**文章编号:** 1005-6734(2023)06-0611-09

doi.10.13695/j.cnki.12-1222/o3.2023.06.011

## 基于 Noise2Noise 的静电悬浮惯性传感器噪声抑制方法

徐鹏<sup>1,4,5</sup>,杨智岚<sup>1,2,3,4</sup>

(1. 国科大杭州高等研究院,基础物理与数学科学学院,杭州 310024;

2. 中国科学院国家空间科学中心,北京 100190;

3. 中国科学院大学,北京 100049;

4. 中国科学院力学研究所,引力波实验中心,北京 100190;

5. 兰州大学, 兰州理论物理中心, 兰州 730000)

**摘要:**针对星载静电悬浮惯性传感器噪声复杂,在轨测量数据真值未知,传统方法难以有效抑制的问题,提出了基于无监督学习的 Noise2Noise 框架,结合集成学习方案,设计了基于 Noise2Noise 无监督 学习的广谱随机噪声抑制方法,并基于 GRACE-FO 加速度计数据进行了实验验证。实验结果表明所 提方法相较于传统噪声抑制方法的噪声均方误差下降 8%以上,使用集成学习后,噪声水平进一步下 降至 12%以上。此外,所提方法在有效抑制高频噪声的同时,能够识别出高频数据中的特征性信号, 可为惯性传感器载荷在轨运行状态评估提供信息保障。

**关 键 词:**惯性传感器;加速度计;数据处理;Noise2Noise;深度学习 **中图分类号:**U666.1 **文献标志码:**A

# Noise suppression method of electrostatic suspension inertial sensor based on Noise2Noise

XU Peng<sup>1,4,5</sup>, YANG Zhilan<sup>1,2,3,4</sup>

(1. Hangzhou Institute for Advanced Study, UCAS, School of Fundamental Physics and Mathematical Science, Hangzhou 310024, China;

2. National Space Science Center, Chinese Academy of Sciences, Beijing 100190, China;

3. University of Chinese Academy of Sciences, Beijing 100049, China;

4. Institute of Mechanics, Chinese Academy of Sciences, Center for Gravitational Wave Experiment, Beijing

100190, China;

5. Lanzhou University, Lanzhou Center for Theoretical Physics, Lanzhou 730000, China)

Abstract: In view of the noise of onboard electrostatic suspension inertial sensors is complex and difficult to be effectively suppressed by traditional methods when the true value of in-orbit measurement data is unknown, a Noise2Noise framework based on unsupervised learning is proposed. Combined with an integrated learning scheme, a broad spectrum random noise suppression method based on unsupervised learning framework of Noise2Noise is designed, which is verified by experiments based on GRACE-FO accelerometer data. The experimental results show that compared with traditional noise suppression methods, the mean square error of noise of the proposed method is reduced by more than 8%, and the noise level is further reduced by more than 12% after using integrated learning. In addition, the proposed method can effectively suppress the high-frequency noise and identify the characteristic signals in high-frequency data, which can provide information guarantee for the on-orbit operation status evaluation of inertial sensor

收稿日期: 2023-02-14; 修回日期: 2023-05-20

基金项目: 国家重点研发计划"引力波探测"重点专项课题(2020YFC2200601, 2021YFC2201901)。

作者简介:徐鹏(1979—),男,研究员,博士生导师,从事引力波探测,实验引力,数据处理方向的研究。

通讯作者:杨智岚(1997—),男,硕士研究生,从事惯性传感器数据预处理。

#### payloads.

Key words: inertial sensor; accelerometer; data processing; Noise2Noise; deep learning

星载惯性传感器可以作为航天器在空间中的惯性 运动的参考基准,在涉及空间精密测量、测绘、高精 度导航、无拖曳控制、自主轨道维持等测量技术和需 求的空间卫星任务中有着重要的应用。在全球重力场 探测与反演,以及空间引力波探测天线等涉及(相对 论性或者非相对论性)引力场测量的空间任务中,高 精度惯性传感器更是其关键科学载荷。

目前基于静电伺服控制技术的高精度静电悬浮惯 性传感器仍然是在轨运行精度和可靠性最高星载惯性 基 准 技 术 方 案 。 分 辨 率 在  $10^{-12}$  m/s<sup>2</sup>/Hz<sup>1/2</sup>~ $10^{-10}$  m/s<sup>2</sup>/Hz<sup>1/2</sup>水平高精度静电悬浮惯 性传感器已经成功服务于一系列重力卫星任务如重力 恢复与气候实验任务(Gravity Recovery And Climate Experiment, GRACE)<sup>[1]</sup>、重力恢复与气候实验延续计 划(GRACE Follow-on, GRACE FO)<sup>[2]</sup>、重力场与稳 态洋流探测器(Gravity Field and steady-state Ocean Circulation Explorer, GOCE)<sup>[3]</sup>。经由激光干涉空间天 线(Laser Interferometer Space Antenna, LISA) PathFinder 卫星验证<sup>[4]</sup>,  $10^{-15}$  m/s<sup>2</sup>/Hz<sup>1/2</sup>水平超高精度 静电悬浮惯性传感器在未来将成为空间引力波探测天 线如 LISA<sup>[4]</sup>、Taiji<sup>[5]</sup>、以及 Tianqin<sup>[6]</sup>计划的核心载荷。

