

DOI: 10.19650/j.cnki.cjsi.J2209179

# 基于注意力残差网络的航天器测控系统故障诊断

慕晓冬,魏 轩,曾昭菊

(火箭军工程大学作战保障学院 西安 710025)

**摘要:**随着航天器数量的不断增加,快速而准确地对航天器测控系统进行故障诊断尤为重要。针对航天器所处空间环境变化较大、遥测数据成分复杂和故障诊断准确率不高的问题,提出了一种基于注意力残差网络(AM-ResNet)的航天器测控系统故障诊断方法。首先,将原始遥测数据转换成灰度图像;其次,将图像依次通过残差网络和注意力模块,获取具有全局依赖关系的特征图;最后经过卷积、池化操作后利用 Softmax 分类器进行分类,实现航天器测控系统的故障诊断。实验结果表明,所提出的基于注意力残差网络的航天器测控系统故障诊断方法可将诊断准确率提升至 95.68%,与 ResNet-18、AlexNet 和 LeNet-5 故障诊断模型相比,诊断准确率分别提高了 3.53%、5.62% 和 16.43%,验证了该方法可以有效提高航天器测控系统故障诊断性能。

**关键词:**深度学习;故障诊断;残差网络;航天器;注意力机制

中图分类号: TH165.3 文献标识码: A 国家标准学科分类代码: 470.40

## Fault diagnosis method of spacecraft tracking telemetry and control system based on the attention residual network

Mu Xiaodong, Wei Xuan, Zeng Zhaoju

(College of Operational Support, Rocket Force University of Engineering, Xi'an 710025, China)

**Abstract:** As the number of spacecrafts increasing, it is particularly important to diagnose the fault of spacecraft tracking telemetry and control (TT&C) system quickly and accurately. To address the problems of large changes in the space environment, complex telemetry data components and low accuracy of fault diagnosis, a fault diagnosis method of spacecraft TT&C system based on the attention mechanism residual network (AM-ResNet) is proposed. Firstly, the telemetry data are converted into grayscale image. Secondly, the image is passed through the residual network (ResNet) and attention module to obtain feature map with global dependence. Finally, the softmax classifier is used to achieve image classification after convolution and pooling operations to realize the fault diagnosis of spacecraft TT&C system. Experimental results show that the fault diagnosis method of spacecraft TT&C system based on the proposed AM-ResNet can improve the accuracy of fault diagnosis to be 95.68%. Compared with ResNet-18, AlexNet and LeNet-5 fault diagnosis models, the diagnostic accuracy is increased by 3.53%, 5.62% and 16.43%, respectively, which prove that the method can effectively improve the fault diagnosis performance of the spacecraft TT & C system.

**Keywords:** deep learning; fault diagnosis; ResNet; spacecraft; attention mechanism

## 0 引 言

随着我国对太空探索的深入发展,航天器在轨数量不断增多。航天器系统作为高可靠、高稳定性系统,因其结构复杂、构件精密和在轨维修难度大等特点,使得故障诊断一直是航天器智能化管理的关键。

近年来,航天器的故障诊断技术受到广泛关注<sup>[1-2]</sup>,诊断方法更新迅速,出现了基于模型、基于信号处理以及基于数据驱动的航天器故障诊断方法<sup>[3-5]</sup>。其中,基于解析模型的方法在航天器故障诊断中应用面最为广泛<sup>[6]</sup>,但其数据利用率不够高;基于信号处理的方法主要是对遥测数据进行预处理<sup>[7]</sup>,但诊断准确率易受数据处理算法影响;基于数据驱动<sup>[8-9]</sup>的方法通

过大量历史数据来建立系统故障模型,进而实现故障诊断。随着航天器各分系统复杂程度的增加,产生的数据量呈指数增长,基于数据驱动的故障诊断方法对于航天器系统非常适用。

传统的机器学习和深度学习的方法是数据驱动故障诊断方法的重要组成部分。传统的机器学习方法,一般需要人工设计特征,结合数据处理技术和多分类器来判断航天器所属故障<sup>[10]</sup>。但是,人工设计的特征往往判别性不足,无法获取数据的深层特征<sup>[11]</sup>,导致诊断过程中对故障的区分度差,无法识别多个关联故障,使得航天器故障诊断准确率不高。

