

DOI: 10.13382/j.jemi.B2305616

基于可解释模型的火箭推力故障辨识与 轨迹预测方法

周登极¹ 刘巧珍² 岳梦云² 黄大文¹ 王煜林¹

(1. 上海交通大学动力机械与工程教育部重点实验室 上海 200240; 2. 北京宇航系统工程研究所 北京 100076)

摘要:针对运载火箭飞行过程中的强非线性和高不确定性问题,以及火箭推力下降故障对飞行过程可靠性和安全性的重大影响,基于注意力机制提出一种可解释机器学习模型以提高火箭推力下降故障检测、故障发动机定位、故障程度估计、以及故障后轨迹预测的准确性和鲁棒性,使用注意力层提取高维时序飞行监测数据的特征,以特征矩阵简洁表达高维时序数据,进而采用自注意力及全连接网络预测推力下降发生的位置和推力下降程度,并通过长短期记忆单元对特征向量进行解码实现未来时段内飞行轨迹准确预测。在火箭推力下降数据集上对提出的模型进行测试,验证了模型的有效性。结果表明,提出的模型的故障定位准确率为96.0%,故障严重程度估计精度为94.7%,轨迹预测平均误差为0.94%,提出的模型在推力下降故障模式中具有良好的应用效果。

关键词:可解释机器学习模型;注意力机制;推力下降故障;故障严重程度;轨迹预测

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2

Method for thrust fault identification and trajectory prediction of launch vehicle based on interpretable machine learning model

Zhou Dengji¹ Liu Qiaozhen² Yue Mengyun² Huang Dawen¹ Wang Yulin¹

(1. Key Laboratory for Power Machinery and Engineering of Ministry of Education, Shanghai Jiao Tong University, Shanghai 200240, China; 2. Beijing Institute of Astronautical Systems Engineering, Beijing 100076, China)

Abstract: Aiming at the strong nonlinearity and high uncertainty in the flight process of launch vehicle, and the significant impact of thrust descent faults on the reliability and safety, an interpretable machine learning model based on attention mechanism is proposed to improve the accuracy and robustness of thrust descent fault detection, fault engine location, fault degree estimation, and trajectory prediction after faults. The attention layer is used to extract the features of the high-dimensional time series flight monitoring data, and the feature matrix is used to express the high-dimensional time series data succinctly. Then the self-attention and fully connected network are used to predict the position and degree of thrust descent, the feature vector is decoded by the long-term and short-term memory unit to realize the accurate prediction of flight trajectory. The proposed integrated model is tested on the thrust descent data set to verify the effectiveness. The results show that the accuracy of the proposed model is 96.0% for the fault location, the accuracy is 94.7% for the fault severity estimation, and the average trajectory prediction error is 0.94%. The proposed model has good application effect in thrust descent fault modes.

Keywords: interpretable machine learning model; attention mechanism; thrust drop fault; fault severity; trajectory prediction

0 引言

运载火箭是航天运输系统的重要组成部分,是克服地心引力进入空间的主要工具,是发展空间技术、确保空间安全的基石^[1]。随着航空航天技术的快速发展,运载

火箭的推力需求越来越大,系统组成更加复杂,其可靠性和安全性问题日益突显。推力下降是当前运载火箭动力系统最常见的故障之一,轻则导致火箭性能和稳定性降低、入轨精度差,重则导致发射任务失败^[2]。推力下降故障一方面可通过飞行数据特征辨识,另一方面可通过飞行轨迹辨识。有效地对运载火箭的飞行轨迹进行跟踪和

预测是观测火箭飞行状态、及时预警发射事故的重要技术手段^[3],在实际飞行中具有重要的价值和意义。

目前,关于运载火箭故障检测的研究方法主要包括以下几种。基于动态模型的故障检测方法,如胡峰等^[4]通过火箭质心状态演化方程及测量方程建立火箭质心状态空间模型,实现对故障类型和故障程度的估计。基于信号检测与分析的故障检测方法,如王丽舫等^[5]通过对实测数据进行小波变换,并将变换后的信号作为判断故障类型的依据;周虎等^[6]利用模态识别算法分解惯组输出数据,将模态分量映射为故障特征向量,采用概率神经网络形成对故障的可信诊断能力。基于专家系统的故障检测方法,如胡建等^[7]通过搭建故障图谱及贝叶斯网络实现发动机推力故障检测。王硕等^[8]利用动力学和运动学模型以及最小二乘方法实现发动机故障情况下推力大小的辨识,虽能辨识故障下的推力下降,但有一定的时延。基于神经网络的故障检测方法,如基于径向基神经网络在线辨识并补偿模型的故障变化和不确定干扰,发展火箭推力下降容错姿态控制方法^[9];Park 等^[10]提出了一种基于深度学习的液体火箭发动机起动机故障检测与诊断方法,描述火箭发动机热试车启动瞬态的数值模型可以模拟各种故障引起的正常和异常情况;Xu 等^[11]提出了一种基于量子遗传算法和 BP 神经网络的液体火箭发动机故障检测优化方法,并应用于液体火箭发动机的典型故障检测过程。上述单一类型的神经网络构建的故障检测模型通常难以获得较佳的故障诊断效果,禹建丽等^[12]和孙志成等^[13]提出了模型融合的方法,通过不同神经网络的预测结果准确推理故障类型。模型融合的方法虽然牺牲了一定的决策效率,但能够提高故障诊断结果的准确性和鲁棒性。

