

一种基于元学习的大口径射电望远镜俯仰轴承 故障辨识方法研究*

朱金浩^{1,2} 许谦^{1,3,4†} 薛飞^{1,2} 何飞龙^{1,2} 梁娟^{1,2} 许多祥^{1,2}

(1 中国科学院新疆天文台 乌鲁木齐 830011)

(2 中国科学院大学 北京 100049)

(3 中国科学院射电天文重点实验室 乌鲁木齐 830011)

(4 新疆射电天体物理重点实验室 乌鲁木齐 830011)

摘要 在经过长期运行后大口径射电望远镜俯仰轴会出现微小扭曲, 滚动轴承作为承载俯仰轴的核心部件, 也会因长期承受交变载荷增加疲劳风险, 导致轴承寿命以及望远镜指向精度的下降, 极大影响望远镜的性能。以俯仰轴承为研究对象, 开展故障辨识方法研究, 可为望远镜天线的高性能运行提供重要支撑。为实现在有限数据和复杂工作条件下准确地辨识俯仰轴承故障, 提出了一种小样本条件下基于元学习的故障辨识方法(Few-shot Meta-learning Fault Identification, FMFI)。首先将不同工况下的原始信号转换为时频图像数据, 之后按照元学习协议将数据样本随机采样到不同的学习任务中。在有限样本的条件下, FMFI可以通过训练任务中的样本信息获取通用的先验知识, 在未知的测试任务下实现准确快速的故障辨识。选取了与望远镜俯仰轴承工况具有相似性的变负载轴承数据集进行实验, 实验结果表明, FMFI方法具有很高的准确性和可靠性, 为大口径射电望远镜俯仰轴承的主动运维和高质量服役提供了有力的技术支持。

关键词 望远镜, 仪器: 俯仰轴承, 方法: 数据分析, 方法: 模式识别

中图分类号: P111; **文献标识码:** A

1 引言

伴随着射电望远镜朝着大口径、高频段的方向发展, 望远镜的指向精度越来越高, 这对设备的精确性、可靠性的要求越来越严苛, 望远镜结构的稳定性对望远镜综合性能的影响变得不可忽略。大口径射电望远镜的正常运行对机械系统的稳定性和所用部件的质量、性能有很高的要求^[1], 俯仰轴承作为支撑和稳定天线的关键部件, 其性能关系到

望远镜的观测精度和结构稳定性。随着射电望远镜口径的不断增大, 望远镜的结构重量在不断增加, 并且望远镜受环境和自身重力因素影响^[2-4], 天线经过长期运行后结构上会发生扭曲, 产生小尺度形变, 导致轴承部分的动态承载平衡产生变化, 轴承结构易损伤, 降低望远镜性能甚至危及望远镜结构安全。

国内外学者对于望远镜的轴承系统的研究主要集中在轴承的受力分析、载荷特性、轴系支撑

2023-03-21收到原稿, 2023-04-03收到修改稿

*国家自然科学基金项目(12273102), 中国科学院青年创新促进会项目(Y202019), 国家重点研发计划(2021YFC2203601), 新疆维吾尔自治区自然科学基金项目(2021D01B111、2022D01B72), 中国科学院天文台站设备更新及重大仪器设备运行专项, 中国科学院科研仪器设备研制项目(PTYQ2022YZD01)资助

†xuqian@xao.ac.cn

系统设计方面^[5-7]. 针对望远镜轴承的故障辨识方向, Rayo^[8]研究了甚大望远镜(Very Large Telescope, VLT)中的旋转机械结构, 基于时域和频域方法分析了该结构内外轴承的振动特性, 完成了旋转机械结构轴承部分的故障识别, 为VLT的运维提供了参考. 在轴承故障识别领域主流方法均基于机器学习, 在充足的样本上通过分析处理得到特征表示, 实现故障的识别^[9-11].

在射电望远镜中, 俯仰轴承一般为滚动轴承, 其性能对望远镜的高精度观测至关重要. 望远镜在运行时天线方位和俯仰角不断变化, 并且望远镜会受到环境以及自重的影响, 长时间的运行将引起天线俯仰轴微小变形, 导致轴承的承载特性变化, 产生磨损和其他失效表现, 影响望远镜的精度和可靠性. 因此对俯仰轴承进行故障辨识方法研究, 可以及时发现和解决轴承的潜在风险, 保障望远镜的正常运行和观测数据的准确性, 还可以为天线的主动运维和观测计划的调整提供重要技术支撑, 为俯仰轴承有效服役甚至超期服役提供坚实保障.

传统的机器学习方法通常需要大量的数据训练模型, 然而望远镜天线机械系统复杂, 俯仰轴承故障样本数量有限, 采用传统的机器学习方法难以达到理想的效果. 为应对这一挑战, 结合实际的应用和需求, 本研究提出了一种小样本条件下基于元学习的故障辨识方法(Few-shot Meta-learning Fault Identification, FMFI), 能够节省人工辨识故障的成本, 并且克服传统机器学习方法需要大量数据的缺陷, 实现了快速准确的轴承故障辨识.

2 理论背景

2.1 小样本学习

小样本学习(Few-shot Learning, FSL)通过模拟人类从少量样本中快速搜索特征并获取知识的学习概括能力, 能够在有限样本条件下获得高准确度的模型. 在小样本学习中, 通常会出现训练数据和测试数据领域不同的情况, 其中训练数据来自源域, 测试数据来自目标域. 小样本学习方法针对源域数据样本学习, 将有限的训练样本转化至通用的特征空间, 获取领域知识和经验, 得到一种通用

的特征表示方法, 倾向于应用知识以解决新的问题^[12]. 在面临未知领域的测试数据时, 根据所学知识, 通过计算新样本的通用特征表示, 实现目标域的分类.