与传统的机器学习方法不同,基于深度学习的故障诊断方法通过加深网络结构进而学习到数据的深层特征,提高了故障诊断的准确率。Luo等<sup>[12]</sup>应用深度学习模型成功地识别了机床的健康状态,实现了机床在时变工况下诊断和监测。Abbaspour等<sup>[13]</sup>通过深度网络对具有非线性特性的无人机传感器进行故障检测,并应用卡尔曼滤波器更新网络参数,该方法能有效地检测和识别无人机传感器和执行器的各种故障,与传统的递归方法相比可减少92%的计算时间。Hundamn等<sup>[14]</sup>针对大量的航天器遥测数据,采用长短期记忆网络(long short term memory, LSTM)对航天器异常数据进行诊断,当非参数阈值为0.13时,该方法的预测准确率达到87.5%,召回率达到80%,实现了航天器故障的高预测性。上述方法均是时域信号直接作为深度网络的输入端,自动提取特征后进行故障分类,整个过程虽不需要人为进行特征提取,但是极容易出现特征丢失现象,进而导致分类的准确率不高。其次,一维卷积神经网络随着网络深度的加深,参数量不断增大,资源的消耗量不断增加,且容易导致过拟合问题。

卷积神经网络(convolutional neural network, CNN)在进行大量数据的处理时表现优异,其输入一般是二维图像,近年来在故障诊断领域也得到了应用。文献[15]利用数据归一化、灰度值化、信号截取和矩阵变换等操作将轴承原始时域信号转化为二维灰度图像,并将此图像作为卷积神经网络的输入,由此实现了故障信号的诊断。文献[16]将多个传感器信号融合后依此排列,经过归一化处理 and 信号截取的方式转换成二维灰度图像,利用CNN模型实现了轴承的故障诊断。文献[17-18]在数据处理方面也是通过类似的方法,将原始信号转换为二维灰度图后作为CNN网络的输入。

针对上述问题,本文提出了一种基于注意力残差网络(attention mechanism residual network, AM-ResNet)的航天器测控系统故障诊断方法。残差结构在增加网络深度的同时可降低训练难度,避免梯度消失,提高分类准确率,在故障诊断领域有很好的应用效果。注意力机制的

引入可强化航天器测控系统某故障状态下各部件、各标志位之间的关联关系,进而从遥测数据的局部特征中发现更丰富特征依赖关系,提高故障诊断精度。

为实现残差网络与注意力机制的有效融合,提升模型的诊断效果,本文首先将航天器测控系统故障数据集中遥测数据转换成灰度图像,通过残差网络提取图像特征;然后利用通道注意力模块和空间注意力模块获取更具判别性的特征图;最后将此特征图经过卷积、池化等操作后利用Softmax分类器输出故障类别,以实现航天器测控系统的故障诊断。本文采用遥测数据-灰度图像转化方法,将航天器测控系统遥测数据转换为二维图像,实现数据预处理;将残差网络模型应用于航天器测控系统的在轨故障诊断任务;将通道注意力模块和空间注意力模块融入残差网络中,获取更具判别性的特征图,以提高航天器测控系统的故障诊断准确率。

## 1 注意力残差网络

### 1.1 残差网络

He等<sup>[19]</sup>提出了残差网络作为一种经典的卷积神经网络。残差网络易于优化、网络深度可达到152层,具有较强的特征提取能力。该网络利用残差结构避免了梯度消失现象,克服了网络性能退化问题<sup>[20]</sup>,主要由残差块构成。