由于运载火箭的故障检测过程包含较为复杂的非线性方程,且发射和飞行环境对火箭的运动轨迹影响较大,难以精确表征和衡量。因此,面向运载火箭在线故障检测,上述方法存在准确性低、泛化性差的问题。相比之下,可解释机器学习模型能够描述更加复杂的数学关系,能够兼容多种机理方程和数据,增强故障检测的鲁棒性,提高检测精度。

故障状态下,准确预测运载火箭运动轨迹可提前掌握火箭后续状态变化趋势,为发动机智能化控制决策提供依据,可保障故障下的火箭安全飞行。吕新广等^[14]提出一种将迭代制导与数值积分相结合的轨迹预测制导方法,该方法计算量较小,适合箭上实时计算,能够同时满足终端姿态约束和轨道参数约束要求;王志祥等^[2]基于火箭 6 自由度动力学模型实现了对发动机推力下降状态下的轨迹预测,但只考虑了发动机关机情况,并为考虑发动机推力下降到一定比例时的预测情况。翟岱亮等^[15]基于机理仿真给出了适用于飞行器轨迹预测的气动参

数,并进行了仿真实验;陈易成等^[16]针对运载火箭上升段的轨迹优化问题的高度不确定性和严格的飞行过程约束,利用了模型预测控制方法构建轨迹预测控制方法,并采用内点法进行了在线求解;Yu 等^[17]通过仿真和实验研究了不同初始落差条件下模型火箭自由落体过程中的弹道预测问题;Ghosh 等^[18]在已知的环境条件下提出了一种预测火箭弹道性能的前馈神经网络模型,测试结果证明了方法的有效性。

传统的火箭轨迹预测方法需要构建火箭的运动学和动力学方程,而发射和飞行环境因素对火箭运动的影响较大且难以精确建模,因此导致通过机理模型预测火箭运动轨迹精度较低,基于传统的神经网络的轨迹预测会出现实际数据难以通过模型解释的情况。

为此,需要发展基于可解释机器学习模型的火箭故障检测与轨迹预测方法,以增强诊断和预测结果的可靠性和透明度。实际上,在机器学习的基础研究领域,已有大量关于模型可解释的研究。Lipton 等^[19]将机器学习可解释性的实现途径分为两大类:其一为模型透明性,又常被称作内在可解释性;其二为事后可解释性。内在可解释性强调模型结构的透明性,稀疏性以及模块功能化,如以逻辑规则约束对神经网络进行稀疏训练,得到更光滑的决策边界,提高模型的可解释性^[20]。注意力机制是典型的模块功能化可解释研究,其对循环神经网络的状态向量赋予权重,约束机器在翻译过程中参考上下文信息的范围,以权重过滤的方式对模型决策提供解释^[21]。事后可解释性主要在模型构建完成后通过对模型进行后验分析来研究模型的决策机制^[22]。典型的方法之一为对深度模型的近似替代,旨在用简单的树模型、线性回归模型代替复杂黑盒模型,研究替代后的模型以分析其决策机制^[23]。

本文以运载火箭故障检测和轨迹预测方法中现存的问题为切入点,旨在发展面向高惯性和高时间相关性的火箭飞行数据的推力故障检测、隔离、识别和故障状态下轨迹预测一体化可解释模型,完成故障定位、故障程度预测和故障轨迹预测任务。通过使用注意力机制对多维时序飞行监测数据进行特征提取,建立高维时序数据的特征矩阵,通过注意力机制的可视化能力提高神经网络模型的可解释性。进而发展以特征矩阵为输入的深度学习模型预测推力下降的发动机和推力下降程度的方法。采用长短期记忆单元解码特征向量来预测火箭飞行轨迹^[24],并通过真实数据验证了方法的有效性。

面向传统方法难以辨识火箭发动机推力故障和故障状态下飞行轨迹难预测的实际问题,本文通过对真实高维参数据进行深入分析,发展了针对性的解决方法,主要创新点如下:1) 发展了集发动机推力下降故障检测、辨识与故障状态下轨迹预测于一体的智能化模型,突破了

传统机理方法以及故障检测与轨迹预测隔离的弊端;2)建立了基于注意力机制的高维飞参数据与发动机推力下降故障和轨迹特征的映射方法,提高了深度学习模型的可解释性和故障检测与轨迹预测的精度;3)通过对运载火箭的经度、纬度、高度、速度、攻角及姿态等轨迹特征值和装备健康状态进行有效的学习和辨识,以及与真实航行数据进行误差对比分析,验证了提出方法的有效性,实现了故障状态下运载火箭入轨点的准确预测。