传统的机器学习方法一般是针对特定数据, 采用专门设计的算法来完成固定的任务. 其训练数据和测试数据来自同一领域, 并且通常需要大量的数据来训练模型, 使模型在测试数据上具有高准确性. 在应对数据样本较少的情况下, 采用传统的机器学习方法可能会面临过拟合等问题, 导致模型无法有效地泛化到新数据中, 难以达到理想的分类和辨识效果.

图1展示了不同学习方法策略, 其中X0至X6分别为7种不同类别的数据. 图1 (a)展示了小样本学习方法的学习策略, 训练数据和测试数据的数据类型不同, 且数据量有限. 图1 (b)展示了传统的机器学习方法的学习策略, 训练数据和测试数据的数据类型相同, 且所需的数据量较多.

2.2 元学习

元学习(Meta Learning)针对任务进行学习, 能够开发快速有效地适应新任务的模型. 通过在一组任务上训练模型, 使其学习一套更普遍的知识, 针对多个任务都能有较好效果, 并在面对未知的新任务时也可得到不错的性能.

元学习的每个学习任务均包含训练数据和测试数据. 给定元模型 f 、训练任务集 $\mathcal{D}_{\text{train}}$ 、测试任务集 $\mathcal{D}_{\text{test}}$, 每个任务都包含作为训练数据的支撑集 $\mathcal{D}_{\mathcal{T}_i}^s$ 以及作为测试数据的查询集 $\mathcal{D}_{\mathcal{T}_i}^q$. 在训练阶段, 第*i*个任务的任务模型参数更新以及性能评估的公式表述如(1)式和(2)式所示.

$$\theta'_i = \arg \min_{\theta_i} \mathcal{L}(\mathcal{D}_{\mathcal{T}_i}^s; \theta_i; \omega), \quad (1)$$

$$P_{f_{\theta'_i}} = f_{\theta'_i}(\mathcal{D}_{\mathcal{T}_i}^q), \quad (2)$$

其中 $\mathcal{D}_{\mathcal{T}_i}^s$ 和 $\mathcal{D}_{\mathcal{T}_i}^q$ 分别是第*i*个任务的支撑集和查询集, θ_i 为更新前的任务模型参数, ω 为模型的元知识, $\mathcal{L}(\mathcal{D}_{\mathcal{T}_i}^s; \theta_i; \omega)$ 为模型在第*i*个任务的损失函数, θ'_i 为任务模型参数的更新结果, $P_{f_{\theta'_i}}$ 为模型 f 使用任务参数 θ'_i 在查询集 $\mathcal{D}_{\mathcal{T}_i}^q$ 中的性能度量.

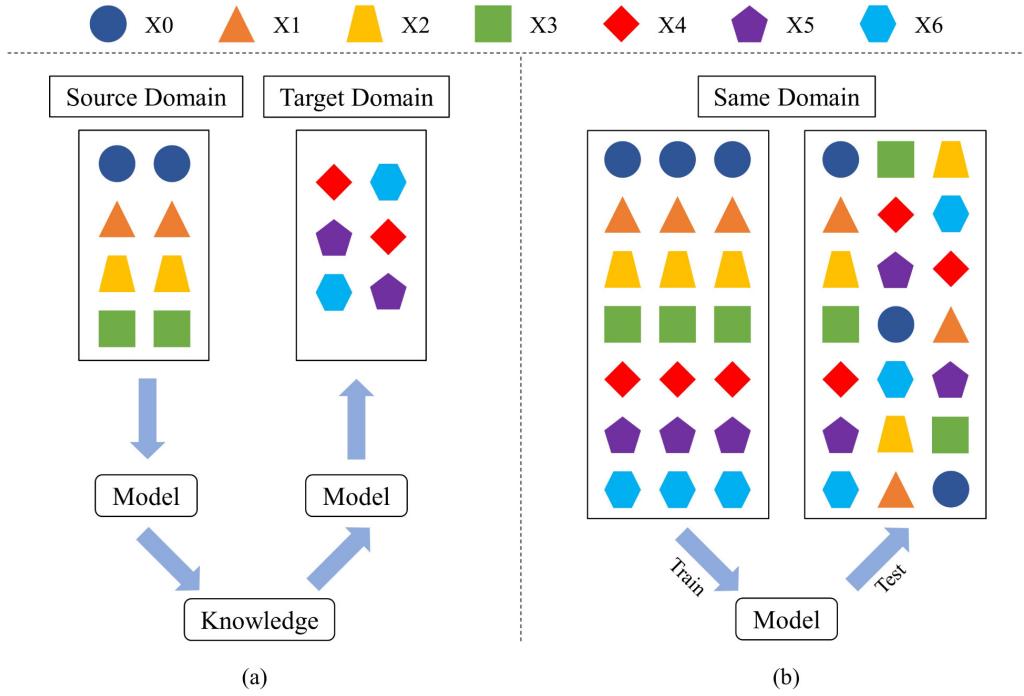


图1 不同学习策略的示意图. (a) 小样本学习, (b) 传统的机器学习.

Fig. 1 Diagram of different learning strategies. (a) Few-shot Learning, (b) Traditional Machine-Learning.

模型通过学习所有训练任务, 获得通用的知识 ω . 在面对测试任务时, 可以快速适应新的情况.

本研究提出的FMFI方法使用的算法是作为目前元学习方法中最具代表性的与模型无关的元学习算法(Model-Agnostic Meta-Learning, MAML), 能够通过对极少样本的学习, 获得跨任务的概括能力, 从而快速适应新的情况^[13-14]. 在对大口径射电望远镜的俯仰轴承进行故障辨识时, 基于MAML可以在有限样本的条件下, 提取到通用的故障知识, 实现未知工况的故障辨识.

