 DBN。

在 Zheng 等的另一项研究中, 作者基于时序表示的 LSTM, 利用 C-MAPSS 基准数据集预测涡扇发动机的 RUL。文献则提出用 CNN 估计同类发动机的 RUL, 该流程以时间窗方法得到的特征作为模型输入, 因而需要采集更多的退化数据。这样一来模型输入的维度随之上升, 给 DNN 模型的构建带来困难: 既要设置合适的网络节点数与网络层数以避免过拟合、降低时间与计算开销, 又要避免陷入局部极小点。Muneer 等给出了四种数据驱动的预测模型, 采用带注意力机制的 DNN 精确估计涡扇发动机的 RUL; 这些模型借助滑动时间窗方法增强 DNN 的特征提取能力, 无须预先掌握预测或信号处理知识。为进一步改进涡扇发动机的 RUL 预测, Muneer 等还提出了一种基于注意力机制的新型深度 CNN 设计, 通过依据可处理性度量选择特征、并用时间窗技术准备样本, 充分利用多变量时序信息。Peng 等^[1]近期的另一项研究提出把一维 CNN 与 LSTM、全卷积层相结合 (1-FCLCNN) 作为 RUL 预测手段, 利用 LSTM 与 1-FCLCNN 从涡扇发动机的 FD003 与 FD001 数据集中提取空间与时间特征。CNN 在 RUL 相关学科中的应用同样受到研究者的高度重视。Babu 等最早把深度 CNN 方法用于 RUL 预测, 数据显示 CNN 的表现优于 MLP、SVM 与 SVR 模型; 该方法在 C-MAPSS 数据集上经检验, 得到的均方根误差为 18.45。

与之类似, Li 等提出了一种深度 CNN 时间窗方法以改进信号提取, 该方法在 NASA 涡扇发动机 (C-MAPSS 数据集) 退化问题上经过检验并展现出明显优势。不过, 即便 CNN 模型性能优异, 其训练耗时仍长于其他浅层方法, 计算负担较重, 仍需进一步优化。Wen 等提出了全新的残差 CNN (ResCNN): 残差块通过快捷连接跨越若干卷积层块, 有助于缓解梯度消失 / 爆炸问题; k 折集成方法则进一步增强了 ResCNN 的效果, 所提出的集成 ResCNN 在 NASA 的 C-MAPSS 基准数据集上得到验证。文献提出了另一种面向 RUL 预测的深度特征学习技术, 采用多尺度 CNN (MS-CNN) 与时频表示 (TFR)。TFR 能够有效刻画轴承退化信号的非平稳特性; 借助小波变换, 作者累积时序退化信号并生成信息丰富的 TFR。由于这些 TFR 维度很高, 在输入深度学习模型之前需先用双线性插值降维。然而该方法存在若干局限: 其一, 算法训练速度偏慢, 计算速度有待提升; 其二, 必须借助图形处理器来承担主要的 TFR 处理任务。

此外, Li 等提出了一种结构为受控无环图、融合 LSTM 与 CNN 的网络, 以改进机械的 RUL 估计。Li 等注意到, 当以单个时间戳作为输入时, 同一训练批次内的填充信号会损害该融合方法的整体预测能力。

为缓解这一问题, 作者用所提方法构造短时序列, 并以单相时长为步长移动时间窗 (TW); 同时依据退化机理, 用分段 RUL 技术取代常规的线性函数。作者最后指出, 增大时间窗长度可以提高所提模型的精度。Zhang 等的另一项研究采用基于 CNN 的极端梯度提升 (CNN-XGB) 并扩展时间窗, 以应对航空发动机系统常在多种工况下运行所带来的难题——工况变化会以不同方式影响系统的退化路径, 从而妨碍 RUL 预测的准确性。该方法在 NASA C-MAPSS 涡扇航空发动机数据集上得到验证, 均方根误差为 20.3, 报告的训练时长为 621.7 秒。Wang 等提出用 MS-CNN 估计滚动轴承的 RUL; Liu 等所建议的方法旨在克服常规 CNN 同步学习局部与全局特征的能力不足: 把不同膨胀率的卷积滤波器组合成膨胀卷积块, 使其能够在多种感受野下学习特征; 再把若干堆叠、集成且深度各异的膨胀卷积块级联起来, 即可同时提取局部与全局特征。该方法的有效性在名为 PRONOSTIA 的轴承基准数据集上得到验证。有鉴于此, 本研究旨在考察不同的 DNN 模型在 RUL 估计中的表现, 以确定兼具优异特征提取能力与高涡扇发动机 RUL 预测能力的技术。