1 诊断与预测一体化方法

1.1 Seq2seq 模型

Seq2seq 是一种循环神经网络的变体,由编码器、解码器两部分构成,在自然语言处理中有重要的应用^[25]。在编码器中,初始序列 $X = (x_1, x_2, \dots, x_n)$ 经神经网络转换为特征向量 c 。其编码过程为:

$$h_t = f(x_t, h_{t-1}) \quad (1)$$

$$c = \phi(h_1, h_2, \dots, h_n) \quad (2)$$

其中, h_t 为编码器中各轮循环之间传递的隐藏状态向量, $f(\cdot)$ 是动态函数, $\phi(\cdot)$ 为针对所有隐藏状态向量的某种关系函数。例如, $\phi(\cdot)$ 可以赋予所有隐藏状态向量相同的权重,则有:

$$c = \frac{h_1 + h_2 + \dots + h_n}{n} \quad (3)$$

$\phi(\cdot)$ 也可忽略前 $n-1$ 个隐藏状态向量,则有:

$$c = h_n \quad (4)$$

解码器通过神经网络结构将特征向量 c 解码为目标序列,其计算过程为:

$$s_i = f(y_{i-1}, s_{i-1}, c) \quad (5)$$

$$y_i = g(y_{i-1}, s_i, c) \quad (6)$$

其中, $Y = (y_1, y_2, \dots, y_n)$ 为目标轨迹序列, $f(\cdot)$ 和 $g(\cdot)$ 为动态函数, s_i 为解码器中各轮循环之间传递的隐藏状态向量。实践表明,相比于传统的循环神经网络,使用长短期记忆神经网络和门控循环单元 (gate recurrent unit, GRU) 等循环结构体能够有效地提高模型准确率^[26]。

1.2 注意力机制

Seq2seq 结构将初始序列 X 编码为单一的特征向量 c , 容易忽略原始序列中蕴含的部分特征,降低解码过程的准确性和鲁棒性。注意力机制是一种常用于神经网络模型中的先验可解释方法,它通过对信息进行相关性分析建立动态权重参数,加强输入数据中的关键信息并弱化无用信息。动态权重参数可以评估不同特征的重要程度,分析神经网络模型内部决策过程。同时,注意力机制可以在不增加模型参数数量的情况下,显著提高模型的非

线性能力,从而避免过拟合现象的发生,增强模型的泛化性和准确率。输入数据为二维时序数据,包括特征维度和时间维度。输入数据经过卷积结构得到包含输入数据特征信息的多个特征矩阵;同时,输入数据经过非线性模块后,通过归一化函数得到动态注意力权重。将注意力权重与特征矩阵相乘,可以得到加权特征矩阵 $c = (c_1, c_1, \dots, c_n)$, 使编码结果可以随解码的过程动态变化^[27]。图 1 展示了注意力模型结构,为降低循环过程产生的梯度消失现象对编码过程的影响,注意力模型采用双向循环神经网络结构,编码过程为:

$$h_t = f(x_t, h_{t-1}, h_{t+1}) \quad (7)$$

$$c_t = \sum_{i=1}^n \alpha_{ti} h_i \quad (8)$$

$$\alpha_{ti} = \frac{e^{\eta(h_i, s_{t-1})}}{\sum_{j=1}^n e^{\eta(h_j, s_{t-1})}} \quad (9)$$

$$s_t = f(y_{t-1}, s_{t-1}, c_t) \quad (10)$$

其中, $n(\cdot)$ 用于表征编码器隐藏状态向量 h_t 与解码器隐藏状态向量 s_{t-1} 之间的函数关系,该关系一般由多层全连接层表征,并在模型训练过程中学习。

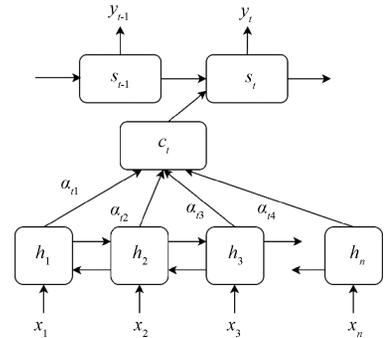


图 1 注意力模型结构

Fig. 1 Attention model structure

1.3 决策过程可视化分析

本文基于类激活图映射法 (class activation mapping, CAM), 对故障诊断和检测过程进行可解释分析, 分析注意力机制模块对模型决策过程及准确率性能的影响。故障检测网络中的特征向量, 经过全局平均池化处理后, 得到 n 个输入神经元, 并通过全连接层得到故障模式概率分布向量。故障概率分布向量中, 每个元素对应一种故障发生的概率, 其值等于全连接层输入神经元的加权和。若第 k 种故障发生的概率对应的输入神经元权重为 $W_1^k, W_2^k, \dots, W_n^k$, 则第 k 种故障对应的类激活映射向量 L_{CAM}^k 可表示为:

$$L_{CAM}^k = \sum_{i=1}^n W_i^k c_i \quad (11)$$

CAM 方法能够以热力图的形式展示神经网络模型

决策过程中关注的特征区域,增强卷积神经网络模型的透明度与可解释性。实验中,将通过 CAM 方法,探究时间注意力机制及特征注意力机制对模型准确率性能的影响机理,同时,也为故障时间定位任务提供机理解释与理论依据。

1.4 故障检测与轨迹预测一体化模型

本文研究的运载火箭动力系统共包含 4 台发动机,分别位于左右推进器中。其故障程度按照 10% 的推力下降间隔划分为 10 个区间,即 0%~10%,10%~20%,...,90%~100%。故障发动机位置及故障程度预测问题可转化为分类问题,将推力下降故障定位至某台发动机;故障轨迹预测则为回归问题,根据故障发生前 n 个时间节点的实测飞行状态信息,预测未来一段时间火箭的飞行轨迹。故障诊断及轨迹预测模型框架如图 2 所示。

