

基于时空自注意力的航天器电源系统故障诊断^{*}

陈义鹏 徐志强 钟杰 张玉杰 苗强

(四川大学电气工程学院 成都 610065)

摘要: 航天器电源系统是航天器关键子系统之一,其运行状态直接影响整个航天器系统的寿命和性能,因此采用先进的技术对电源系统进行故障诊断,以此提高航天器在轨可靠性和安全性成为目前故障诊断领域的研究重点。基于深度学习的方法具有拟合能力强、特征提取丰富等优势,成为故障诊断领域的主流方法。然而,在航天器电源系统故障诊断领域,主流的故障诊断方法无法捕获序列的长期依赖关系且局限于时间维度建模,严重影响故障诊断方法的性能。因此,本文提出一种基于时空自注意力机制的方法,对航天器电源系统进行高效准确的故障诊断。方法采用基于Transformer的编码器结构提取空间航天器遥测数据中的高维特征,并对其中的自注意力机制进行优化,采用时间卷积提取处理时序特征信息,并采用时间、空间双向自注意力机制提取数据中的时空特征,然后对模型提取的特征进行映射得到空间航天器故障诊断结果。最后在航空电源系统数据集上开展相关实验。实验结果表明与目前故障诊断领域常用的方法进行相比,所提方法具有更强的故障表征提取能力,可有效提高航天器电源系统故障诊断能力。

关键词: 故障诊断;航天器电源系统;时间卷积;自注意力

中图分类号: TN98;TP206+.3 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Spacecraft power system fault diagnosis based on spatio-temporal self-attention

Chen Yipeng Xu Zhiqiang Zhong Jie Zhang Yujie Miao Qiang

(College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: The spacecraft power system is one of the key subsystems, and its operational status directly affects the lifespan and performance of the entire spacecraft system. Therefore, employing advanced technology for fault diagnosis of the power system to improve the reliability and safety of spacecraft in orbit has become a research focus in the field of fault diagnosis. Methods based on deep learning have advantages such as strong fitting ability and rich feature extraction, making them the mainstream approach in the field of fault diagnosis. However, in the field of fault diagnosis of spacecraft power systems, mainstream fault diagnosis methods cannot capture the long-term dependency of sequences and are limited to modeling in the time dimension, severely affecting the performance of fault diagnosis methods. Therefore, this paper proposes a method based on spatio-temporal self-attention mechanism for efficient and accurate fault diagnosis of spacecraft power system. The method adopts a Transformer-based encoder structure to extract high-dimensional features from spacecraft telemetry data, optimizes the self-attention mechanism therein, uses temporal convolution to extract temporal feature information, and employs both temporal and spatio bidirectional self-attention mechanisms to extract spatio-temporal features from the data. Finally, the features extracted by the model are mapped to obtain the fault diagnosis results of spacecraft power system. Relevant experiments are conducted on the spacecraft power system dataset. The experimental results show that compared with commonly used methods in the field of fault diagnosis, the proposed method has stronger fault representation extraction ability, which can effectively improve the fault diagnosis capability of spacecraft power systems.

Keywords: fault diagnosis; spacecraft power system; temporal convolution; self-attention

0 引言

航天器电源系统是航空航天不可或缺的一部分,其被

称为航天器的“心脏”,为航天器各个部件提供持续的能源供给^[1]。但是由于航天器在轨运行过程的恶劣的环境,航天器时有故障发生,通过对1994年~2014年期间的227颗卫

星发生的324例故障信息进行统计,统计表明其中电源系统故障占总故障的26%,是航天器上故障频发的子系统之一^[2-3]。电源系统一旦出现在轨故障,则会影响航天器的整体寿命,并且更严重时会导致整个飞行任务失败,造成巨大的科学和经济损失。因此准确的航天器电源系统故障诊断,有助于提高航天器的可靠性和安全性具有重要的意义^[4]。

目前故障诊断主要可分为基于模型的方法和基于机器学习的方法两类。其中基于模型的方法包括使用定性模型、解析模型等实现对系统的故障诊断^[5-6]。哈尔滨工业大学的张依^[7]详细分析了地球同步卫星的电源系统的各个组成部分的工作原理,并对卫星电源系统中的电池部分、蓄电池部分和控制器部分进行了仿真建模,并依据该模型实现了航天器电源系统的故障诊断。电子科技大学 Shao 等^[8]着重以基于组件的建模方式构建了航天器电源系统模型,能够实现现有组件的可复用性和系统模型的可扩展性,并通过仿真实验验证了模型的正确性。以上基于模型的故障诊断模型在一定程度可实现较高精度的诊断效果,但该方法依赖于专业的知识和经验指导,需要建立精确的机理模型,否则会导致故障诊断精度下降。同时该方法对数据分布有较强的限制,建立的物理模型往往只能针对于某些指定工况,当数据的实际分布与模型假设分布不一致时,会导致模型失效。