三、材料与方法

本研究采用比较分析方法, 评估四种主流深度学习模型预测各类发动机单元 RUL 的效果。所提出的基于 DNN 的模型均以公认的性能指标严格训练与评价。本节首先描述四种候选深度学习模型, 随后的小节则介绍该方法论的后两个阶段。

(一) 候选模型的训练与优化

本小节深入介绍为构建涡扇发动机 RUL 预测候选模型所采用的 DNN 结构与优化策略。为此, 本研究采用了 CNN、RNN、门控循环单元 (GRU) 和 LSTM 等若干常用神经网络架构。此外, 本文参照文献的做法, 采用随机化超参数搜索方法提升 DNN 模型的性能: 在广阔的超参数空间中作随机搜索, 以有限的计算开销找出最优超参数。具体而言, 本文随机采样超参数、依据这些参数构建模型并评估其性能。后续小节将简要描述本研究中用于涡扇发动机 RUL 预测的各类 DNN 架构。

(二) 循环神经网络

传统 DNN 存在一项局限: 由于系统结构复杂, 单个神经元的权重无法为对应的 RUL 找出确切的特征表示。RNN 通过引入在时间步上运行的循环机制来克服这一局限: 对序列向量 $\{x_1, \dots, x_n\}$, 采用递推式 $r_t = f_\alpha(r_{t-1}, X_t)$, 其中 f 表示激活函数, α 表示每个时间步 t 上所用的一组参数, X_t 为时间步 t 上的输入。本研究考察三类循环神经元来构建基于 RNN 的候选模型: 基本 RNN 单元、GRU 与 LSTM 单元。

在每个时间步 t 上, 激活函数记为 g , X_t 为该时间步的输入, b_a 为偏置, W_a 为时间步 t 上对应激活输出 a_t 的累积权重。若有需要, 激活输出 a_t 可用于生成 t 时刻对 y_t 的预测。

该模型借助嵌入层把 RUL 映射到维度为 R^{20} 的向量空间, 从而把语义关系转化为几何关系。DNN 的后续各层分析这些几何形状, 以识别并理解复杂的特征表示; 输出层再据此作出预测, 其中使用单个 sigmoid 单元。尽管采用基本 RNN 神经元的 DNN 在若干领域颇为有效, 这类模型仍面临梯度消失问题, 并且捕捉长期关系的能力有限。为克服这些障碍, 学界提出了 GRU 和 LSTM 等替代性循环神经元设计, 它们在缓解梯度消失问题、帮助学习长期依赖方面表现更佳。

式中 W_r, W_c, W_u 为权重矩阵, b_r, b_c, b_u 为各时间步 t 上对应输入 X_t 的偏置项, σ 表示逻辑斯谛函数, a_t 为时间步 t 上的激活值。除神经元类型不同外, 采用 GRU 的 RNN 模型与采用普通 RNN 神经元的模型相似。Hochreiter 与 Schmidhuber 提出的 LSTM 神经元改进了 RNN 单元, 也使 GRU 更为稳健。GRU 与 LSTM 单元的差异如下:

(1) 在标准 LSTM 单元中, 计算 $\tilde{H}_t$ 时没有类似 Γ_r 的重要门控。

(2) LSTM 单元使用输出门 Γ_o 和更新门 Γ_u 两个不同的门, 而不是只依赖一个更新门。输出门负责计算 LSTM 单元向网络中其他隐藏单元输出的激活值, 并监控记忆单元内容 H_t 的可见程度; 更新门则调节对先前隐藏状态 H_{t-1} 的信息替换幅度, 以得到更新后的隐藏状态 H_t , 这一过程需要确定记忆单元中应丢弃多少信息才能保证最佳性能。

