本文引用格式:单苏苏,信明江.多故障模式下的设备剩余使用寿命预测方法[J].自动化与信息工程,2025,46(2):54-62.

SHAN Susu, XIN Mingjiang. Remaining useful life prediction method for equipment under multiple failure modes[J]. Automation & Information Engineering, 2025,46(2):54-62.

多故障模式下的设备剩余使用寿命预测方法

单苏苏 信明江

(五邑大学轨道交通学院,广东 江门 529020)

摘要:针对设备因多种故障模式失效时,不同故障模式对设备的使用寿命和退化轨迹产生不同影响的问题, 提出一种基于深度时间序列聚类(DTC)的多任务分支模型,实现设备的故障模式识别和剩余使用寿命(RUL) 预测。首先,利用 DTC 从输入数据中提取特征,并完成故障模式识别;然后,基于 DTC 的故障模式识别结果选 择对应的分支预测器进行设备 RUL 预测。在涡轮发动机仿真数据集上的实验结果表明,相较于未考虑多故障模 式的模型,该模型具有更高的 RUL 预测精度,其平均绝对百分比误差降低了 5.69%。

关键词:剩余使用寿命;多故障模式;深度时间序列聚类;故障模式识别;分支预测器

中图分类号: TP277; TP183	文献标志码: A	文章编号: 1674-2605(2025)02-0008-09
DOI: 10.12475/aie.20250208		开放获取

Remaining Useful Life Prediction Method for Equipment under Multiple Failure Modes

SHAN Susu XIN Mingjiang

(School of Railway Transportation, Wuyi University, Jiangmen 529020, China)

Abstract: To address the issue where different failure modes of equipment have varying impacts on its service life and degradation trajectories when the equipment fails due to multiple failure modes, this paper proposes a multi-task branch model based on deep time-series clustering (DTC) to achieve failure mode identification and remaining useful life (RUL) prediction. First, DTC is employed to extract features from the input data and perform failure mode identification. Then, based on the DTC based failure mode identification results, the corresponding branch model is selected for RUL prediction. Experimental results on a turbofan engine simulation dataset demonstrate that, compared to models that do not consider multiple failure modes, the proposed model achieves higher RUL prediction accuracy, with the mean absolute percentage error reduced by 5.69%.

Keywords: remaining useful life; multiple failure modes; deep time-series clustering; failure mode identification; branch predictor

0 引言

剩余使用寿命(remaining use life, RUL)预测作 为设备健康管理的重要组成部分,受到学术界和工业 界的广泛关注^[1-2]。RUL 预测有助于提前制订设备的 维修方案,确保设备处于良好的工作状态,防止设备 突发故障^[3-5]。近年来,学者们针对 RUL 预测提出了 多种方法并在实际应用中取得显著成效^[6-7]。文献[8] 利用卷积神经网络处理原始振动信号并进行 RUL 预 测,在轴承退化试验数据上取得了良好效果。文献[9] 采用深度卷积神经网络预测涡轮风扇发动机的 RUL, 在无需专家先验知识的情况下,预测结果的均方根误 差为12.61周期。文献[10]基于循环神经网络(recurrent neural network, RNN)捕获时间序列的长期依赖关系, 用于滚动轴承的 RUL 预测,提高了长时间序列预测 的准确性。为避免传统的 RNN 在训练过程中出现梯 度消失或爆炸问题,文献[11]提出一种基于长短期记 忆(long short-term memory, LSTM)的 RUL 预测框 架,并通过实验证明了 LSTM 在时间数据融合方面的 性能优于 RNN。文献[12]提出一种基于门控循环单元 (gated recurrent unit, GRU)^[13]的锂离子电池 RUL 预 测方法,克服了 RNN 因长时间序列训练导致的长期 依赖问题,并具有更少的参数量和更简单的结构。但 上述方法仅考虑了一种故障模式,忽略了多故障模式 之间的差异。在实际应用场景中,由于个体差异、环 境因素等影响,设备会产生多种故障模式^[14]。在不同 的故障模式下,设备的性能退化轨迹和使用寿命均存 在差异,这些差异会影响设备的 RUL 预测^[15]。文献 [16]证明了对不同故障模式分别建立预测模型的多模 型方法优于单模型方法。