3 FMFI架构

利用有限的数据样本在新工况下进行俯仰轴承的故障辨识, 是典型的小样本分类问题. 由于传统的机器学习方法难以解决, 为此本文利用元学习方法提出了基于MAML框架的FMFI方法.

图2展示了FMFI方法的流程, 整个流程分

为4个模块: 轴承数据获取模块、数据处理模块、任务构建模块、故障辨识模块. 轴承数据获取模块主要用于获取不同工况的轴承振动状态数据. 数据处理模块将采集到的轴承数据划分为已知工况数据和未知工况数据, 分别提取数据的时频域特征. 任务构建模块进一步将已知工况的数据特征转换为元训练集, 未知工况的数据特征转换为元测试集, 根据元学习的 N -way、 K -shot协议将特征分别采样至不同的任务, 其中 N -way指的是每个任务的训练数据中有 N 个类别, K -shot指每个类别下有 K 个被标记数据用来训练, 称为当前任务的支撑集, 此外还有部分被标记数据用于测试, 称为当前任务的查询集. 假定元训练集包含 n 个任务, 元测试集包含 n' 个任务, 二者支撑集的故障种类均为 M , 从而构建FMFI任务. 故障辨识模块给出了FMFI方法的网络模型结构, 基于FMFI方法通过对已知工况的轴承样本特征的学习获取元知识, 在有限数据样本条件下, 实现未知工况的俯仰轴承故障辨识.

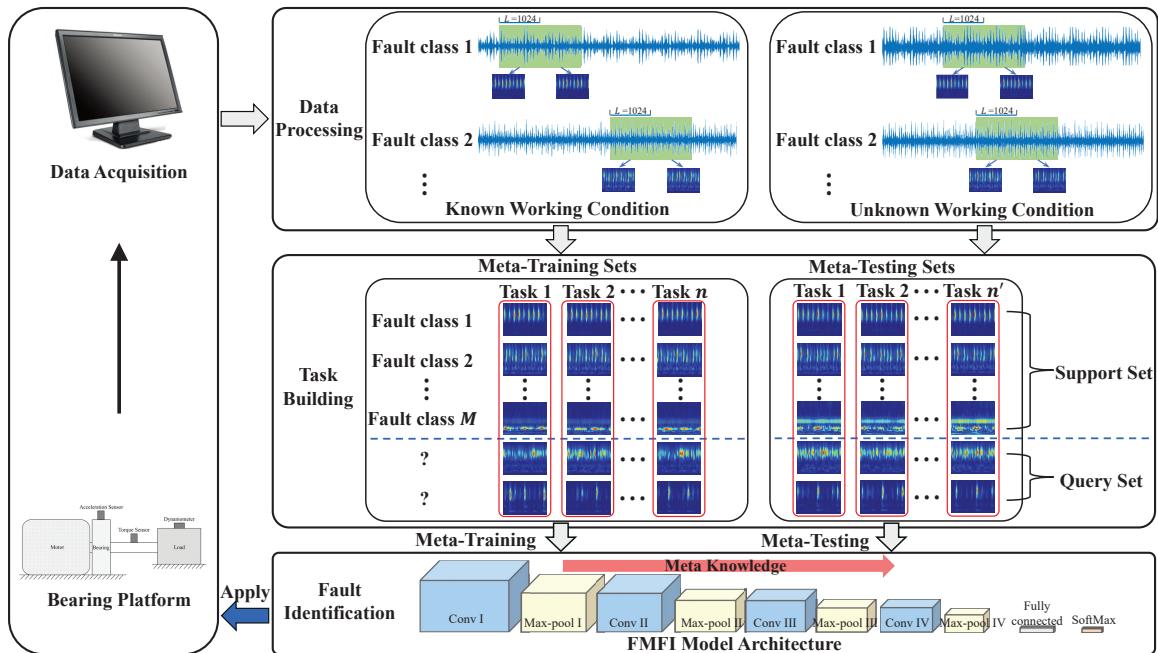


图2 FMFI方法流程图

Fig. 2 The flowchart of FMFI method

3.1 数据处理

利用加速度传感器获取轴承振动信号后,采用连续小波变换(Continuous Wavelet Transform, CWT)将一维时域数据转换为时频图像数据,获得信号的时频域特征。

CWT的基本原理是将一个小波函数 $\psi(t)$ 不断在时间轴和尺度轴上进行平移和缩放得到小波基函数 $\psi^{a,b}(t)$,其公式表述如下:

$$\psi^{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), \quad (3)$$

其中 a 为实现小波伸缩变换的尺度因子, b 为实现小波移位变换的位移因子。

将小波基函数 $\psi^{a,b}(t)$ 的复共轭函数 $\psi^{*,a,b}(t)$ 与信号进行内积运算,可以得到一系列时频系数。给定原始信号 $s(t)$,其小波变换定义为:

$$C(a, b) = \int_{-\infty}^{+\infty} \psi^{*,a,b}(t) s(t) dt. \quad (4)$$

对于不同的尺度和位移参数,可得到一系列时频系数 $C(a, b)$,这些时频系数可以反映信号在不同

时间和尺度上的能量分布,进而构成信号的时频图。

CWT具有可变分辨率的优点,能够更好地捕捉信号中的瞬时频率变化^[15],本研究采用CWT获取时频图像。时频图像如图2右上部分所示,图像的x轴为时间轴,代表信号的时域变化;y轴为频率轴,代表信号的频域变化;图像的亮度颜色深浅代表频域的振幅大小,即特定时间和频率处的信号强度,深色代表高能量,浅色代表低能量。