(3) LSTM 单元以两个显式的门取代 GRU 单元中单一的更新门 Γ_u , 即输出门 Γ_o 与遗忘门 Γ_u 。输出门负责调节记忆单元内容在计算 LSTM 单元输出激活值时的可见程度; 遗忘门则管理先前记忆内容被覆盖的程度, 以生成新的 H_t 。

(4) LSTM 与 GRU 架构的一项关键区别在于: 在 LSTM 中, 记忆单元的内容 H_t 未必等于 t 时刻的激活值 a_t 。

此外, 基于 RNN 方法开发的 LSTM 模型, 其架构设计与 GRU 模型和基本 RNN 模型高度相似, 唯一区别在于循环层中使用的是 LSTM 单元。图 1 给出了本文为 RUL 估计所提出的深层 RNN 模型结构。




Figure 1 Structure of a Deep RNN-Based Model Proposed for RUL Estimation

图 1 为 RUL 估计所提出的深层 RNN 模型结构

(三) 卷积神经网络

CNN 特别擅长处理涉及高维输入数据中复杂空间模式的学习任务。这类挑战广泛存在于图像处理视频分析氨基酸序列分析 以及时序失效信号考察等诸多领域。CNN 的主要目标是学习分层滤波器, 用尽可能少的可训练参数把大规模输入数据转换为精确的类别标签。这一转换通过输入数据与可训练参数之间的稀疏交互实现, 并借助参数共享机制完成, 使 CNN 能够为复杂且具有空间组织的输入数据获得等变的表示, 即特征图。在深层 CNN 中, 深层单元能够借助池化操作间接与相当大比例的输入数据发生交互; 池化操作以统计摘要简化某一位置的输出, 使模型网络能够从这种压缩后的表示图中获取复杂特性。CNN 的顶部通常包含若干全连接层(含输出层), 利用前面各层所获得的复杂信息作出预测。

用于 RUL 预测的 CNN 架构由嵌入层中的两个卷积—最大池化块、一个全局平均层和一个 sigmoid 神经元输出层构成。多重非线性特征提取显著提升了 CNN 模型的学习效率, 使模型能够自主学习数据的分层表示。因此, 卷积核的尺寸与卷积层的数量对模型的预测能力影响很大。图 2 给出了本研究为 RUL 估计设计的 CNN 架构。初始输入数据为二维格式, 其中一维以一维形式表示特征编号, 另一维对应传感器的时间序列, 同样为一维。




Figure 2 The Proposed Architecture for RUL Prediction Using a deep CNN

图 2 所提出的基于深度 CNN 的 RUL 预测架构

随后, CNN 模型让输入数据依次通过四个结构相同的卷积层以提取特征, 再把提取到的特征与一个配备单个 3×1 滤波器的卷积层相整合。特征图展平后连接到全连接层, 并采用 Dropout 方法抑制过拟合。各层的激活函数均为 ReLU。本研究以随机梯度下降 (SGD) 算法完成模型优化。

式中 y_i 为实际值, $\hat{y}_i$ 为预测值, N 为验证集样本数。惩罚系数 ω 的取值规则为: 若实际值 y_i 大于预测值 $\hat{y}_i$ 则取 1, 若实际值小于预测值则取 2。

(四) 数据预处理与归一化

在实际场景中, 通常可以获得来自传感器的原始数据、运行参数和运行至失效的信息。为使数据可用于训练与测试, 需要对各传感器的数值作标准化处理, 因为它们的量纲可能不同。本文实验使用了 21 个传感器的数据, 并剔除了异常或恒定不变的数据。所采用的归一化技术为 Min-Max 缩放, 逐特征把数据缩放到 0 与 1 之间。此外, 对于健康衰退自运行之初即呈非线性的系统, 可用分段函数提高 RUL 估计值的精度; 若还能获得关于变化载荷、运行环境和特定劣化模式的信息, 也可将其纳入 RUL 估计模型, 在特定应用中进一步提高精度。图 3 展示了 FD001 数据集各传感器测量值与原始输入的 RUL 分布。




Figure 3 RUL Display Plot for Each Sensor Measurement and the Raw Input of FD001 Dataset