多故障模式下的设备 RUL 预测,通常采用两步 法和多任务学习(multi-task learning, MTL)法。两步 法先用分类模型识别设备的故障模式,再构建每种故 障模式的预测模型。文献[17]提出一种故障类型和尺 度诊断的谱相关密度组合方法,用于设备RUL预测, 在轴承退化数据集上取得了良好效果。文献[18]先根 据后验概率估计故障模式,再建立贝叶斯退化模型, 并在设备RUL 预测中为每种故障模式确定失效阈值, 解决了故障阈值先验未知的问题。MTL 法通过一个 一体化的分类和预测模型,可同时获得设备的故障模 式和 RUL 预测信息。文献[19]提出一种联合损失卷积 神经网络架构,用于轴承故障模式识别和RUL预测, 有效提高了模型的泛化能力,降低了过拟合风险和计 算成本。文献[20]针对航空发动机建立了一个基于多 尺度特征融合和多任务并行学习的预测框架,通过联 合损失函数进行故障诊断和 RUL 预测,在商用模块 化航空推进系统仿真数据集上表现出良好的泛化性 和鲁棒性。但上述方法都依赖于标签数据,训练模型 所需的历史监测数据要同时具有寿命标签和模式标 签,这在实际应用中较难实现。

针对上述方法存在的不足,本文提出一种多故障 模式下的设备 RUL 预测方法。该方法采用基于深度 时间序列聚类(deep temporal clustering, DTC)的多任 务分支模型进行设备故障模式识别和 RUL 预测。 1 相关内容

1.1 **GRU**

GRU 是在 RNN 基础上发展的一种变体,结构如图1所示。



图1 GRU结构图

图 1 中, x_t 为时间序列在t时刻的输入; y_t 为t时刻 GRU 的输出; 隐藏状态 h_{t-1} 为t-1时刻 GRU 的输出; r_t 为重置门,决定上一时刻的输出 h_{t-1} 有多少信息进入当前时刻的计算; σ 为 sigmoid 激活函数; \tilde{h}_t 为 h_{t-1} 和 x_t 共同生成的新候选隐藏状态; z_t 为更新门,用于控制新候选隐藏状态 \tilde{h}_t 和 h_{t-1} 对当前时刻 GRU 输出的影响程度。

GRU 的计算公式为

$$\begin{cases} z_{t} = \sigma(\boldsymbol{W}_{t} \cdot [h_{t-1}, x_{t}] + b_{z}) \\ r_{t} = \sigma(\boldsymbol{W}_{r} \cdot [h_{t-1}, x_{t}] + b_{r}) \\ \tilde{h}_{t} = \tanh(\boldsymbol{W} \cdot [h_{t-1}, x_{t}] + b_{z}) \\ h_{t} = (1 - z_{t}) \cdot h_{t-1} + z_{t} \cdot \tilde{h}_{t} \end{cases}$$
(1)

式中: W和b分别为权重矩阵和偏置项。

双向门控循环单元(bidirectional gated recurrent unit, BiGRU)是 GRU 的扩展,由一个正向 GRU 和 一个反向 GRU 叠加组成。在 BiGRU 中,输入同时提 供给两个相反方向的 GRU 网络层进行学习,最终输 出由这两个单向的 GRU 输出共同决定。

1.2 注意力机制

注意力机制可以根据输入特征对输出的影响进 行权重分配,从而筛选出重要特征,进而提高模型的 预测精度。本文采用的注意力机制主要计算公式为

$$e_t = \mu \tanh(wH_t + b) \tag{2}$$

$$\alpha_{t} = \frac{\exp(e_{t})}{\sum_{j=1}^{t} e_{j}}$$
(3)

式中: e_t 为 t 时刻的注意力分布值, μ 和 w 为权 重, H_t 为注意力层的输入, b 为偏置项, α_t 为注意力 层各特征的不同权重值。

1.3 自编码器

自编码器(autoencoder, AE)是一种无监督学习 模型,通过训练来学习数据的压缩表示,包含编码器 (encoder)和解码器(decoder)两部分。其中,编码 器将输入数据压缩成低维的潜在表示;解码器将潜在 表示还原成与原始输入数据相似的输出,其原理如图 2 所示。





AE 结构类似于一个多层的神经网络,输入层与 输出层具有相同数量的神经元,训练目标是实现最小 化重构损失,即输入数据与输出数据之间的差异最小。

2 模型流程

基于 DTC 的多任务分支模型主要包括 DTC 和多 分支预测器两部分。其中, DTC 部分可以半监督地识 别故障模式, 无需故障模式标签; 多分支预测器之间 相互独立, 并基于 DTC 的故障模式识别结果选择对 应的分支预测器进行设备 RUL 预测, 从而表达不同 故障模式之间的差异。