由于其极高的灵敏度, 星载静电悬浮惯性传感器 受到轨道空间环境和卫星平台环境包括温度梯度波 动、磁场、电场波动、微振动、高能粒子束充电等多 物理场复杂环境耦合干扰,以及读出噪声和驱动电压 不稳定性等测控噪声影响,其测量数据中的干扰和噪 声成份极为复杂(详见1.3小节的分析),通过硬件层 面的改进提升探测灵敏度则具有较高的挑战性。因此, 借助于噪声建模、扣除、数据平滑、趋势拟合等传统 处理手段,以及智能计算等先进处理方法,有效剥离 信号与干扰噪声,对噪声进行抑制并提高探测信噪比, 是实现惯性传感器探测灵敏度的进一步提升,以及测 量数据准确高效地科学应用的关键技术。

过去几十年里,人们在信号处理领域提出了许多 噪声抑制算法,其中包括基于卡尔曼滤波、小波变换 和傅里叶变换等方法。在 GRACE-FO 的加速度计信号 数据预处理中,采用了 35 mHz 的低通滤波器处理高 频噪声,残存的由于推进器工作而产生的线性加速度 ("推进器尖峰")需要进一步的校正<sup>[7]</sup>; Ioana-Raluca E 等人<sup>[8]</sup>采用了基于小波滤波器方法处理惯性传感器信 号噪声,基于评估和更新小波最优分解水平的准则来 减少噪声分量; Rio I 等人<sup>[9]</sup>利用卡尔曼滤波对加速度 计和陀螺仪进行噪声抑制处理,通过调整过程噪声方差矩阵 *Q* 和测量方差矩阵 *R* 的权重来获得最佳噪声抑制效果。

随着深度学习的发展,在机器视觉和自然语言处 理等领域都取得了显著的成果。在信号处理方面,深 度学习方法成功应用于惯性传感器相关任务,能够准 确实现人体的动作识别<sup>[10]</sup>、车辆的惯性导航<sup>[11]</sup>和消除 误差等。Hua C 等人<sup>[12]</sup>使用有监督学习和卷积神经网 络(Convolutional Neural Network, CNN)来消除传感 器中的误差,与传统方法相比能够消除不同级别的惯 性传感器的大部分错误。Changhui J 等人<sup>[13]</sup>将递归神 经网络(Recurrent Neural Network, RNN)和长短时间 记忆网络(Long Short Term Memory, LSTM)相结合, 将惯性传感器的输出作为时间序列信号进行处理,从 而提高了精度。李荣冰等人<sup>[14]</sup>使用 LSTM 来构建 MEMS-IMU 的误差模型,对加速度和角速度的补偿效 果更好。

然而,目前大多数基于深度学习实现信号噪声抑 制的方法都采用了由纯净信号和噪声信号组成的数据 对,并需要噪声分布的先验知识。从结果来看,虽然 这些方法取得了一定的噪声抑制效果。然而上述方法 的应用也存在局限性。首先,获取无噪声的纯净信号 非常困难,有时甚至不可能,比如对于星载惯性传感 器传回地面的数据,只能获得含有噪声的实测信号, 如果采用人工处理后的数据作为目标信号,会导致深 度学习方法的噪声抑制上限无法超过人工处理的噪声 抑制效果。此外,有监督学习方法涉及到信号噪声的 先验知识,而实际噪声分布可能与假设的噪声分布不 一致。

对于有监督学习方法的限制,JaakkoL等人<sup>[15]</sup>提 出了 Noise2Noise 噪声抑制框架,首先应用于图像处 理领域,该方法不需要使用无噪声图像作为训练样本 就能够实现噪声抑制网络模型的训练,最终结果表明 深度学习神经网络能够在不需要无噪声目标信号的前 提下,实现信号的噪声抑制处理。为了解决 Noise2Noise方法中需要多个噪声样本的限制,Tao H 等人<sup>[16]</sup>基于 Noise2Noise 方法提出了 Neighbor2Neighbor方法,设计了一种随机邻居子采样 器,通过对单一噪声图像样本采样得到训练图像对, 最终实验结果表明深度学习方法能够处理单信号样本 去嗓的问题,并取得了比现有方法更高的有效性和优 越性。除了图像领域,很多人把 Noise2Noise 方法应 用于时间序列的信号处理中,Takayuki T 等人<sup>[17]</sup>将 Noise2Noise 方法应用于多级窄纳米通道获得的电流 波形信号,这种信号具有高噪声和测量原理复杂的特 点,最终噪声抑制效果优于常见的信号处理方式,能 够更加精确地保留信号细节。

Noise2Noise 方法在图像的噪声抑制上具有普遍 性, 能有效抑制不同种类的图像噪声。基于 Noise2Noise方法在图像处理领域的成功经验,本文首 次将其应用于惯性传感器信号处理,同时,为了解决 Noise2Noise 方法中对一对独立噪声样本的依赖性问 题,采用用单一样本进行噪声抑制。本文设计子采样 器,对噪声序列进行采样生成子样本,子样本能够近 似满足 Noise2Noise 方法的要求。在高强度噪声的影 响下,使用多步长集成学习和单一样本采样能够提高 Noise2Noise 的噪声抑制效果,提高最终信号的信噪 比。

### 1 静电悬浮惯性传感器

### 1.1 概述

本文数据处理是以可获得的 GRACE-FO 惯性传 感器(或加速度计)Level-1 A/B 级数据为例。 GRACE-FO 惯性传感器测试质量及其外部测控电极 分布如图1所示。