3.2 任务构建

采用基于MAML框架的FMFI方法在有限样本条件下实现俯仰轴承的故障辨识,需根据元学习框架协议的特点将数据集划分为包含不同类型故障的小样本学习任务。

N -way、 K -shot协议是元学习中最典型的任务协议,它定义了如何划分数据集来训练元学习模型^[16]。在训练时,通常会从数据集随机选择若干任务,模型在支撑集上进行训练,在查询集上进行评估,并更新任务模型参数,以适应当前任务。通过这种方式,模型在各个任务的不断迭代中逐步优化,

最终可以在新任务上进行快速、高效的学习。

为确保FMFI从多个不同的任务中学习到通用的故障信息知识, 使用已知和全新工作条件下的时频图像构建了元训练、元验证和元测试集。在训练过程中, 模型需要在不同类型的任务上进行训练和调整, 以适应不同类型的俯仰轴承故障辨识任务。在测试过程应用于未见过的新轴承故障辨识任务。

3.3 网络结构

基于MAML的FMFI方法的网络结构主干是一个简单的5层的卷积神经网络(Convolutional Neural Network, CNN), 其中前4层结构基本一致, 均由卷积模块、批归一化模块、非线性变换模块、池化模块4种基础模块构成。FMFI的输入为 28×28 的3通道RGB时频图像, 每层结构卷积模块Conv的卷积核大小为(3, 3), 池化模块选择最大池化(Max-pool), 核大小为(2, 2); 非线性变换模块采用ReLU (Rectified Linear Unit)函数。经过4层网络之后, 利用全连接层实现特征和标签空间之间的映射, 之后通过softmax得到最终的分类结果。由于网络层数较浅, 网络的模型参数较少, 因此收敛性能较好。FMFI主干网络的参数设计如表1所示。

表1 FMFI主干网络的参数

Table 1 The parameters of FMFI backbone

No.	Layer Name	Kernel Size	Stride	Padding
1	Conv I	(3, 3)	1	1
2	Max-pool I	(2, 2)	2	0
3	Conv II	(3, 3)	1	1
4	Max-pool II	(2, 2)	2	0
5	Conv III	(3, 3)	1	1
6	Max-pool III	(2, 2)	2	0
7	Conv IV	(3, 3)	1	1
8	Max-pool IV	(2, 2)	2	0

3.4 训练策略

在FMFI中, 定义 ϕ 为模型参数, f_ϕ 为函数表示。FMFI旨在根据已知工况多种轴承状态类型的样本学习先验知识、优化模型参数 ϕ , 实现在未知的复杂工况下准确快速的故障分类。在元训练阶段,

FMFI分别基于每个训练任务的支撑集和查询集进行内外循环优化, 从而更新模型参数 ϕ 。在元测试阶段, FMFI利用更新后的模型参数 ϕ' , 辨识未知工况的故障。

FMFI在元训练阶段的内循环中, 会利用每个任务更新任务模型参数, 逐步优化模型。在处理任务 \mathcal{T}_i 时, 首先根据任务的支撑集 $\mathbf{D}_{\mathcal{T}_i}^s$, 采用梯度下降的方式计算当前任务模型参数下的损失函数 \mathcal{L}_i 关于参数的梯度, 进而更新任务模型参数。损失函数 \mathcal{L}_i 采用了交叉熵的计算方法, 具体公式如下:

$$\begin{aligned} \mathcal{L}_i(\mathbf{D}_{\mathcal{T}_i}^s, \theta_i^0) = & - \sum_{(\mathbf{x}, \mathbf{y}) \in \mathbf{D}_{\mathcal{T}_i}^s} \left\{ \mathbf{y} \lg f_{\theta_i^0}(\mathbf{x}) + (1 - \mathbf{y}) \lg [1 - f_{\theta_i^0}(\mathbf{x})] \right\}, \end{aligned} \quad (5)$$

其中 θ_i^0 表示任务 \mathcal{T}_i 的初始化任务模型参数, \mathbf{x} 表示属于任务 \mathcal{T}_i 中的支撑集 $\mathbf{D}_{\mathcal{T}_i}^s$ 的所有数据样本, $f_{\theta_i^0}(\mathbf{x})$ 表示对应样本输入 \mathbf{x} 的预测标签值, \mathbf{y} 表示对应样本输入 \mathbf{x} 的真实标签值。利用交叉熵方式计算损失函数可以评估模型对输入样本的预测能力, 使模型的预测结果能够更好地逼近真实标签值。

假设内循环中, 每个任务的梯度会更新 m 步($m > 0$), 则任务 \mathcal{T}_i 经过 m 步的更新之后, 其任务模型参数的更新公式如下:

$$\theta_i^m = \theta_i^{m-1} - \alpha \nabla_{\theta_i^{m-1}} \mathcal{L}_i(\mathbf{D}_{\mathcal{T}_i}^s, \theta_i^{m-1}), \quad (6)$$

其中 θ_i^m 表示任务 \mathcal{T}_i 在第 m 步的任务参数更新结果; θ_i^{m-1} 表示任务 \mathcal{T}_i 在第 m 步时的初始化任务模型参数, 同时也是在第 $m-1$ 步的任务参数更新结果; α 表示学习率, 用以控制每个任务参数更新的步长; $\nabla_{\theta_i^{m-1}} \mathcal{L}_i(\mathbf{D}_{\mathcal{T}_i}^s, \theta_i^{m-1})$ 表示在当前任务参数 θ_i^{m-1} 下, 对于任务 \mathcal{T}_i 使用支撑集 $\mathbf{D}_{\mathcal{T}_i}^s$ 计算损失函数 \mathcal{L}_i 相对于任务参数 θ_i^{m-1} 的梯度。