多故障模式下的设备 RUL 预测方法包括模型的 离线训练阶段和在线预测阶段。

离线训练阶段:首先,利用少量的故障模式弱标 签数据(一对样本数据是否属于同种故障模式^[21])和 足够的无标签数据对 DTC 进行训练;然后,训练好 的 DTC 从输入数据中提取特征并聚类成簇;最后, 利用每个簇的特征训练对应的分支预测器,并记录聚 类形成的质心向量。

在线预测阶段:首先,DTC 对输入数据进行特征提取;然后,计算特征到各质心向量的距离,并 将该特征分配到最近的质心向量实现故障模式识 别;最后,输入对应的分支预测器进行设备 RUL 预测。基于 DTC 的多任务分支模型流程如图 3 所示。



图 3 基于 DTC 的多任务分支模型流程图

基于 DTC 的多任务分支模型具有以下特点:

1) 基于半监督的 DTC 实现故障模式识别;

2) 将设备故障模式识别结果纳入 RUL 预测, 分类任务与预测任务顺序耦合,串联进行;

3) 构建设备故障模式识别和 RUL 预测一体化 模型,通过组合损失函数并行学习多个任务,减少了 模型总参数量,有利于隐式数据增强和知识迁移。

3 预测方法

DTC 部分由 BiGRU 层、注意力层和分类层组成。 其中,BiGRU 层从输入的时间序列中提取特征;注意 力层对重要特征进行加权;分类层基于 K-means 聚类 算法进行聚类^[22]。在离线训练阶段找到各故障模式对 应的质心向量,在在线预测阶段通过计算特征到各质 心向量的距离进行分类,并将分类后的特征输入对应 的分支预测器中。每个故障模式的分支预测器分别由 三层全连接层组成。基于 DTC 的多任务分支模型结



图 4 基于 DTC 的多任务分支模型结构图

3.1 离线训练

针对基于 DTC 的多任务分支模型存在的多目标 优化问题,将离线训练分为 3 个阶段,如图 5 所示。



第一阶段, DTC 预训练。采用编码-解码的 AE 结构对 DTC 进行无监督预训练。编码器为 DTC;解码器由重复向量层、BiGRU 层和全连接层组成。编码函数从输入数据 X_i 中提取特征 $X_f = f_{en}(X_i)$,解码函数基于提取的特征重构原始数据 $\overline{X}_i = f_{de}(X_f)$,训练目标是最小化重构损失 L_{ae} :

$$L_{ae} = \frac{1}{m} \sum_{i=1}^{m} \left\| \bar{X}_{i} - X_{i} \right\|$$
(4)

式中: ||•||为欧氏距离, m为输入数据的数量。

第二阶段,将 K-means 聚类算法嵌入到 AE 中, 使特征向质心向量靠拢,并增大不同质心向量之间的 距离,以获得更好的聚类效果。在这个阶段的每次迭 代过程中,将 DTC 提取的特征聚类成 N 个簇,计算 簇间平均距离 L_{inter} 和簇内平均距离 L_{intra}。训练目标是 最大化簇间平均距离,最小化簇内平均距离。聚类损 失 L_{cluster} 计算公式为

$$L_{\text{inter}} = \frac{2}{N \cdot (N-1)} \sum_{i}^{N-1} \sum_{j=i+1}^{N} \left\| \delta_{i} - \delta_{j} \right\|$$
(5)
$$L_{\text{intra}} = \frac{1}{N} \sum_{k=1}^{N} \frac{1}{n^{k}} \sum_{i=1}^{n^{k}} \left\| f_{en}^{k}(X_{i}) - \delta_{k} \right\|$$
(6)
$$L_{\text{cluster}} = L_{\text{intra}} - L_{\text{inter}}$$
(7)

式中: δ 为质心向量, $f_{en}^{k}(X_{i})$ 为 DTC 提取并被分配至第k个簇的特征, n^{k} 为第k个簇包含的特征数量。

为避免信息丢失,还需考虑重构损失 L_{ae} 。综上所述,第二训练阶段的总体优化目标为最小化总损失 $\lambda_{ae}L_{ae} + \lambda_{cluster}L_{cluster}$,其中 λ_{ae} 和 $\lambda_{cluster}$ 是平衡参数,均大于 $0[^{23}]$ 。