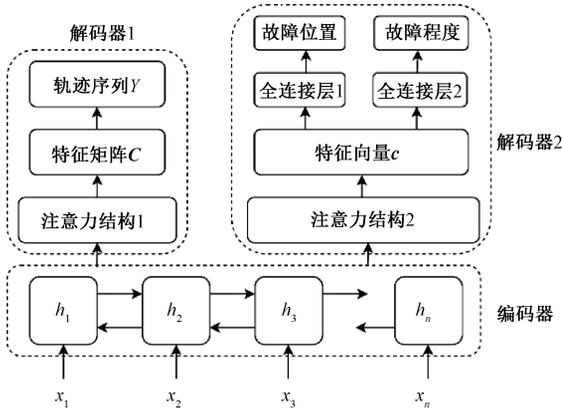


图 2 故障检测和轨迹预测一体化模型框架

Fig. 2 Integrated model framework of fault detection and trajectory prediction

图 2 中,编码器使用双向长短期记忆神经网络结构对初始输入序列进行编码,得到隐藏状态矩阵 $\mathbf{H} = (h_1, h_2, \dots, h_n)$,解码器 1 通过对隐藏状态矩阵 \mathbf{H} 进行解码得到目标轨迹序列 $Y = (y_1, y_2, \dots, y_n)$,其计算过程如式 (7)~(10) 所示。解码器 2 中,特征向量 \mathbf{c} 仅用于预测当前时间状态下的故障位置及推力下降程度,因此注意力结构 2 为自注意力机制,其计算过程可表示为:

$$\mathbf{c} = \sum_{i=1}^n \frac{e^{\eta(h_i)}}{\sum_{j=1}^n e^{\eta(h_j)}} h_i \quad (12)$$

使用两个并联的全连接结构对特征向量 \mathbf{c} 进行解码。全连接层 1 用于预测故障发生于某一发动机的概率 $u \in \{u_1, u_2, u_3, u_4, u_5\}$,其中 u_1 为无故障发生概率, $u_2 \sim u_5$ 对应于发生于左推进器 1 号发动机,左推进器 2 号发动机,右推进器 3 号发动机,右发动机 4 号发动机的故障,其计算过程可表示为:

$$p(u = u_i | \mathbf{X}) = \frac{e^{f_i(c)}}{\sum_{j=1}^5 e^{f_j(c)}} \quad (13)$$

式中:函数 $f_i(\cdot)$, $i = 1, 2, \dots, n$ 由全连接层 1 训练拟合得到。

同理,对于某一推力下降程度的概率 $v \in \{v_1, v_2, \dots, v_{10}\}$,其计算过程为:

$$p(v = v_i | \mathbf{X}) = \frac{e^{g_i(c)}}{\sum_{j=1}^{10} e^{g_j(c)}} \quad (14)$$

式中:函数 $g_i(\cdot)$, $i = 1, 2, \dots, n$ 由全连接层 2 训练拟合得到。

模型训练损失函数定义为各任务的训练损失函数的加权和,其中故障定位及推力下降程度预测采用交叉熵损失函数:

$$H_1(u', u) = - \sum_{i=1}^5 p(u' = u_i) \log(p(u = u_i)) \quad (15)$$

$$H_2(v', v) = - \sum_{i=1}^{10} p(v' = v_i) \log(p(v = v_i)) \quad (16)$$

式中: u', v' 为故障发生位置以及故障程度的真实标签。

轨迹预测任务采用均方误差损失函数:

$$L(Y', Y) = \frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2 \quad (17)$$

式中: $Y' = (y'_1, y'_2, \dots, y'_n)$ 为未来 n 个时刻的真实轨迹数据序列。

考虑到无故障发生时不存在推力下降程度,设计模型的损失函数为:

$$\rho_m = \begin{cases} \frac{1}{m} \sum (L(Y', Y) + \beta_1 H_1(u', u) + \beta_2 H_2(v', v)), & u' \neq u_1 \\ \frac{1}{m} \sum (L(Y', Y) + \beta_3 H_1(u', u)), & u' = u_1 \end{cases} \quad (18)$$

式中: $\beta_1, \beta_2, \beta_3$ 为超参数,用于平衡各任务损失大小以保证各任务具有相近的重要程度。在故障诊断和轨迹预测过程中,设置 $\beta_1 = 1 \times 10^{-3}$, $\beta_2 = 4.1 \times 10^{-4}$, $\beta_3 = 2 \times 10^{-3}$ 。

2 结果与讨论

实验数据是利用运载火箭高精度飞行仿真模型产生的,仿真中采用的故障模式如表 1 所示。实验数据集共包含 500 组运载火箭飞行仿真结果,包括不同故障模式仿真结果 400 组和 100 组正常飞行仿真结果。该运载火箭总长 53.1 m,起飞质量 597 t,近地轨道运载能力达到 13.5 t^[28]。其中故障数据涉及 4 台发动机:1 号、2 号发动机位于左推进器内,3 号、4 号发动机位于右推进器内,

每种故障只存在于单一发动机中。使用剩余 360 组故障模式仿真数据和 90 组正常飞行仿真数据进行训练;使用剩余 40 组故障模式仿真数据和 10 组正常飞行仿真数据进行验证。故障定位模型参数及训练参数设置如表 2 所示。训练簇大小是指在训练过程中使用的单个训练集的大小。

表 1 实验采用的故障模式

Table 1 Fault modes used in experiments

故障模式	1 号 发动机	2 号 发动机	3 号 发动机	4 号 发动机
1	推力下降 30%	推力下降 30%	推力下降 30%	推力下降 30%
2	推力下降 70%	推力下降 70%	推力下降 70%	推力下降 70%
3	推力下降 20%	正常	正常	正常
4	正常	推力下降 50%	正常	正常
5	正常	正常	推力下降 60%	正常
6	正常	正常	正常	推力下降 70%
7	推力下降 30%	正常	正常	正常
8	正常	正常	正常	推力下降 90%