目前随着传感器、大数据等技术的进一步发展,大量的航天器遥测数据得以被记录和分析,因而基于数据驱动的故障诊断方法^[9-10]目前逐渐成为热门方法。北京航天测控公司的 Fang 等^[11]提出了一种基于深度机器学习的卫星电力系统故障诊断方法,在初步训练阶段采用去噪自编码器作为无监督算法,提取隐藏在数据背后的复杂特征来实现航天器电源系统故障诊断。根特大学的 Van 等^[12]采用循环神经网络,根据航天器光伏系统的测量来识别六种故障类型,并在模拟光伏系统上验证了方法的有效性。目前基于数据驱动的故障诊断研究中,传统的神经网络受其拓扑结构影响,泛化能力较弱,迭代过程中容易陷入局部最优。而卷积网络对于时间序列这种存在长期依赖特征的数据,无法提取有效的以来特征信息。长短期记忆网络(long short term memory, LSTM)网络模型需要按时间点逐个计算,无法实现并行计算,限制了模型的计算效率,影响模型性能,且在处理长序列时存在梯度消失和梯度爆炸的问题,影响了模型的训练和预测性能。

在近些年的研究中,Transformer^[13]在被引入故障诊断、寿命预测等领域,并展示出了显著的优势^[14-15]。Transformer 模型能够处理长序列而不会面临梯度消失或梯度爆炸的问题,其次,Transformer 中使用的多头注意力机制可以实现并行计算,进一步提高模型的计算效率,并且自注意力机制使模型能够考虑序列的整个上下文,捕捉全局信息,从而提高模型性能。兰州理工大学的 Du 等^[16]采用堆

叠去噪自动编码器提取数据的高维特征,并通过 Transformer 的自注意力机制对提取的特征进行优化,最后在4个开放数据集验证了所提方法的诊断性能。印度理工学院 Nath 等^[17]提出了一种基于传感器融合和 Transformer 的转子结构故障诊断方法,该方法通过在 Transformer 网络中嵌入长短期记忆和门控循环单元模块来提高模型的性能,并在两个数据集上验证了方法的有效性。然而在上述研究中,大多只考虑捕捉时间点之间的依赖关系,对于航天器电源系统故障诊断任务,不同传感器之间的依赖关系同样重要,且在模型中自机制关注的是各时间点之间全局的注意力,对于时间序列中局部上下文关系并不敏感。

因而,本文提出一种基于时空注意力机制的航天器电源系统故障诊断方法,针对航天器电源系统特性进行适配构建基于 Transformer 的故障诊断网络。通过 Transformer 的编码器结构提取数据背后的高维特征,同时采用时间和空间两个维度进行注意力计算,充分挖掘输入序列数据中的时空特征信息,并采用时间卷积增强注意力机制在时间维度上对局部关系的关注度,此外还在模型中引入蒸馏操作,降低数据维度以便于模型可以输入更长的时间序列,而捕获更多特征信息。

1 理论基础

1.1 自注意力机制

自注意力机制最早提出于 Transformer 网络中,该机制能够在序列建模任务中,根据给定的输入序列中不同位置之间的特定关系,自动地学习每个位置与其他位置之间的关联性,并赋予不同权重,使得模型能够在生成特定位置的输出时更加关注重要的信息,从而提高模型的表现能力。

具体来说,对于给定的输入序列数据 $\mathbf{X} \in \mathbb{R}^{L_T \times d}$, 其中 L_T 是输入序列的长度, d 是每个 x_i 的维度。自注意力机制通过计算 query 向量 \mathbf{Q} , key 向量 \mathbf{K} 和 value 向量 \mathbf{V} 之间的映射关系关注全局的相关性信息, \mathbf{Q} , \mathbf{K} 和 \mathbf{V} 分别是对输入序列做线性变化映射到不同的空间得到的3个不同的向量,即 $\mathbf{Q} = \mathbf{W}_Q \mathbf{X}$, $\mathbf{K} = \mathbf{W}_K \mathbf{X}$, $\mathbf{V} = \mathbf{W}_V \mathbf{X}$, 其中 \mathbf{W}_Q , \mathbf{W}_K , \mathbf{W}_V 是可训练的权重矩阵。然后通过计算 query 和各个 key 的相似性或者相关性,得到每个 key 对应 value 的权重系数,接着对 value 进行加权求和,最终得到了的 Attention 数值,自注意力的计算公式可以表示如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (1)$$

其中, T 表示转置操作; d_k 表示 query 向量的维度,其作用是对计算得到的权重进行缩放,防止向量维度太高时计算出的点积过大,以此来稳定模型; Softmax 函数用于计算每个位置的注意力权重,注意力权重被用于加权求和,得到最终的自注意力表示。

1.2 时间卷积

时间卷积网络 (temporal convolutional networks, TCN)在一维因果卷积的基础上加入了膨胀卷积和残差连接,利用卷积并行处理数据,从而跨时间步提取特征,其结构如图 1 所示^[18]。