少量带故障模式弱标签的样本集成在前两个阶段。在每次迭代过程中,无监督和弱监督两个任务交替进行,共同优化 DTC 参数。弱监督任务的损失计算公式为

$$L_{\text{equal}} = 0.5 \cdot (1 - batch_y) \cdot d_w \tag{8}$$

 $L_{\text{neg}} = 0.5 \cdot batch_y \cdot \max(0, \text{margin} - d_w) \qquad (9)$

式中: $batch_y$ 为一对弱标签样本的标签,同类 取 0,异类取 1; margin 为决策阈值; d_w 为一对弱 标签样本经过 DTC 降维后的特征欧氏距离。

弱监督任务的优化目标为最小化总损失 L_{equal} + L_{neg} 。

第三阶段,对各分支预测器进行联合训练。在每次迭代过程中,DTC 提取的特征 X_f 被聚类成 N 个簇后,分配至对应的分支预测器,得到预测值。第*i*个分支预测器的均方根误差为

$$L_{i} = \sqrt{\frac{1}{n^{i}} \sum_{1}^{n^{i}} (Y_{\text{true}} - Y_{\text{pre}})^{2}}$$
(10)

为避免信息丢失,加入重构损失L_{ae}和聚类损失

2025 年 第 46 卷 第 2 期 自动化与信息工程 57

 L_{cluster} ,则此阶段的训练目标是最小化总损失L:

$$L = \lambda_{ae} L_{ae} + \lambda_{cluster} L_{cluster} + \lambda_{pre} \left(\sum_{i=1}^{N} L_i \right)$$
(11)

式中: L_i 为第i个分支预测器损失, λ_{ae} 、 $\lambda_{cluster}$ 和 λ_{nre} 分别为各部分的平衡参数。

离线训练完成后,记录聚类形成的质心向量。

3.2 在线预测

若设备传感器在 *t* 时刻采样的数据为 *x_t* , 则 *t* 时 刻输入模型的样本 *X* 为

$$X_{t} = [x_{t-p}, x_{t-p+1}, \cdots, x_{t}]^{\mathrm{T}}$$
(12)

该样本形状为(*p*+1)·*q*,其中*p*+1为时间序列的长度,*q*为传感器的数量。

首先,BiGRU 层从两个方向提取时间特征,则 t 时刻 BiGRU 层的输出可表示为

$$\begin{cases} [\overrightarrow{h_{t-p}}, \overrightarrow{h_{t-p+1}}, \cdots, \overrightarrow{h_t}] = \overrightarrow{gru}(X_t) \\ [\overrightarrow{h_{t-p}}, \overrightarrow{h_{t-p+1}}, \cdots, \overrightarrow{h_t}] = \overleftarrow{gru}(X_t) \end{cases}$$
(13)

取最后一个时间步长之和,经注意力矩阵进行加 权处理后,得到 *t* 时刻注意力层输出的特征 *S*,为

$$S_t = \sum_{j=1}^{q} \alpha_t(\vec{h}_t + \vec{h}_t)$$
(14)

然后,计算特征 S, 与各个质心向量之间的欧氏距离,并将 S, 分类至相距最近的故障模式,计算公式为

$$d_{W} = \sqrt{\sum_{j=1}^{q} (S_{t} - \delta)^{2}}$$
(15)

最后,根据分类结果,将特征*S*,输入到对应的分 支预测器,经过3层全连接层,得到t时刻样本的RUL 预测值。

在基于 DTC 的多任务分支模型中,设置输入张 量形状为[30, 50, 16],即每次输入 30 个样本,每个 样本都是 50×16 的二维矩阵,其中 50 代表连续的 时间步长,16 代表特征数量。采用均方误差(mean squared error, MSE)损失函数进行损失计算,利用 Adam 优化器更新模型参数,初始学习率设置为 0.005。为防止过拟合,在全连接层中添加 dropout 层,并设置 dropout 率为 0.1。基于 DTC 的多任务分 支模型参数如表 1 所示。