通过将损失求和, 将(6)式进行改写, 得到模型在任务 \mathcal{T}_i 经历了 m 步的梯度更新后的最终的任务模型参数 θ_i^m 的另一种形式:

$$\theta_i^m = \theta_i^0 - \sum_{j=0}^{m-1} \alpha \nabla_{\theta_i^j} \mathcal{L}_i(\mathbf{D}_{\mathcal{T}_i}^s, \theta_i^j). \quad (7)$$

待任务参数更新完后, 基于任务 \mathcal{T}_i 的查询集 $\mathbf{D}_{\mathcal{T}_i}^q$ 进行FMFI在任务 \mathcal{T}_i 的损失计算, 结合(7)式得到的经历 m 步的梯度更新后的最终任务参数 θ_i^m , 损失计算方法如下:

$$\begin{aligned}\mathcal{L}_{\text{FMFI}_i}(\mathbf{D}_{\mathcal{T}_i}^q, \theta_i^m) = \\ \mathcal{L}_{\text{FMFI}_i} \left[\mathbf{D}_{\mathcal{T}_i}^q, \theta_i^0 - \sum_{j=0}^{m-1} \alpha \nabla_{\theta_i^j} \mathcal{L}_i(\mathbf{D}_{\mathcal{T}_i}^s, \theta_i^j) \right].\end{aligned}\quad (8)$$

FMFI在元训练阶段构建 n 个任务, 待对所有任务进行内循环后, 可以得到 n 个任务模型参数 θ_k^m , $k = 1, 2, \dots, n$. FMFI在元训练阶段的外循环中, 会基于每个任务对应的查询集 $\mathbf{D}_{\mathcal{T}_k}^q$ 和对应的更新后任务模型参数 θ_k^m , 求取总损失函数, 从而更新FMFI的模型参数 ϕ , 得到更新结果 ϕ' . 更新方式可表示为:

$$\begin{aligned}\phi' = \phi - \beta \nabla_{\phi} \mathcal{L}_{\text{FMFI}}(\phi) \\ = \phi - \beta \nabla_{\phi} \sum_{k=1}^n \mathcal{L}_{\text{FMFI}_k}(\mathbf{D}_{\mathcal{T}_k}^q, \theta_k^m, \phi),\end{aligned}\quad (9)$$

其中 β 代表元学习率, 用于控制模型参数的更新步长.

FMFI在元测试阶段对未知工况的轴承故障进行辨识时, 将利用训练阶段得到优化模型参数作为测试阶段初始参数 ϕ , 随机抽取数据组成多个测试任务. 利用每个测试任务中的支撑集微调模型, 查询集测试模型性能. FMFI的目标是最小化模型在所有测试任务查询集的元损失函数 $\mathcal{L}_{\text{FMFI}}$, 元损失函数 $\mathcal{L}_{\text{FMFI}}$ 的计算公式如下:

$$\mathcal{L}_{\text{FMFI}}(\mathbf{D}_{\mathcal{T}}^q, \phi) = \frac{1}{|\mathbf{D}_{\mathcal{T}}^q|} \sum_{l=1}^{|\mathbf{D}_{\mathcal{T}}^q|} \mathcal{L}_{\text{FMFI}_l}(\mathbf{D}_{\mathcal{T}_l}^q, \theta_l^m),\quad (10)$$

其中 $\mathbf{D}_{\mathcal{T}}^q$ 表示测试任务的查询集, $|\mathbf{D}_{\mathcal{T}}^q|$ 表示测试任务的数量, $\mathcal{L}_{\text{FMFI}_l}(\mathbf{D}_{\mathcal{T}_l}^q, \theta_l^m)$ 表示在第 l 个任务中, 内循环更新完成得到任务的模型参数 θ_l^m 后, 利用该任务的查询集 $\mathbf{D}_{\mathcal{T}_l}^q$ 计算的任务损失函数 $\mathcal{L}_{\text{FMFI}_l}$. 最后将所有任务的损失函数进行平均作为元损失函数 $\mathcal{L}_{\text{FMFI}}(\mathbf{D}_{\mathcal{T}}^q, \phi)$, 从而避免极端情况.

4 实验与分析

4.1 数据集介绍

大口径射电望远镜在运行时, 方位和俯仰会不断变化, 并且望远镜会时刻受环境因素和自身重力影响, 因此俯仰轴承承受的载荷也是变化的. 基于此, 本研究选择了工况具有相似性的变负载轴承识别数据集进行实验, 分析本文算法的效果.

目前, 凯斯西储大学(Case Western Reserve University, CWRU)的轴承故障数据库是轴承故障识别中常用的数据集, 广泛应用于故障识别领域, 常被作为评估故障分类性能的基准数据集^[17]. CWRU数据集测量不同负载下的轴承振动信号, 实验工况接近射电望远镜俯仰轴承的运行状况, 均为变负载特性. CWRU数据实验装置示意图如图3所示, 主要由左侧的电机和轴承块、中间的扭矩传感器、右侧的负载和测力计以及图中未显示出的电子控制设备组成.

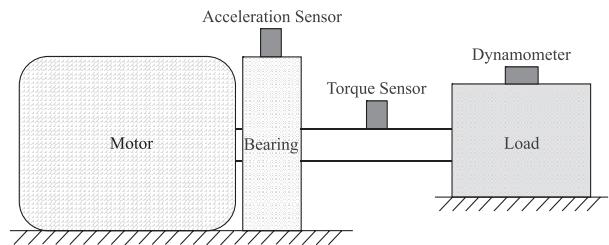


图3 凯斯西储大学轴承故障试验台示意图

Fig. 3 Diagram of the CWRU bearing fault testbed

CWRU数据集有0、1、2、3马力(hp)共4种不同的轴承负载(Load)工况, 可以分别对应射电望远镜运行时轴承所承受的不同载荷. CWRU数据集通过在轴承的外圈、内圈以及轴承滚珠部分进行故障加工, 模拟轴承的磨损等失效表现, 并根据磨损程度的不同, 设置了不同的故障程度. 通过固定在轴承块顶部的加速度传感器采样测试数据, 信号的采样率设置为12 kHz. 在4种不同负载工况下, 分别对正常和损伤的轴承块进行测试, 在每种负载下均包含3种内圈故障状态、3种外圈故障状态、3种滚动体故障状态以及1种正常状态, 共10种轴承状态类型.