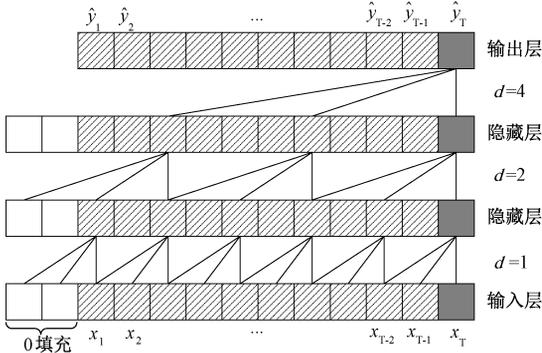


图 1 时间卷积示意图

时间卷积包括因果卷积和空洞卷积两个部分,因果卷积只在当前时间步骤之前的信息上进行卷积,其会将该时刻之前的信息引入当前时刻,且并不会影响时间步骤之后

的信息,保证每个时刻的信息不会包含未来的信息。同时空洞卷积可以有效的增加卷积操作的感受野,以便引入更远时刻的信息,从而可以进一步提高对序列特征捕捉的能力,因果卷积可以定义为:

$$\text{TemporalConv}(\mathbf{X}) = \sum_{i=0}^{k-1} f(k) \cdot x_{i-d \cdot i} \quad (2)$$

其中, f 表示滤波器组; k 表示滤波器的大小; n 表示膨胀系数; $s-d \cdot i$ 表示过去的方向, $\mathbf{X} = (x_1, x_2, \dots, x_T)$ 为输入序列。

从图 1 可以看到时间卷积操作可以有效的增大卷积操作的感受野,增加感受野可以帮助模型识别更长周期的模式,从而更好地捕捉长时间序列中的趋势。同时由于膨胀卷积的卷积核尺寸较小,因此计算效率相对于普通卷积要更高,在处理长时间序列问题时可以降低模型复杂度。

2 基于时空注意力机制的诊断网络

本文所提方法框架如图 2 所示,首先从卫星电源仿真实验平台收集原始数据,并构建训练集和测试集样本,然后训练基于时空自注意力机制的航空电源系统诊断模型,最后使用测试集对模型进行测试,进行实验分析。

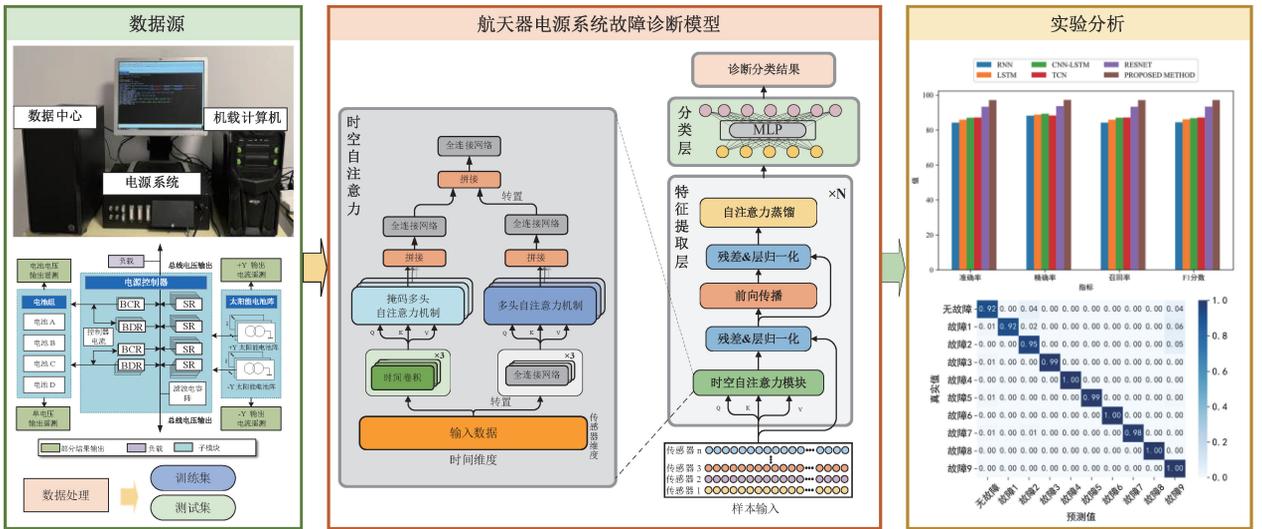


图 2 基于时空注意力机制的航天器电源系统故障诊断模型

本文所提出的基于时空自注意力机制的航天器电源系统诊断网络如图 2 中间部分所示,网络首先将故障样本作为网络输入,通过特征提取网络提取深层的语义信息,转化为内部表示的向量序列。且本文对其中的自注意力机制优化,采用时空注意力机制,在时间维度上计算时间序列中的依赖关系,同时在传感器维度计算传感器之间的相似性和重要关系,充分挖掘航天器电源系统故障模式与时空特征因子的依赖关系,同时采用自注意力蒸馏的方式,降低自注意力模块的维度。

2.1 网络总体结构

基于时空注意力机制的航空器电源系统故障诊断网络是以 Transformer 网络为基础构建。Transformer 主要由编码器和解码器构成,编码器用于将输入序列编码为一种高级抽象表示,解码器则用于生成目标序列。而故障诊断本质上是一种分类任务,因此不需要 Transformer 的解码器结构,这是因为分类任务的目标是将输入序列映射到对应的种类标签上,而不需要生成一个新的序列作为输出。则本文所提出的网络仅采用 Transformer 网络中的编码器来构建特征提取器。