残差块运用跳跃连接的方式,在提取特征的同时保留部分原始输入信息,具体实现为将 $X_l$ 输入卷积核为 $3 \times 3$ ,通道数为64的卷积层中,经过最大池化和激活函数操作后输出 $X_{l+1}$ ,再对 $X_{l+1}$ 进行相同的操作后得到 $X_{l+2}$ ,此时将其与最开始的输入 $X_l$ 相加,得到输出 $X_{l+2} + X_l$ 。残差块中使用 $3 \times 3$ 的卷积核,相比于较大的卷积核,该卷积核在获得相同的感受野的同时可提取更多的特征信息,由于该卷积核参数量少,使得计算量也相应较少。残差结构的设计使得网络在增加层数的同时保留输入特征,减缓特征丢失,避免网络退化。

### 1.2 空间注意力模块

为了在航天器遥测数据的局部特征中发现更丰富的特征依赖关系,引入空间注意力模块<sup>[21]</sup>。针对每个位置特征,均采用加权求和来更新特征,由特征的相似性程度来确定权重,进而利用不同标志位之间的空间位置关系来提高特征的表征能力。

航天器测控系统故障集图像经过残差网络后得到一个特征图 $\mathbf{X} \in \mathbf{R}^{C \times H \times W}$ ,其中 $C$ 是特征图的通道, $W$ 和 $H$ 分别是特征图宽度和高度,本文 $W$ 和 $H$ 相等。首先将特征图分别送入两个 $1 \times 1$ 的卷积层,生成两个新的特征图 $A$ 和 $B$ ,此时 $A$ 和 $B$ 的维度并没有发生变化,仍是 $\{A, B\} \in$

$R^{C \times H \times W}$ 。将  $A$  和  $B$  分别形变为  $R^{C \times N}$ , 其中  $N = H \times W$ ; 并将形变后的  $A$  做转置并与形变后的  $B$  进行矩阵相乘, 将计算结果进行 Softmax 操作后得到空间注意力特征图  $S \in R^{N \times N}$ 。

$$s_{ji} = \frac{\exp(A_i \cdot B_j)}{\sum_{i=1}^N \exp(A_i \cdot B_j)} \quad (1)$$

其中,  $s_{ji}$  体现了  $i$  位置的像素对  $j$  位置像素的影响。

两个像素之间特征越相似, 彼此的关联程度越大。

在故障诊断中表现为两个标志点位的关联程度越大, 越是引发系统故障的原因。

同时, 将  $X$  送入另一个  $1 \times 1$  的卷积层, 生成特征图  $D \in R^{C \times H \times W}$ , 同样将其形变为  $R^{C \times N}$ , 并将形变后的特征图  $D$  与特征图  $S$  做矩阵相乘, 生成新的  $R^{C \times H \times W}$ 。最后, 将其乘以系数  $\alpha$  并与原特征图  $X$  求和, 得到输出  $E \in R^{C \times H \times W}$ 。

$$E_j = \alpha \sum_{i=1}^N (s_{ji} D_i) + X_j \quad (2)$$

式中:  $\alpha$  为空间注意力参数, 初始化为 0, 并在网络训练中进行更新。

此时特征图  $E$  融合了空间中所有像素的特征, 它既具有全局特征, 也有根据注意力机制选择后的特征, 提高数据特征的有效性。

### 1.3 通道注意力模块

通道注意力模块利用不同通道之间的相互依赖关系, 突出具有依赖关系的特征映射, 改善特定故障状态下特征表示能力, 进而改善网络性能<sup>[22]</sup>。通道注意力模块与空间注意力模块在结构上相似。

对于特征图  $X \in R^{C \times H \times W}$ , 首先将  $X$  形变为  $R^{C \times N}$ ,  $N = H \times W$ , 再将形变后的特征图与其自身形变后的转置进行矩阵相乘, 经过 Softmax 操作后得到通道注意力图  $M \in R^{C \times C}$ , 计算公式如下:

$$m_{ji} = \frac{\exp(X_i \cdot X_j)}{\sum_{i=1}^C \exp(X_i \cdot X_j)} \quad (3)$$