4.2 任务设置

在射电望远镜实际运行过程中, 天线工况总是不断变化。为了使模型能够应对天线不同的工作状况, 需对模型在变化工况下的通用性进行实验验证。根据本文提出的FMFI的任务构建方法, 基于相似的变工况下的CWRU数据集构建实验任务。经调研相关研究, 不同工况下的故障数据存在一定的特征差异^[18], 因此可以使用不同工况下的数据集, 构建元学习任务集, 组织元训练和元测试过程。这有利于FMFI学习更多通用的故障知识, 从而实现未知工况下的故障辨识。

为验证FMFI方法在辨识未知工况下的故障性能表现, 依照元学习任务组织方式, 将数据按照负载工况划分为T0-T3共4种任务。每种工况均包括10种轴承状态类型。FMFI在已知工况下进行元学习, 在未知工况下进行故障辨识测试。详细的任务设置见表2所示。例如任务T0是指模型在负载

为0所对应的数据集上训练, 并在负载为1所对应的数据集上验证以推广模型性能, 最后在负载为3所对应的数据集上测试。

表2 基于CWRU轴承数据集的故障辨识场景
Table 2 Fault identification scenarios on CWRU datasets

Task	Training Set	Validation Set	Testing Set
T0	Load 0	Load 1	Load 3
T1	Load 0	Load 1	Load 2
T2	Load 0	Load 3	Load 1
T3	Load 3	Load 1	Load 0

原始的一维故障时域信号通过CWT方法变为时频图像, 每种状态类别包含115张时频图像, 如图4分别给出了内圈故障、外圈故障和滚动体故障的时频图像。

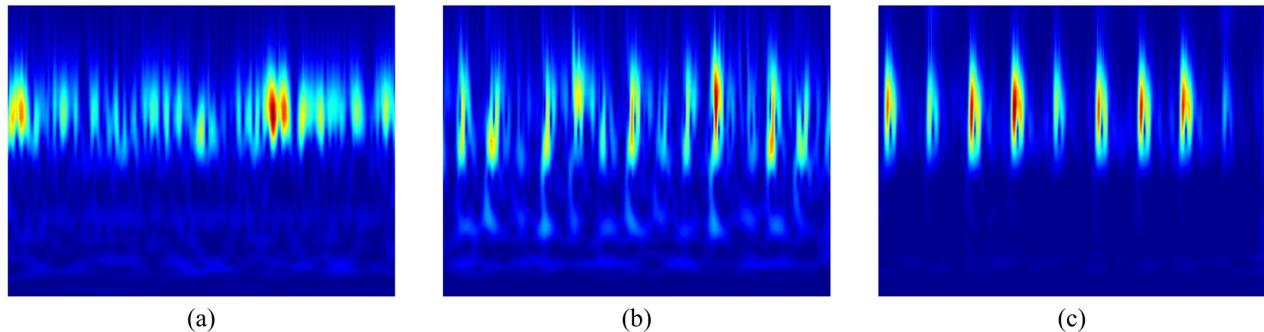


图4 3种不同故障类型的时频图像. (a)内圈故障, (b)外圈故障, (c)滚动体故障.

Fig. 4 Time-frequency images of three different types of faults. (a) Inner ring fault, (b) Outer ring fault, (c) Rolling body fault.

根据FMFI方法的元学习训练方式, 按照5-way 1-shot (或5-shot)的方式从每种工况的时频图中抽取数据, 并将其组合为任务进行训练。每个任务包含5类故障形式, 每一类故障形式的支撑集数目为1 (对应1-shot)或者5 (对应5-shot)。FMFI的学习率 α 、元学习率 β 以及元训练的迭代次数分别设置为0.04、0.0002、300。模型在训练阶段, 每10个epoch采用验证集微调模型, 使模型能够在训练集和验证集上都有较好的效果; 在测试阶段, 选择

1000个测试任务的平均精度作为本次最终测试精度, 从而避免极端结果。对比的基线方法选择CNN, 训练过程的迭代次数同为300, 基于10种故障的所有时频图进行训练、验证以及测试, FMFI与CNN的网络模型结构均参照表1设置。

4.3 结果分析

FMFI依照表2所示的场景任务进行训练测试, 在每个任务下, FMFI在一个工况下进行训练, 并在

新的工况下分别进行验证和测试.

首先对FMFI的支撑集数目(shot)进行测试, 探究支撑集数目对结果的影响. 在任务T0下, 设置5-

way K -shot中 K 分别取1和5. 观察FMFI在元训练过程和元验证过程中准确度和损失的变化. 实验结果如图5所示.