在所提的故障诊断网络中,特征提取网络主要作用是将输入的样本进行编码,提取输入序列中稳健的时空特征信息,以便对故障模式进行建模。特征提取器由 N 个相同的编码器层构成,每个层都由一个时空自注意力层、一个前向传播层、一个残差连接和层归一化层和一个自注意力蒸馏层构成。其中需要对原始的输入序列 \mathbf{X}_m 经过线性变换成一个新的矩阵 $\mathbf{X}_m \in \mathbb{R}^{L_x \times d_{bmodel}}$, L_x 为样本序列长度, d_{bmodel} 为嵌入维度。然后通过特征提取网络进行特征提取,最后经过由多层感知机(multilayer perceptron, MLP)构成的分类器对特征进行映射输出,得到最后分类的故障模式结果。

2.2 时空自注意力机制

1) 时间卷积注意力机制

传统的自注意力机制中采用逐点点积来计算 query 和 key 向量之间的相似性,这种机制关注的是各时间点之间全局的注意力,对于时间序列中局部上下文关系并不敏感。而航天器电源系统的某些特征可能会由于外部因素(如噪声等)而产生波动或异常,这就会导致自注意力机制学习到错误的时序依赖关系。加利福尼亚大学 Li 等^[19]提出采用卷积操作在 query 和 key 中的每个点引入其之前时刻的信息,以增强自注意力机制对局部上下文关系的关注度。但是航天器电源系统的某些特征是变化缓慢的,航天器各部件的故障可能会很大程度取决于更远的时刻状态,而单独的卷积操作的感受野是有限的,因此本文提出采用融合了空洞卷积的时间卷积操作来获取 query 和 key 矩阵,以进一步增强注意力机制对上下文信息的关注。

本文采用时间卷积提取 query, key 和 value 向量,具体来说,分别通过 3 个不同的时间卷积网络,对输入序列做线性变换,分别得到 \mathbf{Q}^T 、 \mathbf{K}^T 和 \mathbf{V}^T 三个向量,具体变换公式如下:

$$\mathbf{Q}^T = \text{TemporalConv}(\mathbf{X}_{en}) \quad (3)$$

$$\mathbf{K}^T = \text{TemporalConv}(\mathbf{X}_{en}) \quad (4)$$

$$\mathbf{V}^T = \text{TemporalConv}(\mathbf{X}_{en}) \quad (5)$$

其中, TemporalConv 表示时间卷积操作; \mathbf{X} 表示输入序列。然后,采用带掩码的多头自注意力机制得出时间维度的自注意力输出,多头注意力机制就是将输入 \mathbf{X} 经过多个线性变换映射到多个不同的空间上,然后通过多个自注意力计算注意力进行运算,并将输出进行拼接,最后通过线性变换映射回原来的空间。

$$\mathbf{A}^T = \text{Concat}(\text{head}_1, \dots, \text{head}_h) \mathbf{W}^{T0} \quad (6)$$

$$\text{head}_i = \text{Softmax}\left(\text{mask}\left(\frac{\mathbf{Q}_i^T (\mathbf{K}_i^T)^T}{\sqrt{d_k}}\right)\right) \mathbf{V}_i^T \quad (7)$$

其中, \mathbf{W}^0 表示全连接层的权重; h 表示多头注意力中头的个数; $\text{mask}(\cdot)$ 表示遮罩操作,其将矩阵的上三角元素置为 $-\infty$,其余元素不变,主要作用是确保某点的注意力分数只能通过改点之前的元素得到,防止历史信息泄露,更有利于模型对重要信息的关注。

2) 时空注意力机制

传统的自注意力机制仅考虑时间维度上事件依赖的相关性,而在航天器电源系统故障诊断任务中,针对不同的传感器参数,同样要考虑各传感器之间的关联关系对最后故障诊断任务的影响。因此在本文中提出了时空自注意力机制,采用前文提到的时间卷积自注意力机制在时间维度上对时间序列中不同时刻之间的关系进行建模,捕捉时间序列中的长期依赖关系。同时在传感器维度进行全局注意力操作,充分挖掘不同传感器之间的关联关系。并将得到的时间维度的自注意力输出和空间维度的自注意力输出进行融合。时空自注意力模块充分考虑时间依赖性和传感器的之间的交互关系,充分挖掘输入序列中的深层语义特征信息,时空注意力机制流程图如图 3 所示。

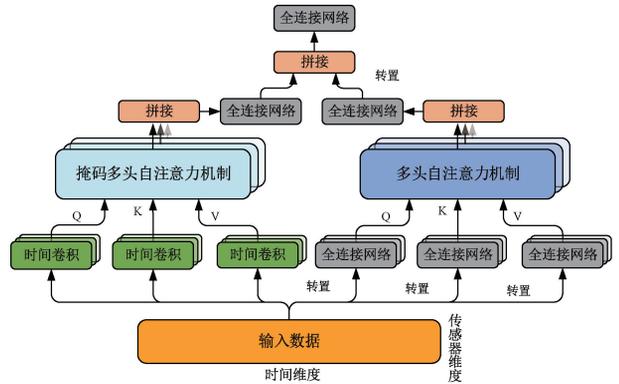


图 3 时空自注意力网络结构图

对于输出数据,首先需要将原始输入数据进行转置操作,然后通过多头注意力机制计算获取各个传感器之间的相关性,并得到自注意力的输出,具体可由下式表示:

$$\mathbf{A}^S = \text{Concat}(\text{head}_1, \dots, \text{head}_h) \mathbf{W}^S \quad (8)$$

$$\text{head}_i = \text{Softmax}\left(\frac{\mathbf{Q}_i^S (\mathbf{K}_i^S)^T}{\sqrt{d_k}}\right) \mathbf{V}_i^S \quad (9)$$