图 1 惯性传感器测试质量与测控电极分布示意图 Fig.1 Layout of the core mechanical assembly of the inertial sensor

测试质量安装于电极笼内部的标称(nominal)几 何中心位置。测试质量与电极笼构成的敏感结构处于 温度梯度波动,磁场涨落高度稳定的真空环境中。在 运行过程中,由于航天器受到空间环境非引力干扰作 用的影响,其飞行轨道偏离引力场中自由下落的惯性 运动轨迹,因此产生了卫星平台或者与其固联的电极 笼与测试质量之间的相对运动。这一相对运动(相对 位移改变)在某一测量轴的投影,引起该测量轴向测 试质量两侧表面与对应电极的电容变化,并由差分电 容检测电路精密测量,给出测试质量相对标称平衡位 置位移的数据。该数据输入给控制单元,对测试质量 与电极笼的相对位置进行实时控制,使得测试质量位 于标称平衡位置附近。

## 1.2 工作原理

实际运行中,星载静电悬浮惯性传感器依据具体 设计方案或者运行需求,可工作于加速度计模式或者 无拖曳控制模式。在加速度计模式中,反馈控制力通 过改变控制电极上电压施加在测试质量上,将测试质 量推回至标称平衡位置。而在无拖曳模式下,反馈控 制则由卫星平台微推进器施加在卫星上,使得卫星跟 随测试质量飞行,维持测试质量悬浮在平衡位置附近。 在空间引力波探测试验卫星如 LISA PathFinder<sup>[4]</sup>以及 Taiji-1<sup>[5]</sup>等任务中,惯性传感器根据需求可以在上述两 种模式切换。在目前重力卫星任务,如 GRACE, GRACE-FO 等,惯性传感器则工作在加速度计模式。 以加速度计测量模式为例,在外部干扰与静电控制力 的共同作用下,测试质量相对于电极笼的运动,在 GRACE-FO 惯性传感器在加速度计模式下正常运行 期间,其测试质量的控制精度极高,偏离标称平衡位 置优于 10<sup>2</sup> pm/Hz<sup>1/2</sup> 水平,残余相对加速度可以忽略 不计。最终航天器所受到的非引力扰动(大气拖曳、 太阳光压、地球返照等)可以写为:

$$a_{para,SC}^{i}(t) = -k_{1}^{i\alpha}V_{\alpha}(t) - G^{ij}(t)d_{i} - a_{para,TM}^{i}(t) - b^{i} \quad (1)$$

其中  $a_{TM}^{i}(t)$  和  $a_{sc}^{i}(t)$  分别代表测试质量和航天器相对 惯性参考系的加速度,下角标 para 代表寄生干扰加速 度,  $b^{i}$  为加速度偏值,  $k^{ia}$  为线性加速度标度因数,  $d_{j}$ 为测试质量质心与航天器质心偏差。 $V_{a}(t)$  为实际测 量读出各电极上的控制电压,  $G^{ij}(t)$  代表引力梯度矩 阵和航天器角动量矩阵等综合项。在质心偏差经过校 正,工作参数经过准确定标后,控制加速度可以作为 航天器收到非引力扰动的精确测量。而式(1)中测试质 量受到的寄生加速度扰动水平则是制约测量精度的关 键因素。

本文所使用的 GRACE-FO 在轨实测数据中, Level-1 A 级数据产品为经过标度因数转换的高采样 控制加速度数据, Level-1 B 级数据产品则是经过粗差 校正,数据平滑和降采样等处理的数据产品。

#### 1.3 噪声分析

星载静电惯性传感器在实际运行过程中,由于其 极高的灵敏度,以及测试质量与其周围环境多物理场 的复杂耦合关系,(1)式中测试质量感受到的寄生扰动 加速度 *a<sup>i</sup><sub>para,TM</sub>*(*t*)的成分极为复杂。其主要包括,对测 试质量的测控引起的加速度扰动,包括位移检测噪声 及其引起的控制误差,控制电压不稳定性引起的加速 度噪声;测试质量相对平衡位置位移抖动与寄生刚度 (主要为静电刚度和自引力刚度)耦合产生的加速度 噪声等。

对于上述提到的绝大部分噪声,无法通过结合平 台环境相关数据进行建模来实现精确扣除。实际上绝 大部分噪声在测量频段的幅度谱密度体现为广谱的有 色噪声。因此,从数据分析角度,通过对噪声的学习, 实现对不可建模的广谱随机噪声的有效抑制,以及探 测信噪比的进一步提升,将对高精度星载静电悬浮惯 性传感器的应用具有重要的实际意义。

## 2 多步长集成 Noise2Noise 算法

## 2.1 算法总体架构

本文提出的加速度计信号噪声抑制的算法框架如 图 2 所示,由训练网络和噪声抑制网络两部分组成。 首先选择需要处理的加速度计数据,通过设计好的采 样器能够得到子序列作为训练集,分别作为模型的输 人数据和目标数据。当网络模型训练好之后,再将需 要噪声抑制的加速度计信号输入到模型中,此时模型 的输出就是噪声抑制后的信号。



图 2 算法总体框架图 Fig.2 The overall framework of the algorithm

### 2.2 Noise2Noise 方法

基于上一章的讨论,为方便起见,将工作于加速 度计模式的在轨实测数据时间序列写成如下形式:

$$y_i = x_i + z_i \tag{2}$$

其中,  $x_i$  代表真实的航天器受到的非引力扰动加速度 计信号  $a_{para,SC}$ ,  $z_i$  为测试质量受到的加速度噪声  $a_{para,TM}$ ,  $y_i$  则代表实际测量得到的控制加速度计信号  $a_c$ , i 为数据标签 (i=1,2,3...k)。