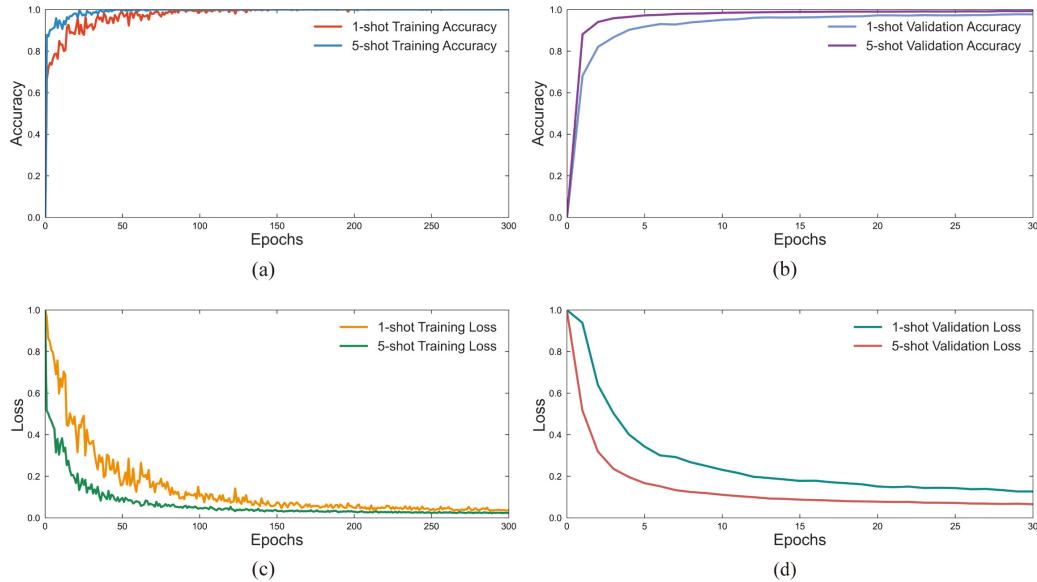


图5 FMFI在任务T0上的元训练和元验证过程. (a)元训练过程的精度曲线, (b)元验证过程的精度曲线, (c)元训练过程的损失曲线, (d)元验证过程的损失曲线.

Fig. 5 The meta-training and meta-validation process of FMFI under the Task T0. (a) Meta-training accuracy curves, (b) Meta-validation accuracy curves, (c) Meta-training loss curves, (d) Meta-validation loss curves.

由图5可以发现, 无论在训练过程还是在验证过程中, 支撑集数目的改变并不会影响准确率和损失的变化趋势, 但支撑集数目的增加能够显著缩短模型达到最终收敛的时间. 在图中可以明显发现, 相比于1-shot在5-shot情况下, 模型的收敛速度更快, 起始准确率上升、起始损失下降, 可以在更短时间内获得准确度更高的模型. 这是由于支撑集数目的增加可以使模型在每次学习时获取更多的信息, 帮助模型实现快速准确的故障辨识.

在分析FMFI的支撑集数目对训练和验证过程以及结果的影响后, 本文进一步探讨多任务下, 支撑集数目对于测试结果的影响, 并以CNN方法作为基线对比方法, 检验元学习框架的有效性.

在模型测试时, 为降低实验偶然性, 减小随机误差, 重复执行FMFI方法与CNN方法10次, 选取平均值作为测试的最终精度. 测试结果如表3和图6

所示.

根据表3和图6所示的不同方法在4种任务下的结果对比, 可以发现在4组变工况的任务下, FMFI方法的性能都较好, 且性能稳定, 平均精度可达到95%以上. 而CNN方法的精度会随着任务的变化而波动, 平均精度在90%以下. 特别是在T3任务中, FMFI的准确率达到98.8%, 比作为基线的CNN方法提高了26.13%.

传统的机器学习方法主要针对特定任务训练, 需要较多的样本, 获取的轴承辨识知识有限, 不足以对未知新工况下的故障进行分类. 表3和图6表明, 基于元学习的FMFI方法相较于CNN方法, 在面临不同分布的数据时, 能够学习到更多的通用故障特征, 具有更强的泛化性能, 能够在新工况下实现准确分类, 完成跨工况的故障辨识. 基础的CNN方法由于参数更新设置简单, 在面临训练数据域与测试

数据域的来源不同时, 提取的特征有限, 难以将从训练数据得到的知识进行推广, 辨识未知工况的故障时效果欠佳.

此外, 根据表3和图6还可以发现, 相对于任务

T1和T2, 两种方法在任务T0和T3上的精度略有逊色, 这或许是因为相对于任务T1和T2, 任务T0和T3训练集和测试集的负载差异较大, 导致根据训练集所学到的知识在测试集下无法发挥全部作用.

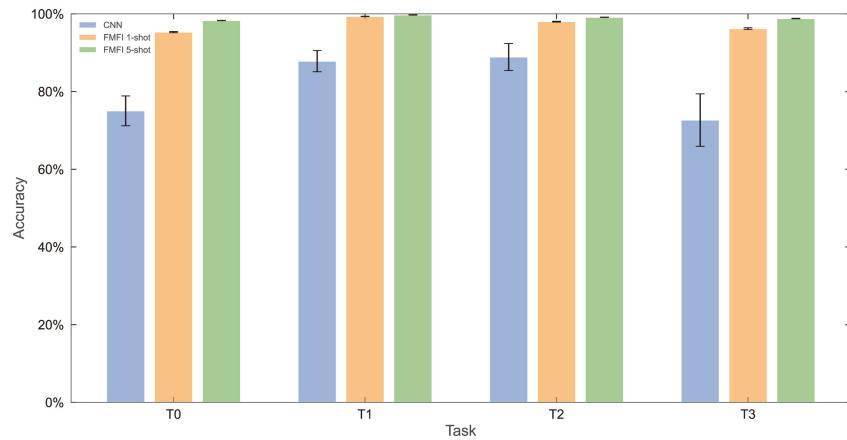


图 6 不同方法在不同任务下的比较结果(FMFI方法稳定性较高, 误差较小, 图中不明显).

Fig. 6 The compared results of different methods under variable tasks (FMFI method is more stable, has fewer errors and the error is not as obvious in the graph).