其中, \mathbf{W}^S 表示全连接层的权重; h 表示多头注意力中头的个数; \mathbf{Q}^S 、 \mathbf{K}^S 、 \mathbf{V}^S 由全连接网络进行线性变化得到,即 $\mathbf{Q}^S = \mathbf{W}_Q \mathbf{X}^T$ 、 $\mathbf{K}^S = \mathbf{W}_K \mathbf{X}^T$ 、 $\mathbf{V}^S = \mathbf{W}_V \mathbf{X}^T$,其中 \mathbf{W}_Q 、 \mathbf{W}_K 、 \mathbf{W}_V 是可训练的权重矩阵。由于在传感器维度上,传感器之间不再存在时序相关性,因此采用全连接网络进行变换,同时也不会存在时序信息泄露问题,因此在传感器维度上不采用 $\text{mask}(\cdot)$ 。当得到时间与空间两个维度的注意力输出后,然后采用与 Transformer 中多头注意力机制中的融合一样的方法,采用全连接操作将时空双维注意力结果融合映射输出,即最后时空自注意力的输出为:

$$\mathbf{A}^{ST} = \text{Concat}(\mathbf{A}^T, \mathbf{A}^S) \mathbf{W}^{ST} \quad (10)$$

其中, \mathbf{W}^{ST} 表示全连接层的权重; \mathbf{A}^T 和 \mathbf{A}^S 分别为时间和传感器维度进行多头注意力计算得到的输出。

2.3 自注意力蒸馏

在航天器电源系统故障诊断任务中,模型输入更长的时间序列可以为模型提供更加丰富的历史信息,因此往往

可以取得更好的效果。但是在内存有限的情况下,会导致输入的时间序列长度受限。并且前文介绍的时空注意力因为采用两条独立的支路分别计算时间和空间注意力,因此增大了模型的参数,进一步限制了模型输入序列的长度。为了输入更长的序列,本文参考了北京航空航天大学 Zhou 等^[20]所提出数据蒸馏方法,蒸馏操作对具有支配特征的优势特征进行特权化,并在下一层构建一个聚焦的自注意力特征图,具体来说就是通过缩减输入的时间维度,且尽可能的保留原有信息,有效降低模型的内存消耗,使得模型能有更长的时间输入,获得更好的预测效果。在编码器中,从 1 层到 1+1 层的蒸馏操作可由下式描述:

$$X_{j+1} = \text{AvgPool}(\text{PReLU}(\text{Conv1d}(X))) \quad (11)$$

其中, AvgPool(·) 表示平均池化操作; Conv1d(·) 表示一维卷积操作; PReLU(·) 为激活函数。本文使用平均池化代替了最大池化操作,平均池化通过提取特征的平均值,避免较小值特征的丢失,同时使用 PReLU 激活函数来代替线性指数激活(ELU)函数, PReLU 在几乎不增加计算量和过拟合风险的同时将输出均值向 0 推进,以便模型可以更快收敛。

3 实 验

本节主要对所提的模型进行实验分析。首先对基线数据进行介绍。其次,结合数据特点介绍了数据预处理和样本构建方法,并介绍了模型的评价指标。然后将本文所提模型与对比模型的结果进行比较分析,验证所提模型的优越性。最后通过消融实验验证模型中组件的必要性和优势。

3.1 数据集介绍

航天器电源系统是一个复杂的系统,负责生成、存储、转换、调控和分配电能。为验证本文所提方法的有效性,本研究搭建了一个半物理实验平台,包括电源系统、数据中心和机载计算机,结构如图 4(a)所示。电源系统是平台的核心部分,由太阳能电池阵、电池组和电源控制单元组成,内部结构如图 4(b)所示。太阳能电池阵和电池组在航天器处于不同光照区时分别交替工作。电源控制单元包括分流稳压器(shunt regulator, SR) 电池充电稳压器(battery charging regulator, BCR)和电池放电稳压器(battery discharge regulator, BDR)主要用于确保电源系统的安全运行。电源系统的数据以 JS 对象简谱(javascript object notation, JSON)日志形式记录在数据中心的数据库中。机载计算机能够随时解析数据库中的日志信息,并将其转化为 32 维时间序列数据。平台记录了九种不同的故障和正常状态,主要涵盖太阳能电池阵和电池组。详细的故障名称如表 1 所示。