其中,  $m_{ji}$  表示第  $i$  个通道对第  $j$  个通道的影响。

同样, 将  $X$  形变后与通道注意力图  $M$  进行矩阵相乘, 得到特征图  $R^{C \times H \times W}$ , 将该特征图乘以系数  $\beta$ , 并与  $X$  进行逐元素求和运算, 最终输出特征图  $F \in R^{C \times H \times W}$ :

$$F_j = \beta \sum_{i=1}^N (m_{ji} X_i) + X_j \quad (4)$$

式中:  $\beta$  为通道注意力参数, 和空间注意力参数一样, 从 0 开始更新。

此时特征图  $F$  包含所有通道的特征, 同时加强了相关类之间的特征映射, 提高了不同故障之间的特征可分辨性。

## 2 故障诊断方法

传统的故障诊断方法均需要对遥测数据进行处理, 这些方法在进行处理时耗时长, 易破坏数据特征, 影响诊断准确率。为解决上述问题, 本文将航天器测控系统某故障状态下遥测数据转换为二维灰度图像, 在此基础上使用残差网络和注意力模块进行故障特征提取。

### 2.1 遥测数据-图像转换

航天器遥测数据是随时间变化的时序数据<sup>[23]</sup>, 为更好地从原始遥测数据中提取故障特征, 同时避免部分特征信息的丢失, 本文将航天器测控系统某故障状态下遥测数据转换为二维图像, 图像像素值大小与遥测数据值相关。选择  $k$  个时间步下  $k$  个标志位的遥测数据, 通过最大最小值归一化方法将航天器遥测数据转换为  $k \times k$  大小的灰度图像, 转换公式为:

$$P(i, j) = R\left(\frac{\theta(i \times k + j) - \min(\theta)}{\max(\theta) - \min(\theta)} \times 255\right) \quad (5)$$

其中,  $0 < i < k, 0 < j < k, R(\cdot)$  为取整函数,  $\theta(t)$ ,  $t = 1, 2, \dots, k^2$  为对应的遥测值,  $\max(\theta)$ 、 $\min(\theta)$  表示  $k^2$  个遥测数据中的最大、最小值,  $P(i, j)$  表示计算后的像素值, 范围为  $(0, 255)$ 。

### 2.2 故障诊断流程

航天器测控系统故障诊断流程分为 3 个步骤, 遥测数据-图像转换、诊断模型训练和故障诊断。故障诊断模型如图 1 所示。

1) 遥测数据-图像转换。首先将航天器测控系统故障数据集的遥测数据与采集到的同一分系统下遥测数据进行数据-图像转换, 生成所需的故障集图像和验证集图像。

2) 诊断模型训练。故障集图像作为模型训练集, 输入到残差网络后得到  $12 \times 8 \times 8$  的特征图, 该特征图分别输入空间注意力模块和通道注意力模块, 得到的两个特征图相加后进行两次卷积操作, 并经过最大池化层、全连接层后由 Softmax 分类器直接输出损失值和准确率。