表 3 不同方法在不同任务下的测试精度
Table 3 Test accuracy of different methods under variable tasks

Method \ Task	T0	T1	T2	T3
Method				
CNN	75.03% ± 3.84%	87.83% ± 2.74%	88.89% ± 3.47%	72.67% ± 6.76%
FMFI 1-shot	95.32% ± 0.16%	99.35% ± 0.05%	98.01% ± 0.10%	96.22% ± 0.21%
FMFI 5-shot	98.30% ± 0.04%	99.74% ± 0.03%	99.14% ± 0.04%	98.80% ± 0.06%

5 结语

本文提出了基于元学习的大口径射电望远镜俯仰轴承的故障辨识方法FMFI, 实现了复杂未知工况下利用少数样本进行准确、快速的故障辨识. 根据望远镜运行时工况不断变化的特性, 选择了类似工况的CWRU数据集进行实验, 设计了4个模拟俯仰轴承复杂工况的实验任务, 并使用CNN方法作为基线对比. 对比结果表明, FMFI方法凭借其自学习能力, 得到的模型泛化性能较为优异, 在多个任

务上的辨识性能高于基线方法, 在复杂工况下具有很高的辨识准确性和可靠性. 本文的工作可为大口径射电望远镜俯仰轴承的故障辨识提供一种可行的参考方法, 同时也可为俯仰轴承的动态运维以及高性能服役提供重要支撑.

致谢 感谢审稿人对文章提出的宝贵建议, 使得文章的质量有了显著的提高. 感谢CWRU数据库的协助. 感谢实验室提供的实验条件.

参 考 文 献

- [1] 王娜, 许谦. 天文学进展, 2016, 34: 63
- [2] 江永琛, 王锦清, 荀伟, 等. 天文学报, 2019, 60: 95
- [3] 梅庚君, 项斌斌, 王娜, 等. 天文学报, 2020, 61: 62
- [4] Mei G J, Xiang B B, Wang N, et al. ChA&A, 2021, 45: 236
- [5] 黄龙. 大型望远镜指向精度及轴系技术研究. 北京: 中国科学院大学, 2016: 87-106
- [6] Han L, Zhang J, Yang F. Journal of Vibration and Shock, 2017, 36: 263
- [7] 谭玉凤. 地基大口径望远镜结构设计及主镜热控研究. 北京: 中国科学院大学, 2018: 31-37
- [8] Rayo R S M. Analysis of the Load Distribution of the Dome Weight on the Rotation Mechanisms of the Very Large Telescope Located at the Paranal Observatory, and Development of a Condition Monitoring Method. Concepción: University of Concepción, 2020: 25-39
- [9] Nguyen V C, Hoang D T, Tran X T, et al. Machines, 2021, 9: 345
- [10] Chen X, Zhang B, Gao D. Journal of Intelligent Manufacturing, 2021, 32: 971
- [11] Zuo L, Xu F, Zhang C, et al. Reliability Engineering & System Safety, 2022, 225: 108561
- [12] Ren Z, Zhu Y, Yan K, et al. Mechanical Systems and Signal Processing, 2020, 138: 106608
- [13] Finn C, Abbeel P, Levine S. Proceedings of the 34th International Conference on Machine Learning. Sydney: PMLR, 2017, 1: 1126
- [14] Vilalta R, Drissi Y. Artificial Intelligence Review, 2022, 18: 77
- [15] Chen Z, Wang Y, Wu J, et al. Applied Intelligence, 2021, 51: 5598
- [16] Sun Q, Liu Y, Chen Z, et al. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44: 1443
- [17] Loparo, K A. Case Western Reserve University Bearing Data Center. Cleveland: Case Western Reserve University, 2012: 22-28
- [18] Gu Y, Zeng L, Qiu G. Measurement, 2020, 156: 107616

Research on Fault Identification Method of Elevation Bearing for Large Aperture Radio Telescope Based on Meta Learning

ZHU Jin-hao^{1,2} XU Qian^{1,3,4} XUE Fei^{1,2} HE Fei-long^{1,2} LIANG Juan^{1,2} XU Duo-xiang^{1,2}

(1 Xinjiang Astronomical Observatory, Chinese Academy of Sciences, Urumqi 830011)

(2 University of Chinese Academy of Sciences, Beijing 100049)

(3 Key Laboratory of Radio Astronomy, Chinese Academy of Sciences, Urumqi 830011)

(4 Xinjiang Key Laboratory of Radio Astrophysics, Urumqi 830011)

ABSTRACT The prolonged operation of the large aperture radio telescope will lead to slight distortion of elevation axis, increasing the risk of fatigue of the rolling bearing which is the core component of the elevation axis. This can lead to a decline in the bearing life and the pointing accuracy of the telescope, which will greatly affect the telescope's high performance service. Investigating the fault identification method for the elevation bearing can provide an important support for the high-performance operation of the telescope antenna. In this paper, a few-shot meta-learning fault identification (FMFI) method based on meta-learning is proposed in order to achieve accurate fault identification of elevation bearing under limited data and complex working conditions. The raw signals of different working conditions are first converted to time-frequency images data and then randomly sampled for different learning tasks according to the meta-learning protocol. Under limited sample data condition, the FMFI method can obtain universal prior knowledge from the sample in the training task to achieve accurate and fast fault identification in unknown testing tasks. The variable load bearing data set which is similar to the working condition of telescope elevation bearing is selected for experiment, and the experimental results show that the FMFI method is high accurate and reliable, providing strong technical support for the operation, maintenance, and high-quality service of large aperture radio telescope.

Key words telescope, instrumentation: elevation bearing, methods: data analysis, methods: pattern recognition