表 2 故障定位模型参数及训练参数

Table 2 Fault location model parameters and training parameters

参数名称	参数值
输入样本数量	61 618
训练簇大小	1 000
时间节点/s	1
初始学习率	0.001
梯度下降算法	Adam 算法
模型损失	2.26×10^{-4}

模型测试结果可知,故障定位平均准确率为 96.0%,图 3 和 4 展示了在特定推力下降程度下,故障发动机定位诊断的结果。其中横坐标是测试样本,纵坐标为发动机故障位置,真实故障位置为各测试样本中故障发生的真实位置,预测故障位置为模型预测结果。其中,推力下降 30%时,故障定位准确率为 95.0%;推力下降 70%时,故障定位准确率 97.2%。在特定的推力下降程度下,提出的故障检测和定位模型能够准确辨识故障发动机的位置,具有较高的准确率。

在火箭发动机的实际健康检测中,不仅需要准确检测出现推力下降的发动机位置,更重要的是需要及时掌握该发动机推力下降的严重程度。随机选择位于不同发动机的故障组数据对提出的模型进行测试,通过提出的模型预测发动机出现推力下降的时间节点和出现推力下降的严重程度,结果如图 5~8 所示。分别展示了 1 号、2 号、3 号、4 号发动机出现 20%、50%、60%和 70%推力下降时的失效程度预测结果与真实测量结果的对比。由图可知,模型预测出 1 号发动机故障时间为 115 s,2 号发动机故障时间为 156 s,3 号发动机故障时间为 145 s,4 号

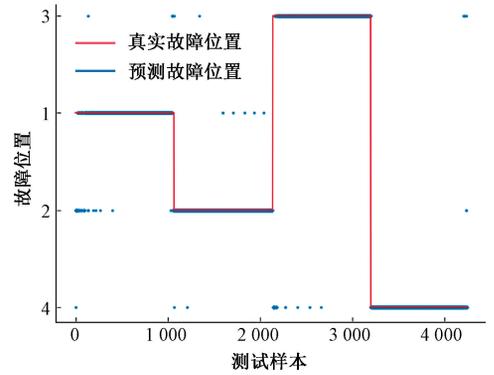


图 3 发动机推力下降 30%情况下测试组分类结果散点图

Fig. 3 Scatter diagram of test group classification results when engine thrust decreases by 30%

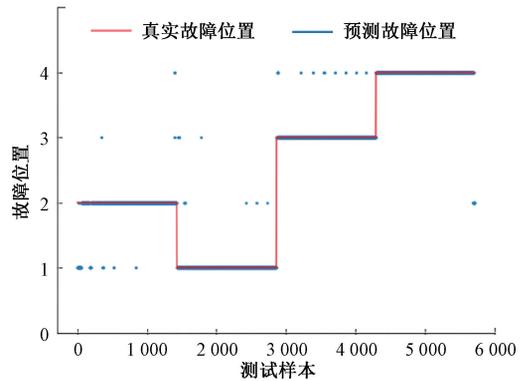


图 4 发动机推力下降 70%情况下测试组分类结果散点图

Fig. 4 Scatter diagram of test group classification results under 70% reduction of engine thrust

发动机故障时间为 125 s。结果表明,对于 1 号和 2 号发动机推力下降故障失效程度,提出的方法能够完全准确的检测出推力下降故障时间和故障程度;对于 3 号和 4 号发动机,在出现故障之前存在较少时间点的误诊,在出现故障之后能够准确检测出故障发生时间和故障严重程度。推力下降程度预测任务的总体准确率为 94.7%,能够满足实际需求。

在检测火箭推力故障过程中,以类激活映射热力图,解释了时间注意力机制模块对模型决策过程产生的影响,图 9 展示了发动机推力下降故障下时间注意力机制模块产生的类激活映射热力图。在每幅热力图中,分别展示了在不同的真实故障时间 t_{gt} 与预测故障时间 t_p 下,模型产生的类激活映射热力图。可以看出,模型特征层激活值的波动可以较为明显地反应故障发生位置。全连接层通过学习模型特征层上产生的激活值变化,对故障发生时间进行定位。

在检测出火箭推力下降发动机的位置和推力下降的程度后,重要的是及时的预测火箭在故障发动机的支撑

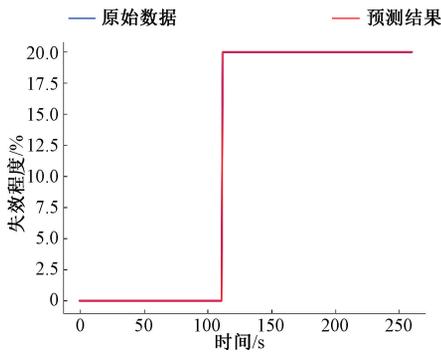


图 5 1 号发动机推力下降 20% 预测结果
Fig. 5 Predicted thrust reduction of engine 1 by 20%

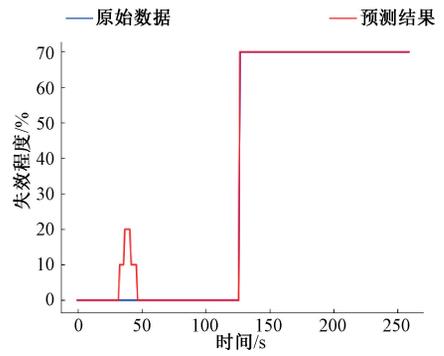


图 8 4 号发动机推力下降 70% 预测结果
Fig. 8 Predicted result of 70% thrust reduction of engine 4