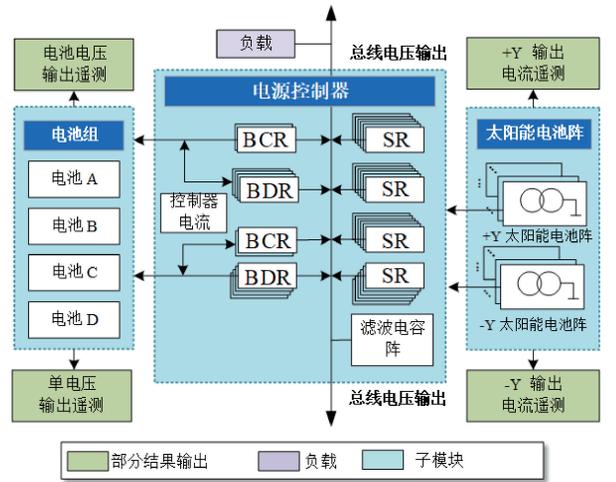
3.2 实验设置

1) 实验环境

该节实验在一台配备了 NVIDIA GeForce RTX 4090



(a) 半物理实验平台



(b) 航天器电源系统结构图

图 4 航空器电源系统故障诊断平台

表 1 电源系统故障类型

故障部件	故障描述	故障编号
太阳能电池阵	负 Y 太阳电池阵组功率下降	故障 1
	正 Y 太阳电池阵组功率下降	故障 2
	负 Y 方向蓄电池组电压偏高	故障 3
蓄电池组	蓄电池 A 单体电压故障	故障 4
	正 Y 方向蓄电池组电压偏高	故障 5
	蓄电池 C 单体电压故障	故障 6
	PCU 主误差控制电压漂移	故障 7
电源控制器	母线负载短路	故障 8
	分流调节器电压转换故障	故障 9

GPU 的服务器上实验,操作系统为 Centos Stream 9,编程语言为 Python,采用 Pytorch 深度学习框架进行开发。网络优化器选择为 Adam,学习率设置为 0.001, BatchSize 设置为 32。

2) 归一化

卫星电源数据的每个通道测量值均来自不同的遥测

传感器,因而数据集中各数据段的量纲存在较大差异,因此使用最大值最小值归一化使得不同规模的特征值处于同一数值范围之内,避免特征间的影响。并且归一化可以减少特征间的异常值,使得各参数可以更好地发挥作用,提高学习算法的性能和准确性。具体归一化过程可表示如下式:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (12)$$

其中, X_{norm} 是归一化后的数据, X 是原始数据, X_{max} 和 X_{min} 分别代表数据中的最大值和最小值。

3) 滑动窗口处理

滑动窗口是一种处理时间序列数据的技术,可以将时间序列划分为多个大小相同的窗口,滑动窗口将连续时间序列划分为多个子序列样本,滑动窗的方式相较于单一时间步长,它更能反映故障模式。具体而言,滑动窗口方法会选择—个窗口大小(即时间序列数据点的数量),并且从时间序列的开始位置开始,依次移动窗口。网络模型的输入则是每个窗口中包含的数据。

4) 评价指标

为了量化模型的诊断效果,本文采用准确率(Accuracy)、精确率(Precision)、召回率(Recall)和F1分数四种指标对模型进行评估,本文选取这四种指标进行评估可以较为全面的评价模型的优劣。评价指标定义如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Recall = \frac{TP}{TP + FN} \quad (15)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (16)$$

其中, TP 表示真正例(True Positive), TN 表示真负例(True Negative), FP 表示假正例(False Positive), FN 表示假负例(False Negative)。

3.3 对比实验

本文选取了几种基于循环神经网络(recurrent neural network, RNN)和卷积神经网络(convolutional neural networks, CNN)的深度学习模型作为基准方法,这些方法在故障诊断领域得到了广发的使用,具体诊断分类结果如表2所示。从表中可以看到本文所提方法,在各项指标上均达到了最优。模型相较于RESNET^[21]、TCN^[18]、CNN-LSTM^[22]、LSTM^[23]和RNN^[24]在准确率上分别提升了3.83%、9.96%、10.09%、11.22%和12.92%,所提方法相较于这些经典方法均有较大提升。在各类模型中RNN分类效果最差,这是因为简单的循环神经网络,其拓扑结构仍较为简单,对于复杂的航天器电源系统数据,无法提取有效的特征信息,因而效果较差。而改进后的LSTM和CNN-LSTM相较于原始RNN网络,其性能得到了一定的

提升,但结果仍不理想。

表2 诊断分类精度对比结果

模型名称	准确率	精确率	召回率	F1分数
RNN	84.23	88.25	84.23	84.44
LSTM	85.93	88.83	85.93	86.14
CNN-LSTM	87.06	89.32	87.06	86.79
TCN	87.19	88.33	87.19	87.21
RESNET	93.32	93.70	93.32	93.39
所提方法	97.15	97.24	97.15	97.17

此外,各模型的各项分类评价指标柱状图如图5所示,可以看到所提出的模型在各指标上均达到了最优值,由于基于时空自注意力的诊断模型采用了Transformer架构,它能够捕捉传统网络无法获得的故障表征,并且采用了时空双向自注意力,能够捕获更加丰富的时空特征,因此更适合于故障诊断任务。