3) 故障诊断。将测试集图像输入该模型, 判断验证集所属故障类型, 并计算诊断后的准确率, 以实现航天器测控系统的故障诊断。

## 3 实例分析

### 3.1 航天器遥测数据-图像转换

本文使用的航天器故障数据集和验证集均来自某航天器的历史遥测数据和地面测试数据, 受限于地面测试样本量、航天器运行年限和故障发生频次, 为更好地验证

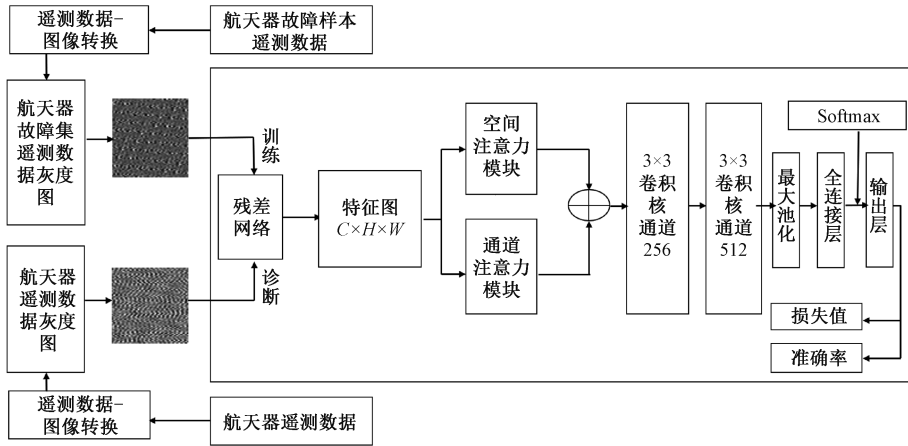


图1 基于AM-ResNet故障诊断模型

Fig. 1 Fault diagnosis model based on AM-ResNet

模型效果,选取4种故障状态下的航天器测控系统遥测数据,并将其转换为灰度图像。图2所示为航天器测控系统遥测数据-图像转换流程。

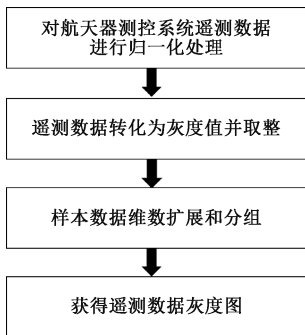


图2 遥测数据-图像转换方法

Fig. 2 Telemetry data-image conversion method

在航天器实际故障中,每种故障发生的频率均不同,导致各故障状态下数据量大小不一,在选取到的航天器历史遥测数据和地面测试数据中,故障1包含16 120组数据,故障2包含33 790组数据,故障3包含21 760组数据,故障4包含19 900组数据,每组数据包含62个数据量。首先将样本中所有数据进行归一化处理并转化为灰度值,为便于数据处理,将每组数据维数扩展至64维;每64组数据堆叠后形成一个 $64 \times 64$ 的二维矩阵,这样,航天器测控系统遥测数据就转变为一张长为64,宽为64,包含 $64 \times 64$ 个像素点的灰度图。在进行数据维数扩展中,空缺数据补0。转换后的结果如表1所示。

该方法将航天器测控系统遥测数据转化为 $64 \times 64$ 的图片,并将4种故障的类型作为转化后灰度图片的标签,行像素值代表同一时间序列下,航天器测控系统中不同标志位的遥测值,列像素值表示不同时间序列下同一

表1 数据-图像转换结果

Table 1 Results of data image conversion

故障类型	尺寸大小	样本量	样本长度	图片数量	类型标签
故障1	$64 \times 64$	16 120	62	252	0
故障2	$64 \times 64$	33 790	62	528	1
故障3	$64 \times 64$	21 760	62	340	2
故障4	$64 \times 64$	19 900	62	311	3

标志位的遥测值。转换后的图像中选取80%作为训练集样本,剩余20%图像为测试集样本。图3所示为4种故障状态下,各选取的1张图片。




图3 航天器遥测数据灰度图

Fig. 3 Gray scale diagram of spacecraft telemetry data

### 3.2 实验参数设置

模型训练时优化器使用随机梯度下降法,学习率使用余弦衰减策略,基础学习率设为0.05,动量值为0.9, Batchsize设置为64, epoch设置为800。测试时除epoch为100外,其余参数与训练过程一致。软硬件环境如表2所示。

### 3.3 残差网络设计

残差网络包含了大量的残差块结构,将尺寸大小为 $64 \times 64 \times 1$ 的故障集图像输入到残差网络后得到 $128 \times 8 \times 8$ 特征图。该网络结构有3个特点。

表 2 实验的软硬件配置情况

Table 2 Software and hardware configuration of the experiment

名称	配置
操作系统	Ubuntu 14.04 64 位
实验框架	Pytorch 0.4.1 (Python 3.6)
CPU	Intel Xeon E5-2630
GPU	NVIDIA GeForce GTX 1080Ti(11 G)
内存	64 GB