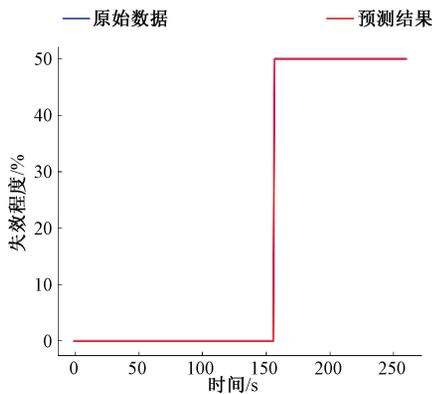


图 6 2 号发动机推力下降 50% 预测结果
Fig. 6 Predicted result of 50% thrust reduction of engine 2

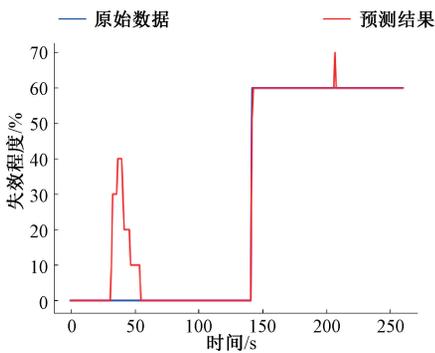


图 7 3 号发动机推力下降 60% 预测结果
Fig. 7 Predicted result of 60% thrust reduction of engine 3

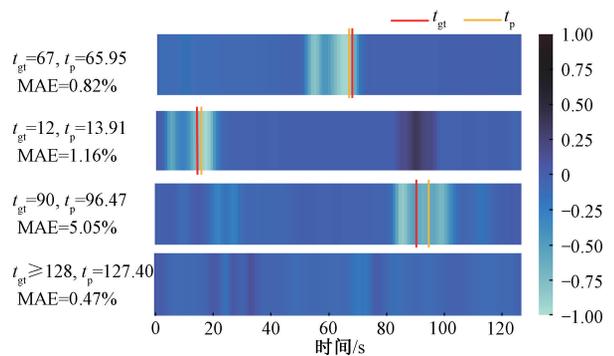


图 9 类激活映射热力图
Fig. 9 Class activation map heatmap

置 x 、位置 y 和位置 z 。图 10~13 展示了不同故障状态下,轨迹预测的结果,其绘图位置采用归一化坐标。

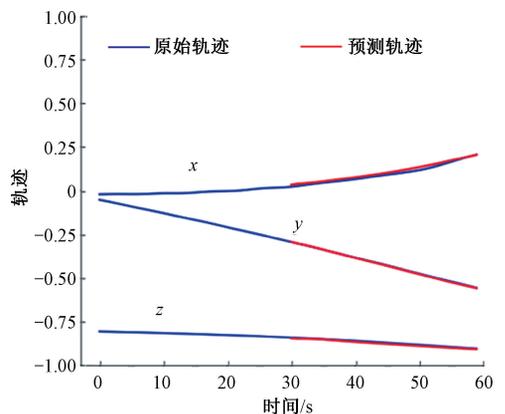


图 10 发动机无故障轨迹预测
Fig. 10 Engine fault free trajectory prediction

下的飞行轨迹,以便判断故障状态下飞行任务能否成功执行。轨迹预测基于 Seq2Seq 神经网络模型,输入量为前 30 个时刻(30 s)的火箭飞行状态参数,其中选取输入的火箭飞行状态参数为:时间、火箭飞行速度、火箭速度 x 分量、火箭速度 y 分量、火箭速度 z 分量、位置 x 、位置 y 、位置 z 、俯仰角、滚转角、偏航角、 x 视加速度、 y 视加速度、 z 视加速度。预测火箭在接下来 30 个时刻(30 s)的飞行轨迹,即火箭在接下来 30 s 内在发射坐标系中的位

图中原始轨迹表示火箭位置参数的实际变化情况,预测轨迹为神经网络模型的预测结果。图 10 为正常状态下的轨迹预测结果,图 11 为 1 号发动机出现 30% 推力失效时的轨迹预测结果,图 12 为 3 号发动机出现 60% 推力失效时的轨迹预测结果,图 13 为 4 号发动机出现 90%