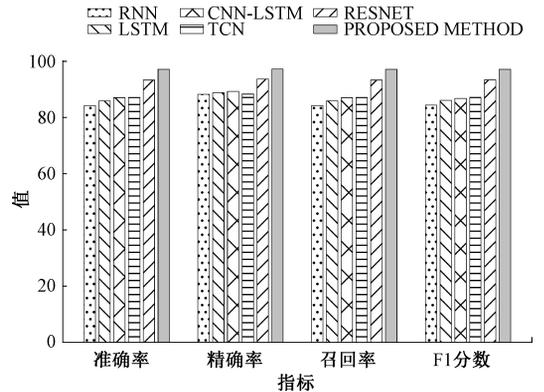


图5 模型指标对比结果

为进一步分析表1内各种故障模式诊断的精度,本文绘制了分类准确度前四的模型分类混淆矩阵如图6所示。从故障分类结果可以看出,3种对比模型对于正常状态的分类结果都不是很好,都存在较高概率会将无故障的样本错分成其他故障类型,而本文所提的模型则能较好的诊断无故障样本。此外,对比方法除了RESNET网络外,其余两种对比方法TCN和CNN-LSTM对于故障6(蓄电池C单体电压故障)会有较大概率错分成故障4(蓄电池A单体电压故障),而RESNET则会有较大概率将故障4错分成故障6,这因为两者均为电池组电压故障,其特征表现类似,如果无法提取有效的特征信息则会无法分辨这两种故障,因此对比方法对于这两种相似故障有较高概率错分,而本文提出的方法则能较好的处理这两种故障,相比之下,本文提出的模型在总体上表现得更加出色,具有更低的误判率。

3.4 消融实验

为了验证所提出的时空自注意力机制的必要性,在本小节将进行相关消融实验。以本文所提的基于时空自注

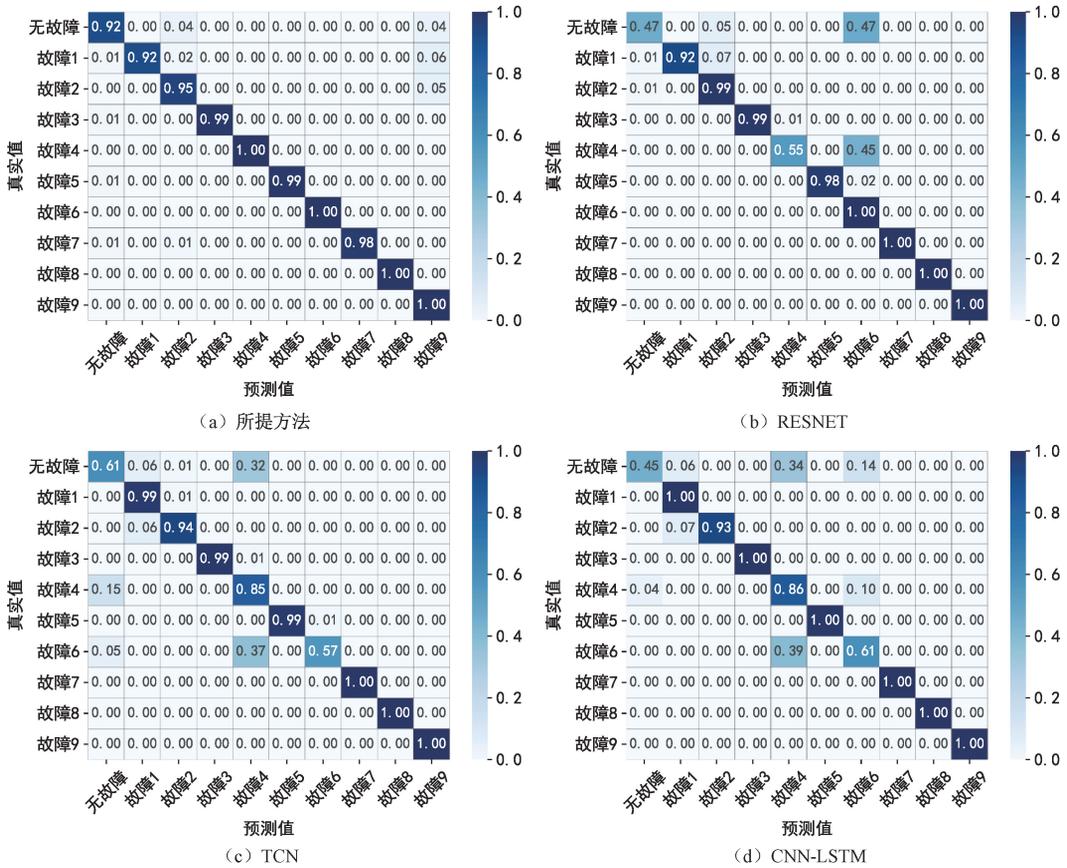


图 6 各模型混淆矩阵

注意力机制的航空器电源系统故障诊断模型为基准模型，分别去除时间维度的自注意力机制和空间维度的自注意力机制，并保持模型其他结构、参数不变，在相同环境下重新训练模型，并使用测试集测试得到如表 3 所示的结果。从表中可以看出，无论去除哪一个维度的自注意力机制，都会导致模型性能的损失，去除时间维度和空间维度的自注意力机制将导致模型最后预测精度分别下降 0.95% 和 1.19%，因此本文所提出的时空自注意力机制模块的双维度均具有必要性，本文所提模型能将这两个维度有机结合，相互协同，最终取得了较好的诊断性能。

表 3 自注意力机制消融结果

模型	准确率	精确率	召回率	F1 分数
所提基准模型	97.15	97.24	97.15	97.17
仅保留时间维度	95.96	97.01	95.96	96.19
仅保留空间维度	96.20	96.95	96.20	96.37