1) 通道数为 64 的残差块中步长均为 1,而通道数为 128 的残差块里,除第一个卷积操作将步长设置为 2,其余的卷积操作都将步长设置为 1,此设计在减小特征图的尺寸的同时增加其通道数,以便更好地提取高阶特征。

2) 相同通道数的残差块内部进行卷积操作时,特征图大小不发生变化。

3) 残差块相加时,对于通道数不同的残差块进行 1×1 卷积操作,使得输入和输出通道数一致。

3.4 模型的训练与验证

目前,常用的二维卷积神经网络的卷积核大小为 1×1、3×3、5×5 和 7×7。本文将一维遥测信号进行灰度图像转化后,选用 3×3 的卷积核进行故障图像的特征提取,在加深网络深度的同时可实现以较少的参数获取较大的感受野,从而抑制过拟合。另外在模型中使用 1×1 的卷积核进行升维,实现通道数的一致性。为了验证卷积核大小的适用性,通过选用不同尺寸的卷积核来验证实验效果。

表 3 为不同卷积核尺寸下所提方法的诊断准确率。通过对比不同尺寸卷积核的分类准确率可以看出,当卷积核尺寸为 3×3 时,故障诊断准确率可达到最大值 95.69%,相比于较大的卷积核,该卷积核在获得相同的感受野的同时可提取更多的特征信息,更易于识别航天器测控系统的故障特征,因此最后选用的卷积核尺寸为 3×3。

表 3 不同尺寸卷积核条件下诊断正确率

Table 3 Diagnostic accuracy under convolution kernel of different sizes

卷积核尺寸	准确率/%				平均准确率/%
	故障 1	故障 2	故障 3	故障 4	
3×3	95.27	96.01	95.82	95.69	95.69
5×5	94.96	95.33	95.12	95.09	95.13
7×7	94.13	94.49	94.38	94.35	94.34

为了验证诊断效果,将本文所提模型与 LeNet-5、AlexNet 和 ResNet-18 模型均使用同一数据集进行训练,并在各自的环境下进行了 10 次试验。为使对比实验更具可靠性,同时减少其他因素的干扰,诊断准确率和标准差取 10 次平均值。最终得到的各诊断模型的准确率如表 4 所示。

表 4 各诊断模型准确率

Table 4 Accuracy of each diagnostic model

模型	迭代次数	准确率/%	标准差/%
LeNet-5	100	79.25	15.492
AlexNet	100	90.06	10.025
ResNet-18	100	92.15	5.142
AM-ResNet	100	95.68	4.616

本文所提出的 AM-ResNet 模型可将航天器测控系统的故障诊断准确率提升至 95.68%,10 次重复训练后标准差的均值为 4.616%。与 LeNet-5、AlexNet 和 ResNet-18 这三种故障诊断模型相比,该模型波动性小、稳定性好,且诊断准确率高于其他 3 种模型。其中,AM-ResNet 模型的诊断准确率比 ResNet-18 模型提高了 3.53%,说明使用注意力机制后模型的诊断准确率有显著提升,ResNet-18 模型的诊断准确率分别比 AlexNet 和 LeNet-5 模型提高了 2.09% 和 12.9%,说明残差结构具有显著提高特征提取的能力,可以更好地挖掘深层次特征,对航天器测控系统的故障诊断效果较好。4 种模型的诊断准确率对比效果如图 4 所示。




图 4 不同模型的故障诊断准确率对比

Fig. 4 Comparison of fault diagnosis accuracy of different models

对 AM-ResNet 模型的训练过程进行分析,如图 5 所示,随着迭代步数的增加,诊断准确率越来越高,迭代 80 次后,模型收敛并趋于稳定,最终诊断准确率为 95.6%。

为观察 AM-ResNet 模型在 4 类故障中的诊断效果,对测试集样本进行一次随机测试,得到混淆矩阵如图 6 所示。图 6 中,主对角线为 AM-ResNet 模型预测的正确样本数。由图 6 可以看出,注意力残差网络模型对航天器测控系统各类故障识别具有较高的精度。