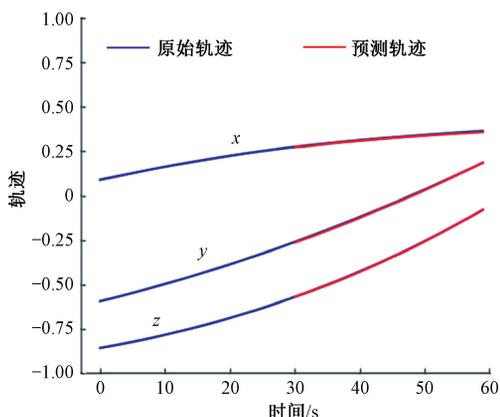


图 11 1 号发动机推力下降 30% 轨迹预测

Fig. 11 Prediction of thrust reduction trajectory of engine 1 by 30%

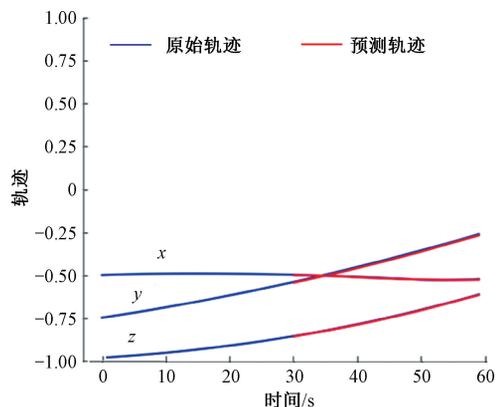


图 12 3 号发动机推力下降 60% 轨迹预测

Fig. 12 Trajectory prediction of 60% thrust reduction of engine 3

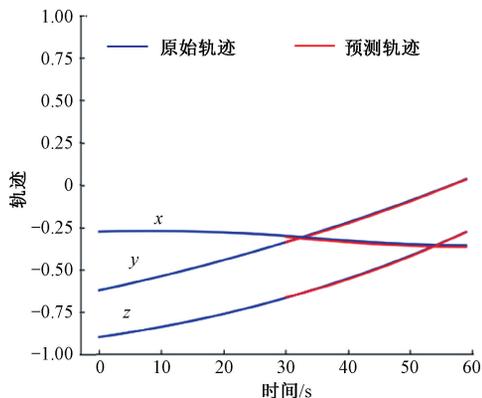


图 13 4 号发动机推力下降 90% 轨迹预测

Fig. 13 Trajectory prediction of 90% thrust reduction of engine 4

推力失效时的轨迹预测结果。针对图 10~13 中 30~60 s

时间内的预测轨迹和真实轨迹计算预测误差,然后计算所有时间点的预测误差的平均误差。结果表明,提出的方法的平均预测误差为 0.94%,其能够准确预测故障状态下的火箭飞行轨迹。

3 结 论

本文针对火箭推力下降故障发动机的定位、推力下降程度预测、以及故障发生后飞行轨迹预测问题,提出了一种融合注意力机制的可解释机器学习模型。实验结果表明,提出的故障检测及轨迹预测模型可以及时地检测出推力下降故障,将推力下降故障定位至故障发动机的准确率为 96.0%,故障定位延迟时间不超过 2 s,推力下降程度估计的准确率为 94.7%,并能够对故障后的飞行轨迹进行准确预测,平均预测误差为 0.94%。

此外,模型使用单一编码器对输入原始时间序列进行特征提取,并使用不同的解码器完成对应的分类及预测任务。该方法能够有效降低模型参数量,减小训练难度,同时可提高模型检测效率,使模型能够更好地部署在计算能力较低的箭载嵌入式系统中,可显著提高模型的通用性。

参考文献

[1] 秦旭东, 龙乐豪, 容易. 我国航天运输系统成就与展望[J]. 深空探测学报, 2016, 3(4):315-322.
 QIN X D, LONG L H, RONG Y. The achievement and future of China space transportation system [J]. Journal of Deep Space Exploration, 2016, 3(4): 315-322.

[2] 王志祥, 李家文, 李道奎. 基于六自由度动力学模型的火箭推力下降故障仿真[J]. 载人航天, 2017, 23(5):650-657.
 WANG ZH X, LI J W, LI D K. Failure simulation of thrust decline of launch vehicle based on six DOF model [J]. Manned Spaceflight, 2017, 23(5): 650-657.

[3] 叶松, 陈曦, 熊寸平. 基于线性二次滚动时域法的运载火箭发动机推力故障诊断[J]. 宇航总体技术, 2020, 4(6):29-37.
 YE S, CHEN X, XIONG C P. Thrust fault diagnosis of launch vehicle engine based on linear-quadratic receding horizon algorithm [J]. Astronautical Systems Engineering Technology, 2020, 4(6): 29-37.

[4] 胡峰, 温熙森. 运载火箭动力系统突发性故障检测与辨识[J]. 航天控制, 2001(4):59-64.
 HU F, WEN X S. Detection and recognition of burst fault in dynamical system of launch vehicle [J]. Aerospace Control, 2001(4):59-64.