表1 基于 DTC 的多任务分支模型参数

输入层 - [30,50,16] 编码器BiGRU层 60个单元 [30,60] 编码器注意力层 - [30,60] 編码器重复向量层 50次 [30,50,60] 解码器BiGRU层 60个单元 [30,50,60] 解码器全连接层 50×16个单元 [30,50,16] 分类层 - [None,60] 预测器全连接层1 40个单元 [None,40] 预测器全连接层2 20个单元 [None,20]	网络层	参数设置	输出张量形状
編码器BiGRU层 60个単元 [30,60] 編码器注意力层 - [30,60] 解码器重复向量层 50次 [30,50,60] 解码器BiGRU层 60个単元 [30,50,60] 解码器全连接层 50×16个単元 [30,50,16] 分类层 - [None,60] 预测器全连接层1 40个单元 [None,40] 预测器全连接层2 20个单元 [None,20]	输入层	_	[30,50,16]
编码器注意力层 - [30,60] 解码器重复向量层 50次 [30,50,60] 解码器BiGRU层 60个单元 [30,50,60] 解码器全连接层 50×16个单元 [30,50,16] 分类层 - [None,60] 预测器全连接层1 40个单元 [None,40] 预测器全连接层2 20个单元 [None,20]	编码器BiGRU层	60个单元	[30,60]
解码器重复向量层50次[30,50,60]解码器BiGRU层60个单元[30,50,60]解码器全连接层50×16个单元[30,50,16]分类层-[None,60]预测器全连接层140个单元[None,40]预测器全连接层220个单元[None,20]	编码器注意力层	_	[30,60]
解码器BiGRU层 60个单元 [30,50,60] 解码器全连接层 50×16个单元 [30,50,16] 分类层 - [None,60] 预测器全连接层1 40个单元 [None,40] 预测器全连接层2 20个单元 [None,20] 输出层 1公单元 Direct1	解码器重复向量层	50次	[30,50,60]
解码器全连接层 50×16个单元 [30,50,16] 分类层 - [None,60] 预测器全连接层1 40个单元 [None,40] 预测器全连接层2 20个单元 [None,20] 输出层 1 1	解码器BiGRU层	60个单元	[30,50,60]
分类层 - [None,60] 预测器全连接层1 40个单元 [None,40] 预测器全连接层2 20个单元 [None,20] 输出层 1个单元 Diana 11	解码器全连接层	50×16个单元	[30,50,16]
预测器全连接层1 40个单元 [None,40] 预测器全连接层2 20个单元 [None,20] 输出层 1个单元 Diana 11	分类层	- 10	[None,60]
预测器全连接层2 20个单元 [None,20]	预测器全连接层1	40个单元	[None,40]
输出已 1个单元 Diana 11	预测器全连接层2	20个单元	[None,20]
	输出层	1个单元	[None,1]

4 实验

为验证基于 DTC 的多任务分支模型在多故障模 式下,设备 RUL 预测的有效性和精确性,在涡轮发 动机仿真数据集上进行实验验证。在 TensorFlow 2.6 深度学习框架上搭建基于 DTC 的多任务分支模型, 运行环境为 Anaconda 3 和 Python 3.6,计算设备为配 备 AMD R7 5800H (3.20 GHz) CPU, 16 GB RAM 的 计算机。

4.1 数据集

本实验采用的数据集是由TEACHES模拟软件生成的涡轮发动机数据集,包括训练集和测试集两个子集。其中,训练集记录了涡轮发动机的多个状态参数从某一时刻到发生故障完整周期内的采样值;测试集包含了故障前某一时间点之前的状态参数值以及对应的RUL。实验目标是预测测试集中每个涡轮发动机的RUL。每个子集均包含3种故障模式(故障模式1、故障模式2和故障模式3),每种故障模式的退化情况可用公式(16)多项式模型来描述:

$$f_{n,t}^{k} = \sum_{m=0}^{M} \beta_{k,m} t^{m}$$
(16)

式中: $f_{n,t}^k$ 为故障模式 k 下t时刻单元n的健康因子, M 为多项式的阶数, $\beta_{k,m}$ 为对应的回归参数。

故障模式 1 和故障模式 2 的单元为线性退化 (*M*=1),故障模式3的单元为二次退化(*M*=2), 如图6所示。



图 6 3 种故障模式下的涡轮发动机退化情况

训练集和测试集各有 150 个样本,每个样本均包 含一定时间序列的 16 个传感器信息,不同样本之间 的时间序列长度不一。数据集中 3 种故障模式的样本 数量分布如表 2 所示。

表 2 3 种故障模式的	同样本数量分布	单位:个
故障模式	训练集	测试集
故障模式1样本数量	30	30
故障模式2样本数量	70 91	70
故障模式3样本数量	50	50