4 结 论

本文提出了一种基于时空双维度自注意力机制的航天器电源系统故障诊断方法。所提方法采用基于 Transformer 编码器结构的网络提取样本数据中的深层特

征信息，并且针对网络中的自注意力机制模块进行优化，采用并行的时间、空间双维度的自注意力机制来分别提取时间维度的特征和传感器维度的特征信息。最后通过在航空器电源系统数据集进行了实验分析，通过对比实验与目前常用的 RNN 和 CNN 网络进行对比，验证了模型的优越性，在诊断精度上均有较大提升。此外，还通过消融实验验证了时空自注意力机制模块中时间维度和空间维度两个维度的必要性。鉴于空间电源系统工作于环境恶劣的深空环境，难以避免一些未知的故障情况的发生。为了提升空间电源系统的可靠性和稳定性，将在未来的研究中着重关注空间电源系统在未知故障情景中的故障诊断任务。

参考文献

[1] SUO M, TAO L, ZHU B, et al. Soft decision-making based on decision-theoretic rough set and Takagi-Sugeno fuzzy model with application to the autonomous fault diagnosis of satellite power system[J]. Aerospace Science and Technology, 2020, 106: 106108.

[2] CHEN Q, LIU Z, ZHANG X, et al. Spacecraft Power System Technologies [M]. Singapore: Springer, 2020.

[3] 谭春林, 胡太彬, 王大鹏, 等. 国外航天器在轨故障

- 统计与分析[J]. 航天器工程, 2011, 20(4): 130-136.
- [4] 向刚, 韩峰, 周虎, 等. 数据驱动的航天器故障诊断研究现状及挑战[J]. 电子测量与仪器学报, 2021, 35(2): 1-16.
- [5] 董磊, 马桂芳, 李清东. 卫星电源系统的有向图分层诊断方法[J]. 计算机应用, 2012, 32(S2): 38-40.
- [6] 李伟宸. 卫星电源系统关键装置在轨状态监测方法研究[D]. 南京: 南京理工大学, 2023.
- [7] 张依. 卫星电源系统故障诊断平台的设计与研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.
- [8] SHAO J, WAN H, HUANG H Z, et al. Study on modeling and diagnosis of the satellite power system[C]. 2012 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, 2012: 607-611.
- [9] 田思维, 朱爱军, 贾树泽, 等. 基于遥测数据频域特征的气象卫星故障诊断方法[J]. 电子测量技术, 2021, 44(14): 158-162.
- [10] ZHOU Y, WU K, MENG Z, et al. Fault detection of aircraft based on support vector domain description[J]. Computers & Electrical Engineering, 2017, 61: 80-94.
- [11] FANG H, SHI H, DONG Y, et al. Spacecraft power system fault diagnosis based on DNN [C]. 2017 Prognostics and System Health Management Conference, 2017: 1-5.
- [12] VANN GOMPEL J, SPINA D, DEVELDER C. Satellite based fault diagnosis of photovoltaic systems using recurrent neural networks[J]. Applied Energy, 2022, 305: 117874.
- [13] VASWANI A, SHAZEER N, PARAMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30: 5998-6008.
- [14] 康玉祥, 陈果, 盛嘉玖, 等. 低转速航空发动机滚动轴承故障深度异常检测方法[J]. 振动与冲击, 2024, 43(7): 186-195.
- [15] 张帆, 姚德臣, 姚圣卓, 等. 基于 Transformer-LSTM 网络的轴承寿命预测[J]. 振动与冲击, 2024, 43(6): 320-328.
- [16] DU X, JIA L, HAQ I U. Fault diagnosis based on SPBO-SDAE and transformer neural network for rotating machinery[J]. Measurement, 2022, 188: 110545.
- [17] NATH A G, UDMALE S S, RAGHUWANSHI D, et al. Structural rotor fault diagnosis using attention-based sensor fusion and transformers [J]. IEEE Sensors Journal, 2021, 22(1): 707-719.
- [18] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. ArXiv Preprint, 2018, ArXiv: 1803.01271.
- [19] LI S, JIN X, XUAN Y, et al. Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting [J]. Advances in Neural Information Processing Systems, 2019, 32: 5243-5253.
- [20] ZHOU H, ZHANG S, PENG J, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11106-11115.
- [21] 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.
- [22] SUN Z, MACHLEV R, WANG Q, et al. A public dataset for synchronous motor electrical faults diagnosis with CNN and LSTM reference classifiers [J]. Energy and AI, 2023, 14: 100274.
- [23] TANG Z, BO L, LIU X, et al. A semi-supervised transferable LSTM with feature evaluation for fault diagnosis of rotating machinery [J]. Applied Intelligence, 2022, 52(2): 1703-1717.
- [24] YANG G, LIU Y, LI N, et al. Intelligent Fault Diagnosis Method of Capacitor Voltage Transformer based on Recurrent Neural Network [C]. 2023 4th International Conference on Computer Engineering and Application, 2023: 412-416.

作者简介

陈义鹏, 硕士, 主要研究方向为装备故障诊断。

E-mail: yipeng_scu@163.com

苗强(通信作者), 教授, 主要研究方向为装备智能健康评估。

E-mail: mqiang@scu.edu.cn