在使用深度学习方法处理噪声中,通过数据来训 练神经网络模型,得到 $y_i$ 和 $x_i$ 之间的关系。将含有噪 声的信号 $y_i$ 输入网络模型,就能得到噪声抑制后的信 号。在有监督的深度学习架构下,需要一对理想的纯 净信号 $x_i$ 和噪声信号 $x_i + z_i$ 来训练网络模型的参数, 也被称作 Noise2Clean (N2C)方法,具体的噪声抑制 模型依据如式 (3):

$$\arg\min\sum_{i=1}^{k} ||f_{\theta}(x_{i}+z_{i})-x_{i}||^{2}$$
(3)

其中  $f_{\theta}$ 表示以 $\theta$ 为参数的神经网络模型, k 为训练集 样本数量。与 N2C 相对应的 Noise2Noise(N2N)是一种 无监督学习方法,区别在于 N2N 方法不需要理想纯净 的信号作为输入,只需要基于  $x_i$  的两个独立的含有噪 声的实际测量值  $x_i + z_{i1}$ 和  $x_i + z_{i2}$ ,具体的噪声抑制模 型依据如式 (4):

$$\arg\min\sum_{i=1}^{k} \|f_{\theta}(x_{i}+z_{i1})-(x_{i}+z_{i2})\|^{2}$$
(4)

当满足以下两个条件时,式(3)和式(4)之间是可以互相转换的,也就是说 N2N 的噪声抑制效果能够接近 N2C 的噪声抑制效果。

**条件 1**:输入样本的噪声信号和标签样本的噪声信号 之间是不相关的关系;

条件 2: 输入样本和目标样本的噪声的期望为零。

基于条件 1 和条件 2, 经过公式具体的展开推导 后,可以发现式(3)能够获得与式(4)相同的形式,因此 网络模型能够学习到从含噪声信号到纯净信号的映 射,而不是含不同噪声的信号数据之间的映射关系。 在实际应用中,两个条件并不需要严格满足,对于图 像中的泊松噪声和语音信号中的混合噪声等其他类型 的噪声,N2N 同样有较好的噪声抑制效果。以一对含 噪声样本 (y<sub>1</sub>, y<sub>2</sub>) 为例,为了避免样本不足的问题,可 以将样本 y<sub>1</sub>和 y<sub>2</sub>分别作为输入和目标,生成两对含噪 声样本 (y<sub>1</sub>, y<sub>2</sub>) 和 (y<sub>2</sub>, y<sub>1</sub>),此时求解噪声抑制模型的 形式如式 (5):

$$\arg\min\sum_{i=1}^{\kappa} \left\{ \frac{1}{2} \| f_{\theta}(x_{i} + z_{i1}) - (x_{i} + z_{i2}) \|^{2} + \frac{1}{2} \| f_{\theta}(x_{i} + z_{i2}) - (x_{i} + z_{i1}) \|^{2} \right\}$$
(5)

为了实现单噪声样本的噪声抑制,本文设计子采 样器对含噪声序列采样生成子样本对,通过奇偶采样 方法,将时间序列分为奇序列和偶序列,以奇序列作 为模型的输入数据集,偶序列作为模型的标签数据集。 基于这些数据来训练网络,最终可以得到如下公式:

$$f_{\theta}(x_{odd} + z_{odd}) \longrightarrow x_{even} + z_{even} \tag{6}$$

$$f_{\theta}(x_{odd} + z_{odd}) \longrightarrow x_{odd} + z_{even} + (x_{even} - x_{odd})$$
(7)

其中( $x_{odd} + z_{odd}$ )代表着从含噪声序列采样得到的奇序 列样本, $x_{odd}$ 为奇序列中真实的加速度计信号, $z_{odd}$ 为 噪声信号,同理可知( $x_{even} + z_{even}$ )为偶序列样本,基于 奇偶样本,能够训练得到参数为 $\theta$ 的网络模型  $f_{\theta}$ 。和 传统的 N2N 相比,多了括号内的信号真值在相邻奇偶 采样之间的残差。针对于加速度计信号,可以认为其 信号真值在高采样率的相邻采样之间的变化非常微 小,即认为(x<sub>even</sub> - x<sub>odd</sub>) <<1,此时符合使用 N2N 方法的条件,基于同一真值和不同噪声来训练网络模型。同样,为了扩充训练样本的数量,可以将奇序列样本作为目标样本或输入样本,增加一倍的样本数量。

## 2.3 网络模型结构

在 N2N 的文献<sup>[15]</sup>中原始模型使用了 U-net 模型, U-net 模型最初应用于图像分割并取得了良好的性能, 也经常应用于图像的噪声抑制。如图 3 所示,U-net 由三部分组成:编码器、解码器和跳跃连接。U-net 的输入端为 4800 维,代表时间序列中 4800 个采样点, 进入编码器,编码器每层由一维卷积层、Dropout 层<sup>[18]</sup> 和池化层生成特征层,再进入解码器,解码器由反褶 积层、和上采样层组成,跳跃连接将解码器和编码器 维度相同的部分拼接起来,这些连接通道让神经网络 能够学习到训练数据的深层特征和浅层特征。最终得 到与输入相同维的输出,实现信号的噪声抑制,由于 跳跃连接的存在,U-net 模型类似于重建噪声,再去除, 得到最终噪声抑制后的信号。