4.2 数据预处理

首先,为消除不同特征之间的量纲差异,利用线 性函数 max-min normalization 对数据进行归一化处理, 计算公式为

$$x' = \frac{x - x_{\min}}{x_{\max} - x} \tag{17}$$

式中: x'为归一化后的数据, x 为原始数据, x_{min}和 x_{max}分别为原始数据中的最小值和最大值。

然后,对数据进行滑窗处理,窗口大小设置为 50×16,50 表示时间序列的长度,16 表示特征数, 滑动步长为1,每个窗口作为模型的一个输入样本。 接着,对测试集中时间序列长度不足 50 的样本 进行填充,即利用样本最后一个时间周期的数据进行 填充,直至时间序列长度达到 50。

最后,为了防止模型过拟合,提高泛化性能,将 所有数据和对应的寿命标签按相同规则打乱顺序。

4.3 评价指标

本文采用归一化互信息(normalized mutual information, NMI)来衡量 DTC 的聚类结果与真实故障模式标签的相似程度,计算公式为

$$\begin{cases}
I_{\text{NMI}} = \frac{I(A;B)}{H(A) + H(B)} \\
I(A;B) = \sum_{a \in A} \sum_{b \in B} P(a;b) \log \frac{P(a,b)}{P(a)P(b)} \\
H(A) = -\sum_{a \in A} P(a) \log P(a) \\
H(B) = -\sum_{b \in B} P(b) \log P(b)
\end{cases}$$
(18)

式中: *A* 为 DTC 对输入数据的聚类结果; *B* 为输入数据的真实故障模式类别; *I*(*A*;*B*) 为互信息, 互信息越大, *A*、*B* 之间的相关性越强; *H*(*A*) 和 *H*(*B*) 分别为 *A*、*B* 对应的熵值, 熵值越大, 随机变量的不确定性越大; NMI 的值域为[0,1], NMI 值越大, 表示两个聚类结果越相似。

采用准确率(accuracy)作为分类任务的评价指标, 即模型正确识别的样本个数/样本总数。采用均方根 误差(root mean square error, RMSE)和平均绝对百分 比误差(mean absolute percentage error, MAPE)作为 预测效果的评价指标,这两个指标越小,表示预测精 度越高,计算公式分别为

$$\sigma_{\rm RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^{m} (Y_{\rm true} - Y_{\rm pre})^2}$$
(19)

$$\sigma_{\text{MAPE}} = \frac{1}{m} \sum_{i=1}^{m} \left| \frac{Y_{\text{true}} - Y_{\text{pre}}}{Y_{\text{true}}} \right|$$
(20)

式中: m 为预测样本总数, Y_{true} 为涡轮发动机 RUL 真实值, Y_{pre} 为涡轮发动机 RUL 预测值。

4.4 实验结果

离线训练第二阶段的NMI 值变化情况如图7所示。

2025 年 第46 卷 第2 期 自动化与信息工程 59



图 7 训练的第二阶段 NMI 值变化情况

由图 7 可知: DTC 提取的特征在训练初期聚类效 果不明显,这是因为预训练的目标为学习通用特征表 示,但这些特征并不完全适合特定的聚类任务;随着 迭代次数增加, DTC 进一步调整参数以适应聚类任务, 其提取的特征逐渐向质心向量靠拢,聚类效果逐步提 升。经过第二阶段的训练后, NMI 值达到了 0.96,表 明聚类结果与真实故障模式标签的一致性较高,可以 较好地反映数据的真实类别分布,证明了 DTC 在故 障模式识别任务上的有效性和准确性。

测试集样本的故障模式识别结果混淆图如图 8 所示。



由图 8 可知:本文模型对故障模式 1 的 30 个样 本识别结果中,有 21 个正确,9 个错误,识别准确率 为 70.0%,这可能是因为故障模式 1 的样本数量不足, 模型未能学习到足够的特征和规律;本文模型对故障 模式 2 的 70 个样本识别结果中,有 52 个正确,18 个 错误,识别准确率为 74.3%,这可能是因为故障模式 2 样本的退化方式与模式 1 相似,导致特征空间可分 性不足;本文模型对故障模式3的50个样本识别结 果中,有42个正确,8个错误,识别准确率为84.0%, 这可能是因为故障模式3的样本退化特征更明显。测 试集共有150个涡轮发动机样本,其中115个样本识 别正确,模型的识别准确率为76.0%。

涡轮发动机 RUL 预测结果如图 9 所示,用虚线 将每个分支预测器的预测结果分开。



由图 9 可知, 3 种故障模式下涡轮发动机样本的 平均 RUL 具有一定的差异,这是因为不同的故障模 式导致涡轮发动机产生的退化速率不同。但预测值曲 线和真实值曲线拟合程度较高,证明了本文模型的有 效性。