图5 AM-ResNet 模型训练结果

Fig. 5 Training results based on the AM-ResNet model




图6 验证结果混淆矩阵

Fig. 6 Confusion matrix of verification results

## 4 结 论

本文提出了基于注意力残差网络的航天器测控系统故障诊断方法,通过数据-图像处理对航天器测控系统故障集遥测数据与验证集遥测数据进行处理,并利用注意力残差网络模型实现故障诊断,最后与3种典型模型的诊断效果进行对比,得出了如下结论。

1) 对遥测数据利用数据-图像处理方法,可有效保留故障数据集中遥测数据的特征,减少对人工经验的依赖,同时扩大了神经网络的“视野”,相比于传统的故障诊断算法,提高了诊断的准确率。

2) 本文提出的注意力模块使得诊断模型更能专注于遥测数据图像中相似的特征,强化相关联的特征,进而提取到更具判别性的特征,使得诊断效果更好。

3) 通过对比 LeNet-5、AlexNet 和 ResNet 方法,注意力模块的引入使得该网络模型能够建立航天器测控系统遥测数据的全局依赖关系,也使 AM-ResNet 网络在航天器故障样本少的条件下取得了 95.68% 诊断准确率,能够

较好地适应航天器在复杂空间环境下的实际情况。

4) 本文基于注意力残差网络模型,设计了航天器测控系统的故障诊断方法,为帮助航天器“智能化、精细化”管理的工作实际,提供了新方法和研究思路,验证了基于注意力残差网络模型对航天器测控系统故障具有较好的诊断能力。接下来将就小样本条件下航天器测控系统的故障诊断展开研究,解决在故障样本量极少的条件下实现航天器测控系统的高准确度诊断。

## 参考文献

- [1] HUANG Y, LI S, SUN J. Mars entry fault-tolerant control via neural network and structure adaptive model inversion [J]. *Advances in Space Research*, 2019, 63(1): 557-571.
- [2] 王大轶, 屠园园, 符方舟, 等. 航天器控制系统的自主诊断重构技术 [J]. *控制理论与应用*, 2019, 36(12): 1966-1978.  
WANG D Y, TU Y Y, FU F ZH, et al. Autonomous diagnosis and reconfiguration technology of spacecraft control system [J]. *Control Theory & Applications*, 2019, 36(12): 1966-1978.
- [3] 沈毅, 李利亮, 王振华. 航天器故障诊断与容错控制技术综述 [J]. *宇航学报*, 2020, 41(6): 647-656.  
SHEN Y, LI L L, WANG ZH H. A review of fault diagnosis and fault-tolerant control techniques for spacecraft [J]. *Journal of Astronautics*, 2020, 41(6): 647-656.
- [4] PATTON R J, FRANK P M, CLARK R N. *Issues of fault diagnosis for dynamic systems* [M]. London: Springer-Verlag, 2000: 1-12.
- [5] FRANK P M. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy: A survey and some new results [J]. *Automatica*, 1990, 26(3): 459-474.
- [6] GONZALEZ-PRIETO I, DURAN M J, RIOS-GARCIA N, et al. Open-switch fault detection in five-phase induction motor drives using model predictive control [J]. *IEEE Transactions on Industrial Electronics*, 2017, 65(4): 3045-3055.
- [7] WU Q, SAIF M. Robust fault detection and diagnosis for a multiple satellite formation flying system using second order sliding mode and wavelet networks [C]. *American Control Conference, IEEE*, 2007: 426-431.
- [8] TALEBI H A, KHORASANI K, TAFAZOLI S. A recurrent neural-network-based sensor and actuator fault detection and isolation for nonlinear systems with application to the satellite's attitude control