图 3 FD001 数据集各传感器测量值与原始输入的 RUL 分布图

第二种方法是 Min-Max 归一化, 即把传感器的原始数据缩放到 0 与 1 的范围内。为此需先确定传感器读数的最小值与最大值, 并据此把数据映射到 -1 与 1 之间。归一化后的传感器输出 x'_i 由原始传感器输出 x_i 与最小值之差, 除以最大值与最小值之差得到。需要注意的是, 归一化之所以必要, 是因为不同传感器的数值量纲可能不同, 归一化能够保证比较的公平性以及模型训练与测试的准确性。此外, 在某些应用中 (例如 RUL 呈非线性衰退的情形), 可用分段函数调整 RUL 估计目标; 若能获得关于不同载荷、运行环境与劣化模式的知识并将其纳入 RUL 估计模型, 同样有助于提高精度。

此外, 为纳入多变量时序信息, 本文参照文献 [10] 的做法采用时间窗 (TW) 方法。对训练数据集 FD001 选取长度为 30 的时间窗, 并提取窗内全部历史数据构成高维输入向量, 该向量长度为 14×30 , 即以 21 个可用传感器中的 14 个作为原始输入特征。本研究开发的基于 DNN 的模型专门用于预测在单一工况下运行的航空发动机的 RUL, 因此选择了在单一工况下采集数据的 FD001 数据集用于实验分析。用于特征提取的网络结构则依据航空发动机运行数据的动态特性作了适配, 因为这些特性会随工况不同而变化。

(五) 预测流程

图 4 给出了多阶段的预测实验策略。预处理首先提取 14 个原始传感器值, 并把 FD001 数据集归一化至 $[-1, 1]$ 区间; 随后生成时序信息受限于 N_{tw} 的训练集与测试集。DNN 模型使用预先给定的二维标准化数据, 无须人工构造偏度、峰度之类的信号处理特征, 因而不需要预测或信号处理方面的专门知识。接下来构建用于寿命 RUL 预测的深度神经网络模型, 并确定其隐藏层数量、卷积滤波器尺寸等参数; 再用归一化的训练数据和训练样本的 RUL 标注值训练 DNN 模型, 通过反向传播学习与 SGD 中的小批量更新网络权重。每一轮训练时, 数据被随机划分为若干 512 个样本的微批次, 并用微批次的平均损失函数调整深度神经网络模型各层的权重。实验确定最佳批量为 512 个样本, 全部案例研究均采用该值[10-12]。为确保收敛, 本文采用可变学习率: 前 25 个优化轮次取 0.005, 其后调整为 0.001。DNN 候选模型的训练轮次默认不超过 250 轮。




Figure 4 Prediction Process of Our Proposed Approach

图 4 本文所提方法的预测流程

四、实验结果

本节概述实验结果并讨论其意义。第一小节介绍 C-MAPSS 基准数据集, 第二小节给出实验结果与性能分析, 最后一小节则与已有文献作对比分析。

(一) C-MAPSS 基准数据集

C-MAPSS 数据集是先进预测研究中广泛使用的资源, 包含四个子数据集, 分别刻画发动机在不同工况与失效机理下的行为。每个子集都包含训练集与测试集, 并附有真实 RUL 值; 这些子集以 21 个传感器和 3 项运行设置为特征。每台发动机单元经历不同程度的劣化, 随时间逐步退化直至系统失效, 标志着一个非健康运行周期的终结; 因此测试集中的传感器记录会在系统故障发生之前停止。该数据集以压缩文本格式给出, 每一行代表一个运行周期内采集的数据快照, 每一列对应一个不同的变量。表 1 给出了该数据集的详细信息。实验的目标是预测测试集中发动机单元以及单台发动机单元的 RUL。本研究仅使用标记为 FD001 的第一个子集来验证 DNN 模型, 该子集包含 100 个训练样本和 100 个测试样本。

Table 1 Description of C-MAPSS Benchmark Dataset

表 1 C-MAPSS 基准数据集说明

C-MAPSS 数据集	FD001
用于训练的发动机单元数	100
用于测试的发动机单元数	100
工况数	1
失效模式数	1

五、结果与分析

在分析各项评价指标后可以看出, 决策树分类器 (DTC) 与 XGBoost 分类器 (XGBC) 模型的准确率在所有模型中最高; 但从精确率与召回率来看, DTC 的取值最低, 这意味着它比其他模型更容易产生较多的假阳性和较少的真阳性; 相反, XGBC 模型的精确率与召回率均为最高, 说明它产生假阳性的概率更低、产生真阳性的概率更高。残差分析是回归问题中常用的评估手段, 通过建立残差并考察残差图来评价模型的拟合优度。