将本文模型 M0 与未考虑多故障模式的模型 M1 (只包含一个分支预测器的模型)、同时使用了模式 标签和寿命标签的模型 M2^[15]进行比较实验,结果如 表 3 所示。

表 3 个 同 涡 轮 友 动 机 R U L 预 测 模 型 结 果 🛚	抳
---------------------------------------	---

模型	识别精度/%	MAPE/%
M0	76.00	6.18
M1	_	11.87
M2	92.00	3.56

由表 3 可知:本文模型 M0 的 MAPE 比模型 M1 提高了 5.69%,证明了如果能够识别不同的故障模式, 并针对每种故障模式建立对应的预测器,可提高预测 精度;模型 M2 的结构与本文模型 M0 相似,但本文 模型 M0 的 MAPE 低于模型 M2,这可能是因为本文 模型 M0 仅使用了寿命标签和少量模式弱标签,而模 型 M2 同时使用了寿命标签和模式标签。本文训练方 法使模型 M0 牺牲了部分预测精度,但获得了更好的 泛化能力。

为进一步证明模型的有效性和泛化性,从训练集中抽取2号、8号、59号和84号4个时间序列较长的样本,预测涡轮发动机的RUL,结果如图10所示。



图 10 涡轮发动机 RUL 的预测结果

由图 10 可知, 2 号、8 号、59 号和 84 号 4 个样 本在退化过程初期 RUL 预测值与真实值之间存在较 大误差,这是由于样本在退化初期阶段数据信息不足, 数据处理时仅采用简单的填充方法所致;当涡轮发动 机接近退役时,RUL 的预测值与真实值曲线之间的拟 合程度较高,进一步证明了本文模型具有较高的 RUL 预测精度和泛化性,尤其在设备的寿命末期,具有一 定的应用价值。

5 结论

本文提出了一种基于 DTC 的多任务分支模型, 用于多故障模式下的设备故障模式识别和RUL 预测。 基于 BiGRU、注意力机制和K-means 聚类算法的DTC 部分能够从高维、长时间序列中提取特征,并通过计 算特征到各故障模式质心向量的距离来识别故障模 式。多个对应的分支预测器可以描述不同故障模式之 间的差异。通过在涡轮发动机仿真数据集上进行实验, 验证了基于 DTC 的多任务分支模型的有效性和泛用 性。但该模型在处理多目标优化问题时,依赖调参技 巧和经验,超参数的选取对模型性能的影响较大。因 此,如何系统地寻找多任务之间的平衡点是后续研究 的重点。

©The author(s) 2024. This is an open access article under the CC BY-NC-ND 4.0 License (https://creativecommons.org/licenses/ by-nc-nd/4.0/)

参考文献

- [1] DJEZIRI M A, BENMOUSSA S, ZIO E. Review on health indices extraction and trend modeling for remaining useful life estimation[J]. Artificial Intelligence Techniques for a Scalable Energy Transition: Advanced Methods, Digital Technologies, Decision Support Tools, and Applications, 2020:183-223.
- [2] LEI Y, LI N, GUO L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction[J]. Mechanical Systems and Signal Processing, 2018,104:799-834.
- [3] LIU H, SONG W, NIU Y, et al. A generalized cauchy method for remaining useful life prediction of wind turbine gearboxes[J]. Mechanical Systems and Signal Processing, 2021,153:107471.
- [4] CHENG F, QU L, QIAO W. Fault prognosis and remaining useful life prediction of wind turbine gearboxes using current signal analysis[J]. IEEE Transactions on Sustainable Energy, 2017,9(1):157-167.
- [5] ZHANG H, CHEN X, CHEN W, et al. Collaborative sparse classification for aero-engine's gear hub crack diagnosis[J]. Mechanical Systems and Signal Processing, 2020, 141: 106426.
- [6] Ren L, Cui J, Sun Y, et al. Multi-bearing remaining useful life collaborative prediction: A deep learning approach[J]. Journal of Manufacturing Systems, 2017,43:248-256.
- [7] DEUTSCH J, HE D. Using deep learning-based approach to predict remaining useful life of rotating components[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2017, 48(1):11-20.
- [8] YANG B, LIU R, ZIO E. Remaining useful life prediction based on a double-convolutional neural network architecture [J]. IEEE Transactions on Industrial Electronics, 2019,66(12): 9521-9530.
- [9] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks[J]. Reliability Engineering & System Safety, 2018,172:1-11.
- [10] MALHI A, YAN R, GAO R X. Prognosis of defect propagation based on recurrent neural networks[J]. IEEE Transac-

tions on Instrumentation and Measurement, 2011,60(3):703-711.