- subsystem[J]. IEEE Transactions on Neural Networks, 2008, 20(1): 45-60.
- [9] HUANG Y, LI S, SUN J. Mars entry fault-tolerant control via neural network and structure adaptive model inversion [J]. Advances in Space Research, 2019, 63(1): 557-571.
- [10] WEN L, LI X, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics, 2017, 65(7): 5990-5998.
- [11] HE M, HE D. Deep learning based approach for bearing fault diagnosis [J]. IEEE Transactions on Industry Applications, 2017, 53(3): 3057-3065.
- [12] LUO B, WANG H, LIU H, et al. Early fault detection of machine tools based on deep learning and dynamic identification [J]. IEEE Transactions on Industrial Electronics, 2018, 66(1): 509-518.
- [13] ABBASPOUR A, ABOUTALEBI P, YEN K K, et al. Neural adaptive observer-based sensor and actuator fault detection in nonlinear systems: Application in UAV[J]. ISA Transactions, 2017, 67: 317-329.
- [14] HUNDAMN K, CONSTANTINOU V, LAPORTE C, et al. Detecting spacecraft anomalies using LSTMS and nonparametric dynamic thresholding [C]. Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2018: 387-395.
- [15] 肖雄,王健翔,张勇军,等. 一种用于轴承故障诊断的二维卷积神经网络优化方法[J]. 中国电机工程学报, 2019, 39(15): 4558-4568.
- XIAO X, WANG J X, ZHANG Y J, et al. A two-dimensional convolutional neural network optimization method for bearing fault diagnosis[J]. Proceedings of the CSEE, 2019, 39(15): 4558-4568.
- [16] 朱丹宸,张永祥,潘洋洋,等. 基于多传感器信号和卷积神经网络的滚动轴承故障诊断[J]. 振动与冲击, 2020, 39(4): 172-178.
- ZHU D CH, ZHANG Y X, PAN Y Y, et al. Fault diagnosis for rolling element bearings based on multi-sensor signals and CNN [J]. Journal of Vibration and Shock, 2020, 39(4): 172-178.
- [17] DO V T, CHONG U P. Signal model-based fault detection and diagnosis for induction motors using features of vibration signal in two-dimension domain [J]. Strojniški Vestnik-Journal of Mechanical Engineering, 2011, 57(9): 655-666.
- [18] WEN L, LI X, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method [J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [20] YI X, WANG S H. Abnormality diagnosis in mammograms by transfer learning based on ResNet18[J]. Fundamenta Informaticae, 2019, 168(2-4): 219-230.
- [21] LI X, XU F, LYU X, et al. Dual attention deep fusion semantic segmentation networks of large-scale satellite remote-sensing images [J]. International Journal of Remote Sensing, 2021, 42(9): 3583-3610.
- [22] STETCO A, DINMOHAMMADI F, ZHAO X, et al. Machine learning methods for wind turbine condition monitoring: A review [J]. Renewable Energy, 2019, 133: 620-635.
- [23] 唐艺璠, 窦立谦, 季春惠, 等. 基于深度迁移学习的航天器故障诊断[J]. 空间控制技术与应用, 2021, 47(3): 57-63.
- TANG L F, DOU L Q, JI CH H, et al. Deep transfer learning-based fault diagnosis of spacecraft attitude system[J]. Aerospace Control and Application, 2021, 47(3): 57-63.

### 作者简介



**慕晓冬**, 1987年于第二炮兵工程学院获得学士学位, 1990年于第二炮兵工程学院获得硕士学位, 1994年于第二炮兵工程学院获得博士学位, 现为火箭军工程大学教授, 主要研究方向目标识别、智能信息处理。

E-mail: wascom4@sina.com

**Mu Xiaodong** received his B. Sc. degree, M. Sc. degree, and Ph. D. degree all from The Second Artillery Engineering College in 1987, 1990, and 1994, respectively. He is currently a professor at Rocket Force University of Engineering. His main research interests include target recognition and intelligent information processing.



**魏轩** (通信作者), 2014年于西安交通大学获得学士学位, 现为火箭军工程大学硕士研究生, 主要研究方向为航天器故障诊断。

E-mail: 287505216@qq.com

**Wei Xuan** (Corresponding author) received his B. Sc. degree from Xi'an Jiaotong University in 2014. He is currently a M. Sc. candidate at Rocket Force University of Engineering. His main research interests include spacecraft fault diagnosis.