[5] 王丽舫, 朱群雄. 基于小波理论的主元分析在故障诊断中的研究与应用[J]. 化工自动化及仪表,

- 2004 (6): 25-28.
- WANG L F, ZHU Q X. Research and application of PCA in process fault diagnosis based on wavelet theory [J]. *Control and Instruments in Chemical Industry*, 2004(6): 25-28.
- [6] 周虎, 段然, 屈辰, 等. 基于模态分解的运载火箭惯性器件故障诊断方法[J]. *导弹与航天运载技术*, 2020(4): 85-90.
- ZHOU H, DUAN R, QU CH, et al. Research on fault diagnosis method for heavy launch vehicle based on mode decomposition method [J]. *Missiles and Space Vehicles*, 2020 (4): 85-90.
- [7] 胡建, 蔡景, 胡维. 基于贝叶斯网络的发动机推力振荡故障诊断研究[J]. *机械设计与制造工程*, 2020, 49(12): 50-54.
- HU J, CAI J, HU W. Research on engine thrust oscillation fault diagnosis based on Bayesian network [J]. *Machine Design and Manufacturing Engineering*, 2020, 49(12): 50-54.
- [8] 王硕, 潘豪, 白文艳, 等. 基于惯组信息的运载火箭主发动机推力故障在线辨识[J]. *航天控制*, 2019, 37(6):8-12.
- WANG SH, PAN H, BAI W Y, et al. Online fault identification of launch vehicle main engine based on the IMU [J]. *Aerospace Control*, 2019,37(6):8-12.
- [9] 朱海洋, 吴燕生, 陈宇, 等. 适应运载火箭推力下降故障的神经网络容错控制方法[J]. *航天控制*, 2019, 37(4): 3-9.
- ZHU H Y, WU Y SH, CHEN Y, et al. A neural network fault-tolerant control method for launch vehicles with thrust decline [J]. *Aerospace Control*, 2019, 37(4): 3-9.
- [10] PARK S Y, AHN J. Deep neural network approach for fault detection and diagnosis during startup transient of liquid-propellant rocket engine[J]. *Acta Astronautica*, 2020, 177: 714-730.
- [11] XU L, ZHAO S, LI N, et al. Application of QGA-BP for fault detection of liquid rocket engines [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2019, 55(5): 2464-2472.
- [12] 禹建丽, 黄鸿琦, 陈洪根, 等. 神经网络在变压器故障诊断中的应用研究[J]. *控制工程*, 2018, 25(10): 1898-1904.
- YU J L, HUANG H Q, CHEN H G, et al. Application of neural network in the transformer fault diagnosis [J]. *Control Engineering of China*, 2018, 25 (10): 1898-1904.
- [13] 孙成志, 闫晓东. 基于神经网络和证据理论的火箭发动机故障诊断[J]. *宇航总体技术*, 2020, 4(4): 20-30.
- SUN CH ZH, YAN X D. Fault diagnosis of rocket engine based on neural network and evidence theory [J]. *Astronautical Systems Engineering Technology*, 2020, 4(4): 20-30.
- [14] 吕新广, 宋征宇, 巩庆海. 运载火箭轨迹预测制导方法研究[J]. *载人航天*, 2013(6): 20-24.
- LYU X G, SONG ZH Y, GONG Q H. Research on trajectory prediction guidance for launch vehicle [J]. *Manned Spaceflight*, 2013(6): 20-24.
- [15] 翟岱亮, 雷虎民, 李海宁, 等. 面向轨迹预测的高超声速飞行器气动性能分析[J]. *固体火箭技术*, 2017, 40 (1): 115-120,134.
- ZHAI D L, LEI H M, LI H N, et al. Trajectory prediction oriented aerodynamic performances analysis of hypersonic vehicles [J]. *Journal of Solid Rocket Technology*, 2017, 40(1): 115-120,134.
- [16] 陈宜成, 李冬, 李海, 等. 基于模型预测控制的运载火箭轨迹优化方法[J]. *国际航空航天科学*, 2020, 8(3): 49-59.
- CHEN Y CH, LI D, LI H, et al. Model predictive control based launch vehicle trajectory optimization method [J]. *Journal of Aerospace Science and Technology*, 2020, 8(3): 49-59.
- [17] YU X, XIANG G, COLLOPY H, et al. Trajectory prediction of a model rocket falling into the towing tank: Experimental tests versus numerical simulations [J]. *Journal of Aerospace Engineering*, 2020, 33(5): 04020056.
- [18] GHOSH AK, PRAKASH O. Neural models for predicting trajectory performance of an artillery rocket[J]. *Journal of Aerospace Computing, Information, and Communication*, 2004, 1(2): 112-115.
- [19] LIPTON Z C. The mythos of model interpretability[J]. *Communications of the ACM*, 2016, DOI: 10.1145/3233231.
- [20] HU Z T, MA X Z, LIU Z Z, et al. Harnessing deep neural networks with logic rules[C]. *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics*, Berlin, Germany, 2016.
- [21] BAHDANAUD D, CHO K H, BENGIO Y. Neural machine translation by jointly learning to align and translate[J]. *Computer Ence*, 2014.
- [22] MOLNAR C. *Interpretable Machine Learning* [M]. <https://christophm.github.io/interpretable-ml-book/>. 2018.
- [23] CRAVEN M W, JUDE W. Extracting tree-structured representations of trained networks [C]. *Advances in*

- Neural Information Processing Systems, 1996: 24-30.
- [24] HOCHREITER S. The vanishing gradient problem during learning recurrent neural nets and problem solutions[J]. International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems, 1998, 6(2): 107-116.
- [25] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[J]. Advances in Neural Information Processing Systems, 2014, 27.
- [26] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. Computer Science, 2014, DOI:10.3115/v1/D14-1179.
- [27] AHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[J]. Computer Science, 2014, DOI: 10.48550/arXiv.1409.0473.
- [28] 王小军, 范瑞祥, 徐利杰, 等. 长征-7 运载火箭首次飞行任务圆满成功[J]. 国际太空, 2016(8):29-33.
WANG X J, FAN R X, XU L J, et al. Perfect first flight of launch vehicle CZ-7 [J]. Space International, 2016(8): 29-33.

作者简介



周登极(通信作者), 副教授, 博士生导师, 主要研究方向为航空发动机总体性能仿真、系统动态学与先进控制、故障诊断与健康研究。

E-mail: ZhouDJ@sjtu.edu.cn

Zhou Dengji (Corresponding author) is an associate professor and doctoral supervisor. His main research interests include overall performance simulation of aircraft engines, system dynamics and advanced control, fault diagnosis and health management.