考虑到一维信号和二维信号的差异以及不同重建 信号的方式,本文同时尝试了卷积自编码器 (Convolutional Auto-Encoder, CAE)模型来直接重建 纯净信号本身,如图4所示, CAE 模型与 U-net 类似, 同样存在编码器和解码器,不同之处在于,不使用跳 跃连接层,只使用编码器和解码器。在池化层中往往 会损失一部分信号,为了实现更好的重建效果,使用 步长为2和4的卷积层替代池化层实现降维和升维。 激活函数选择 ReLU 函数和 Tanh 函数,Tanh 函数应 用在最终的输出层,ReLU 函数应用在除输出层外的 隐含层,Tanh 函数将输出范围限制在(-1,1),ReLU 函数在引入非线性的同时,计算更加快捷,同时使用 Dropout 层避免过拟合。

#### 2.4 多步长集成学习

在上文提到了可以使用奇偶采样的方式,使用惯 性传感器读出数据生成含噪声信号的子样本。本文对 这种采样方式进行扩展,使用不同的采样方法。以奇 偶采样为例,在第 n 次采样中分别得到了原序列 2n-1 和 2n 处的数据, 可以认为采样点周围一段间隔内, 真 值的差异都很小可以忽略,因此使用 2n-1 和 2n-1+d 处的数据进行网络模型的训练。间隔越小真值之间的 差距可能更小,本文只选择 d 为 1。还可以对惯性传 感器读出的奇偶子序列进行采样,选择不同的采样间 隔,比如1,2,3。当为1时就等于不对奇序列进一 步采样,当大于1时,先对奇序列采样生成子样本, 当完成模型训练后再将噪声抑制后的子样本插值回原 来的位置,得到噪声抑制后的惯性传感器读出数据。 这种方式是一种集成学习的思想,在使用不同的采样 间隔训练网络模型时,尽管网络模型是相同的,但是 数据的分布是不同的。惯性传感器的输出信号是一段 时间序列,本文利用了时间序列信号与图像信号中的 不同之处,每一张图片是一个整体,不同的图片之间 不存在关联。在时间序列信号中由于信号的连续性和 周期性,前后数据可能都存在一定的关联,因此选择 不同的步长能够让网络模型学习到不同的特征和噪声 信息,能够在集成学习后获得更好的效果。本文可以 对不同采样间隔重建后的信号取均值得到最终噪声抑 制后的信号,还可以进一步调整权重,由于采样间隔 增大的同时可能会造成噪声抑制的效果的下降,因此 对采样间隔小的部分施加更大的权重,随着采样间隔 的增加,权重降为之前的0.5。两种集成方法的公式如 (8)和式(9):

$$x = (x_1 + x_2 + \dots + x_m) / m$$
 (8)

$$x = x_1 \times 2^{-1} + x_2 \times 2^{-2} + \dots + x_m \times 2^{-(m-1)}$$
(9)

其中, m 代表 m 种采样方式, x<sub>m</sub> 为第 m 种采样方式 重建得到的加速度计信号, x 代表基于不同方法平均 得到的信号, 也是最终的噪声抑制后的信号。

## 2.5 与不同噪声处理方法的比较

为了对比仿真数据上的噪声抑制效果,而不是真 实加速度计处理流程,本文同时采用了基于傅里叶变 换、小波变换<sup>[19]</sup>、径向基函数(Radial Basis Function, RBF)和卡尔曼滤波<sup>[9]</sup>等传统噪声抑制方式作为参考。 小波变换可以应用在小波分解去噪中,选择合适的小 波对噪声信号进行小波变换分解,每次分解信号被分 为高频部分和低频近似部分,其中低频近似部分可以 进一步进行分解,采用阈值去噪方法处理高频部分存 在的噪声。对于小波基函数的选择,尝试了 Symlets、 Coiflets、Daubechies 和 Haar Biorthogonal 等多种函数, 同时使用网格搜索的方式来找到最佳的小波基函数和 阈值组合,使得滤波后的信号与真实信号的均方误差 最小。卡尔曼滤波分为预测过程和测量过程,不断地 迭代来获得更准确的状态估计,最终能够有效地处理 噪声,根据相关文献卡尔曼滤波中的过程方差矩阵 (*O*)和测量方差矩阵(*R*)卡尔曼滤波器中能够影响 最终的噪声抑制效果,分别尝试了 O=R, O>R, O<R 三 种情况。与小波变换中使用的搜索方法类似,对0和 R的取值进行网格搜索使均方误差最小,其中Q和R的取值变换都是以10倍为基准。傅里叶变换考虑在频 域对信号进行处理,使用巴特沃斯低通滤波器,容许 低于截止频率的信号通过,对于超过截止频率的高频 信号阻隔或减弱。采用行搜索的方法来确定最好的截 止频率,使得噪声抑制后信号的均方误差(MSE)取 值最小。在无监督的 RBF 方法中,将信号表示 RBF 的线性组合,通过最小化 RBF 重构误差来实现信号降 噪,存在两个超参数: RBF 中心数量和高斯核宽度 gamma,同样使用网格搜索的方式确定参数。