- [11] YUAN M, WU Y, LIN L. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network[C]//2016 IEEE International Conference on Aircraft Utility Systems (AUS). IEEE, 2016:135-140.
- [12] SONG Y, LI L, PENG Y, et al. Lithium-ion battery remaining useful life prediction based on GRU-RNN[C]//2018 12th International Conference on Reliability, Maintainability, and Safety (ICRMS). IEEE, 2018: 317-322.
- [13] WANG W, YANG N, WEI F, et al. Gated self-matching networks for reading comprehension and question answering [C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), 2017:189-198.
- [14] VERBERT K, DE SCHUTTER B, BABUŠKA R. A multiplemodel reliability prediction approach for condition-based maintenance[J]. IEEE Transactions on Reliability, 2018,67(3): 1364-1376.
- [15] LI Z, LI Y, YUE X, et al. A deep branched network for failure mode diagnostics and remaining useful life prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2022,71:1-11.
- [16] WEN Y, WU J, ZHOU Q, et al. Multiple-change-point modeling and exact Bayesian inference of degradation signal for prognostic improvement[J]. IEEE Transactions on Auto-

mation Science and Engineering, 2018,16(2):613-628.

- [17] YAN D, WEI X, ZHAI G. RUL prediction for railway vehicle bearings based on fault diagnosis[C]//2017 29th Chinese Control and Decision Conference (CCDC). IEEE, 2017: 2097-2102.
- [18] CHEHADE A, BONK S, LIU K. Sensory-based failure threshold estimation for remaining useful life prediction[J]. IEEE Transactions on Reliability, 2017,66(3):939-949.
- [19] LIU R, YANG B, HAUptmann A G. Simultaneous bearing fault recognition and remaining useful life prediction using joint-loss convolutional neural network[J]. IEEE Transactions on Industrial Informatics, 2019,16(1):87-96.
- [20] ZHOU L, WANG H, XU S. Aero-engine prognosis strategy based on multi-scale feature fusion and multi-task parallel learning[J]. Reliability Engineering & System Safety, 2023, 234:109182.
- [21] IENCO D, INTERDONATO R. Deep semi-supervised clustering for multi-variate time-series[J]. Neurocomputing, 2023, 516:36-47.
- [22] JAIN A K. Data clustering: 50 years beyond K-means[J]. Pattern recognition letters, 2010,31(8):651-666.
- [23] LI X, LI X, MA H. Deep representation clustering-based fault diagnosis method with unsupervised data applied to rotating machinery[J]. Mechanical Systems and Signal Processing, 2020,143:106825.

作者简介:

单苏苏,男,1999年生,在读硕士研究生,主要研究方向:设备剩余使用寿命预测。E-mail:2793153005@qq.com 信明江,男,1999年生,在读硕士研究生,主要研究方向:设备剩余使用寿命预测。E-mail:1474412073@qq.com

(上接第31页)

- [14] HOLLAND J H. Adaptation in natural and artificial systems[M]. USA: University of Michigan Press,1975:126-137.
- [15] 贺琪,官礼崔焕焕.硬时间窗 VRP 的混合变邻域禁忌搜索 算法[J].计算机工程与应用,2023,59(13):82-91.
- [16] 朱利.基于粒子群算法的农产品物流车辆路径问题[J].中国

储运,2023(1):102-103.

- [17] 范厚明,徐振林,李阳,等.开放式多中心需求可拆分 VRP 及 混沌遗传模拟退火算法[J].运筹与管理,2022,31(1):92-98.
- [18] 韩雪.基于约束聚类和粒子群算法的多路径规划[J].计算机 与现代化,2023(8):7-11.

作者简介:

耿永忠, 男, 1968年生, 本科, 工程师, 主要研究方向: 现代医药冷链物流及供应链信息化管理。E-mail: zhxgg8816617@ 163.com

黄秋原,男,1975年生,本科,工程师,主要研究方向:现代物联网技术、数字化工厂与供应链。E-mail:1281850757@qq.com 余太松,男,1987年生,本科,工程师,主要研究方向:医药互联网以及数字化供应链。E-mail:yutaisong@sinopharm.com 刘家鹏,男,1996年生,本科,助理工程师,主要研究方向:软件设计与程序开发。E-mail:liujiapeng@sinopharm.com