回归模型可以通过残差分析来评价, 即借助残差图考察模型的适配程度。残差 e 表示某个数据点 i 上因变量的实测值 y_i 与预测值 $\hat{y}_i$ 之间的差距。残差分析有助于判断模型是倾向于低估还是高估: 当 $e_i > 0$ 时发生高估, 说明预测值 $\hat{y}_i$ 持续高于实际值 y_i ; 反之, 当 $e_i < 0$ 时则为低估, 说明预测值持续低于实际值。

残差图通过揭示低估或高估的规律, 为理解模型行为提供了有价值的线索。理想的回归模型应在高估与低估之间取得平衡, 使残差 e_i 关于 0 呈对称分布, 零上与零下的样本数大致相当。这些信息可用散点图和分布图直观呈现, 展示 e_i 在 0 附近的分布情况。残差分布的偏斜程度反映模型的偏倚: 分布越偏斜, 偏倚越大, 反之亦然。图 6 给出了基于 LSTM 的模型在 FD001 测试数据上的残差分析。

六、结论

总之, 可靠而准确的 RUL 估计有助于实现有效的预测性维护, 避免灾难性故障与人员伤亡。同时, 智能制造的日益普及也使数据驱动的 RUL 技术在学术界与工程界受到越来越多的关注。本研究构建了四种不同的 DNN 模型来准确预测涡扇发动机的 RUL, 并使用 C-MAPSS 基准数据集对模型进行训练与评估。精确预测航

空发动机的 RUL 对于提升航空发动机系统的可靠性与安全性至关重要。对比结果显示, 基于 LSTM 与基于 GRU 的学习模型的预测精度优于其他模型; 而且随着劣化程度加深, 预测结果愈加精确。尽管所建议的方法已取得令人鼓舞的实验结果, 其结构在未来研究中仍有进一步改进的空间。更具体地说, 该方法将被扩展到更多数据子集以及在不同工况下运行的涡扇发动机的 RUL 预测。随着运行环境愈加复杂, RUL 预测的难度也随之上升, 因而需要更深入的分析。

参考文献

- [1] 王树国. 机器人关节驱动器高精度控制. 机器人, 2025, 44(02): 1-8.
- [2] 郝吉明. 工业烟气多污染物协同治理. 中国环境科学, 2022, 42(04): 1501-1508.
- [3] 肖立业. 超导输电线路工程化关键问题. 电工电能新技术, 2025, 41(02): 1-10.
- [4] Peng C, Chen Y, Chen Q, et al. A remaining useful life prognosis of turbofan engine using temporal and spatial feature fusion. *Sensors*, 2021, 21(2): 418.
- [5] Muneer A, Taib S M, Fati S M, et al. A hybrid deep learning-based unsupervised anomaly detection in high dimensional data. *Computers, Materials & Continua*, 2022, 70(3): 5363-5381.
- [6] 朱合华. 城市地下管网数字孪生建模. 地下空间与工程学报, 2025, 18(02): 369-378.
- [7] 李元昊. 数控机床热误差补偿技术. 中国机械工程, 2022, 33(08): 905-912.
- [8] 陈发虎. 高寒冻土路基稳定控制技术. 冰川冻土, 2020, 44(02): 478-486.
- [9] 吴一戎. 合成孔径雷达成像优化算法. 雷达学报, 2022, 11(02): 201-212.
- [10] 黄维和. 天然气管网动态调度优化. 油气储运, 2020, 41(04): 361-368.
- [11] Wei J, Bai P, Qin D, et al. Study on vibration characteristics of fan shaft of geared turbofan engine with sudden imbalance caused by blade off. *Journal of Vibration and Acoustics*, 2018, 140(4): 041010.
- [12] Zschech P, Bernien J, Heinrich K. Towards a taxonomic benchmarking framework for predictive maintenance: the case of NASA's turbofan degradation//*Proceedings of the 40th International Conference on Information Systems (ICIS)*, 2019.