#### 3 实验验证

为了验证本文提出的基于 Noise2Noise 的多步长 集成算法的有效性,本文使用 GRACE-FO 卫星发布的 实测加速度计数据,包含 Level-1A 和 Level-1B 级别 的加速度计数据产品。首先以 Level-1B 数据为基准, 在其上叠加模拟噪声进行仿真数值实验,将 N2N 算法 与传统信号处理方法进行对比。基于噪声抑制算法的 评价指标,与一些常见的信号处理方法进行比较,验 证本文提出算法的潜在优势。然后,使用 N2N 方法处 理 Level-1A 数据得到产品数据,结果表明,使用本文 的处理方法在实现高频噪声有效抑制的同时,能够有 效地保留高频频段的特征性信号。

#### 3.1 数据集和训练过程

GRACE-FO 卫星用于高精度的探测地球静态和 时变的重力场,如前所述,其核心载荷加速度计测量 数据包含卫星在轨所受非引力扰动的信息。选择日期 2022年3月的 Level-1B 级别加速度计数据产品为例。 首先将数据幅值变换到(-1,1)取值区间作为真值样本, 同时制作方差为0.04的高斯白噪声并叠加彩色噪声作 为噪声样本。对于真值样本,本文只用来评价噪声抑 制算法,在训练过程中则只使用含噪声样本。基于奇 偶子采样器,将数据分为82组,每组存在一对含噪声 样本,含噪声样本中包含4800个采样点。其中80组 作为训练集,训练N2N方法中网络模型的参数,同时 可以用来对滤波器的超参数进行行搜索和网格搜索。 后两组作为测试集,用来比对N2N方法和常见处理方 法。

为了进一步验证 N2N 方法在处理真实世界中复杂噪声的表现,本文还选择了数据集中的 Level-1A 加速度计数据产品,采样频率为 10Hz。选择其中 5 天的数据进行实验,经过粗差校正等操作,最后同样需要先对数据幅值变换到(-1,1)取值区间。通过分析数据,可以发现信号中存在较大的高频噪声,同时还存在明显的冲激干扰信号。基于加速度计数据生成了 80 组样本对,每组样本的序列长度同样为 4800,用来验证 N2N 方法对噪声和干扰的处理效果。

具体的训练细节如下:为了训练网络模型,采用 均方误差 MSE 作为损失函数。在网络训练过程中, 采用了学习率为 0.0001 的 Adam 优化器<sup>[20]</sup>,训练批量 大小选择为 16。模型训练批次也十分重要,当训练批 次过大时,比如 100 次,能够发现训练中模型损失函 数的值达到很低的水平,但最终的噪声抑制效果却变 差了。这种现象可以理解为过拟合效应,模型中的损 失函数代表输入噪声信号和标签噪声信号之间差距的 度量,并不是越低越好的。当批次过大时模型学习到 的是从一种噪声分布映射到另一种噪声分布,而失去 了噪声抑制的效果,因此使用早停机制,选择训练批 次为 25,降低了过拟合效应,模型具备噪声抑制能力。

## 3.2 评价指标

对于仿真生成的加速度计信号数据集,可以使用 均方误差 MSE 来评估算法的性能,具体的计算公式 为:

$$MSE = \frac{1}{k} \sum_{i=1}^{k} (x - f(y))^2$$
(10)

其中, y 为输入的含噪声信号, f(y) 为网络模型的输 出值, k 为样本数量, x 为纯净信号。对于无法确定真 值的实测数据集,可通过分析信号的时间序列图和 ASD 谱图来分析算法的噪声抑制效果。

## 3.3 实验结果

(1) 基于 Level-1 B 数据的仿真比对试验

在仿真实验中,信号受到混合噪声影响,本文使 用了深度学习方法和常见的信号处理方法。经过网络 搜索和行搜索,最优的小波基函数和阈值组合选择 Daubechies和0.8,卡尔曼滤波中*Q*=1,*R*=100。RBF 中心数量为350,gamma为1.7。此外,还与有监督方 法N2C相比较,N2C方法中模型参数大部分与N2N 相同,不同处在于不必使用早停机制,训练批次为 100。每种方法最终的噪声抑制结果如表1所示。

	表 1	不同方法的评价指标
Tab.1	The evaluation	ation metrics for different methods







能够发现 N2N 方法对含噪信号的重建效果更好, 最终的 MSE 值要低于其他方法所得到的结果。图 5 是仿真生成的含噪声信号和目标信号(纯净信号), 图 6 是使用 N2N 方法噪声抑制后的信号。传统常用方

法在处理信号细微变化时表现不好,往往会直接拟合为 光滑的曲线,而使用深度学习方法能够在保证噪声抑制 效果的同时也保留了加速度计信号的细节和结构。同时 在实际选择小波分解阈值和波形函数与选择卡尔曼滤 波 *Q、R* 等超参数,不能够使用网格搜索等方法,很难 取得最优的噪声抑制效果。与 U-net 模型相比,使用 CAE 模型能够得到的更加平滑的信号。

对于 N2N 方法,本文还对比了使用基于步长集成 方法的效果,在实验中发现将不同步长得到的噪声抑 制数据合并后,会引入一定程度的高频噪声,考虑采 用低通滤波器进一步处理,结果如表 2 所示。

表 2	多步长集成 N2N 方法和 N2N 方法的对比			
Tab.2	Comparison of the multi-step ensemble N2			
	method and the N2N method			

方法	σ=0.08	<i>σ</i> =0.10	<i>σ</i> =0.12
N2N	9.48×10 <sup>-18</sup>	1.25×10 <sup>-17</sup>	1.72×10 <sup>-17</sup>
多步长 N2N	9.10×10 <sup>-18</sup>	1.13×10 <sup>-17</sup>	1.48×10 <sup>-17</sup>
多步长+低通	8.34×10 <sup>-18</sup>	1.02×10 <sup>-17</sup>	1.32×10 <sup>-17</sup>
N2C	8.76×10 <sup>-18</sup>	1.26×10 <sup>-17</sup>	1.55×10 <sup>-17</sup>

可以看出,在噪声强度较大时,使用集成学习的 N2N 方法要优于直接使用 N2N 方法。如果和低通滤 波器共同使用,能够进一步获得更好的噪声抑制效果, 甚至能够超过 N2C 方法。表 2 中代表了在不同的噪声 强度下使用基于步长集成方法的效果,最终的 MSE 是 有提升的,但看起来会额外保留一些噪声信息。这个情 况可以这样解决,当噪声强度较小时,不必要使用集成 方法,单独使用 N2N 就能够很好地处理噪声。当噪声 强度较大时,再考虑使用基于步长的集成学习方法,同 时可以考虑和滤波器结合使用。

#### (2) 基于 Level-1 A 数据的实测数据实验

对于实测的加速度计信号,本文从时域和频域来分 析噪声抑制效果,信号的时序图如图 7 所示,ASD 图 如图 8-图 10 所示。





图 8



噪声抑制后的 ASD 图 (CAE)



图 10 不同日期的 ASD 图 (CAE) Fig.10 ASD of different day acceleration (CAE) 从时序图中可以发现, N2N 方法对于冲激干扰和 高频系统噪声都有着不错的处理效果。其中,冲激干 扰的数据特性并不完全满足 N2N 中噪声均值为 0 的要 求,但最终也去除了冲激干扰的影响(推进器事件以 外)。观察 ASD 谱图,其中蓝线为含有真实噪声的加 速度计信号,黄线为使用 N2N 方法处理后的加速度计 信号,在频率大于 10 mHz 部分的信号, N2N 起到了较 为明显的噪声抑制效果。但与低通滤波器等方法的处理 结果存在不同,当使用基于低通滤波的传统处理方法 时,会将高频数据完全滤除,其中包含了高频噪声和可 能存在的高频真实信号。

N2N 方法对于高频部分并不是完全滤除,还保留 了一部分高频数据,可以在 ASD 中看到一些峰值信号, 这部分信号可能是特征性信号而不是单纯的噪声,所以 保留这部分高频信号,对于分析惯性传感器/加速度计 的工作状态具有积极的意义。同时,由图 8-10 可以发 现,通过对比使用 U-net 模型和 CAE 模型, CAE 模型 有着很好的噪声抑制效果。同时,能够更全面地保留高 频峰值信号。



Fig.11 Residual between N2N method and Level-1B

最后,将处理后的加速度计数据与 Level-1B 进行 比较,如图 11 所示,通过对残差进行分析,在每一个 N2N 噪声抑制后的样本中,序列的中间数据段部分残 差较小,在起始段和终段两部分残差较大。这是由于卷 积神经网络的特性,可以考虑只采取中间部分的信号, 在不同的训练样本之间可以进行重叠,例如第一个样本 区间为[0,4800],下一个样本为[2400,7200],这样就避 免了边缘信息的损失,而中间段的残差在 10<sup>-10</sup>数量级。

## 4 结论

针对惯性传感器噪声复杂,传统方法难以有效抑制,以及在轨测量真值未知的特点,本文研究设计了一种基于 N2N 无监督学习的广谱随机噪声抑制的方法,通过设计采样器,解决 N2N 中对多样本的需求,同时采取集成学习思想进一步提高噪声抑制效果。以GRRACE-FO 实测数据为例,开展了仿真数据实验和真实数据实验。进行比对分析,得到了相对于传统信号处理方法更好的结果。在 MSE 指标下,N2N 方法取得 8%以上的提升;使用集成方法进一步取得 12%以上的提升。这一结果初步论证了 N2N 方法应用于高精度惯传数据分析与处理的可行性。最后针对

GRACE-FO 数据,对比标准的数据平滑处理方法,验 证了深度学习能够在高效抑制高频噪声的同时,识别 并保留高频频段的特征性信号。这一信号对于惯性传 感器数据分析具有实际意义,后续将针对这一信号, 同时结合 Taiji-1 任务数据分析类似信号, 开展相关研 究。由于 N2N 方法基于数据驱动而实现噪声抑制, 可

以探索 N2N 方法在精密测量领域应用潜力。

#### 参考文献(References)

- TAPLEY B D, REIGBER C. The GRACE mission: status and future plans[C]//EGS General Assembly Conference Abstracts. 2002. [1]
- KORNFELD R P, ARNOLD B W, GROSS M A, et al. [2] GRACE-FO: the gravity recovery and climate experiment follow-on mission[J]. Journal of spacecraft and rockets, 2019, 56(3): 931-951.
- BROCKMANN J M, SCHUBERT T, SCHUH W. An [3] improved model of the Earth's static gravity field solely derived from reprocessed GOCE data[J]. Surveys in Geophysics, 2021, 42: 277-316. ARMANO M, AUDLEY H, AUGER G, et al. The LISA
- [4]
- athfinder mission[C]//Journal of Physics: Conference Series. USA, May 18-24, 2014. 罗子人,张敏, 靳刚,等. 中国空间引力波探测"太极 计划"及"太极1号"在轨测试[J]. 深空探测学报, 2020, 7(01): 3-10. [5] Luo Z, Zhang M, Jin G, et al. Introduction of Chinese space-borne gravitational wave detection program "Taiji" and "Taiji-1" satellite mission[J]. Journal of Deep Space
- Exploration, 2020, 7(01): 3-10.[6] Mei J, Bai Y, Bao J, et al. The TianQin project: current progress on science and technology[J]. Progress of Theoretical and Experimental Physics, 2021, (5): 5A-107A
- BANDIKOVA T, MCCULLOUGH C, KRUIZINGA G L, et al. GRACE accelerometer data transplant[J]. [7]
- Advances in Space Research, 2019, 64(3): 623-644. EDU I, ADOCHIEI F, NEGREA P, et al. New tuning method of the wavelet function for inertial sensors signals [8] denoising[J]. Conferintele EUROPMENT, 2014: 153-157. CSCC14. org si
- [9] ALFIAN R I, MA'ARIF A, SUNARDI S. Noise reduction in the accelerometer and gyroscope sensor with the Kalman filter algorithm[J]. Universitas Muhammadiyah Yogyakarta, 2021(3): 180-189. [10] 路永乐,修蔚然,孙旗,等. 基于多头自注意力机制和
- (上接第600页)
- 赵夫群,马玉,戴翀.基于改进随机抽样一致的点云分 [9] 割算法[J]. 科学技术与工程, 2021, 21(22): 9455-9460. Zhao F, Ma Y, Dai C. Point cloud segmentation algorithm based on improved random sampling consistency[J]. Science and Technology and Engineering, 2021, 21(22): 9455-9460.
- [10] Yuan H, Sun W, Xiang T. Line laser point cloud segmentation based on the combination of RANSAC and growing[C]//2020 39th Chinese Control region Conference (CCC). Shenyang, China, July 27-29, 2020: 6324-6328.
- [11] Wang Z, Wang X, Fang B, et al. Vehicle detection based point cloud intensity and distance on clustering[C]//Journal of Physics: Conference Series. IOP Publishing, 2021, 1748(4): 042-053.
- [12] 蔡怀宇,陈延真,卓励然,等. 基于优化 DBSCAN 算 法的激光雷达障碍物检测[J]. 光电工程, 2019, 46(07): 83-90 Cai H, Chen Y, Zhuo L, et al. Laser radar obstacle detection based on optimized DBSCAN algorithm[J]. Optoelectronic Engineering, 2019, 46(07): 83-90.

[13] Geiger A, Lenz P, Stiller C, et al. Vision meets robotics: The kitti dataset[J]. The International Journal of Robotics Research, 2013, 32(11): 1231-1237.

Bi-GRU的人体动作识别算法[J]. 中国惯性技术学报, 2023, 31(01): 1-6. Lu Y, Xiu W, Sun Q, et al. Human activity recognition algorithm based on multi-head-self-attention mechanism and Bi-GRU[J]. Journal of Chinese Inertial Technology,

- 2023, 31(01): 1-6. 黄凤荣,羿博珩,王旭,等.基于深度学习与运动状态 识别的车辆惯性导航方法[J].中国惯性技术学报, [11] Huang F, Yi B, Wang X, et al. Human activity recognition algorithm based on multi-head-self-attention
- Tecoginton agortum based on nutri-nead-seri-attention mechanism and Bi-GRU[J]. Journal of Chinese Inertial Technology, 2022, 30(05): 569-575.
  [12] Hua C, AGGARWAL P, TAHA T M, et al. Improving inertial sensor by reducing errors using deep learning methodology[C]//NAECON 2018-IEEE National Actional Actional Conference on the sensor by the sensor be sensor by the sensor be sensor by the sensor by the sensor be sensor by the sensor by the sensor by the sensor by the sensor be sensor by the sensor be sensor by the sensor by the sensor by the sensor be sensor by the sensor be sensor by the sensor by the sensor by the sensor by the sensor be sensor by the sensor by the sensor be sensor by the se Aerospace and Electronics Conference. USA, July 23-26, 2018.
- [13] Jiang C, Chen S, Chen Y, et al. A MEMS IMU de-noising method using long short term memory recurrent neural networks (LSTM-RNN)[J]. Sensors,
- 2018, 18(10): 3470. [14] 李荣冰,鄢俊胜,刘刚,等. 基于LSTM深度神经网络的MEMS-IMU误差模型及标定方法[J]. 中国惯性技术 学报, 2020, 28(02): 165-171. Li R, Yan J, Liu G, et al. MEMS-IMU error model and calibration method based on LSTM deep neural network[J]. Journal of Chinese Inertial Technology, 2020, 28(02): 165-171
- [15] LEHTINEN J, MUNKBERG J, HASSELGREN J, et al. Noise2Noise: Learning image restoration without clean data[J]. arXiv preprint arXiv:1803.04189, 2018.
- [16] Huang T, Li S, Jia X, et al. Neighbor2neighbor: Self-supervised denoising from single noisy Self-supervised denoising from single noisy images[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2021.
- TAKAAI T, TSUTSUI M. Unsupervised noise reduction [17] for nanochannel measurement using Noise2Noise deep learning[C]//Trends and applications in knowledge discovery and data mining: PAKDD 2021 workshops, WSPA, MLMEIN, SDPRA, DARAI, and AI4EPT, Delhi. India, May 11, 2021. [18] LABACH A, SALEHINEJAD H, VALAEE S. Survey of
- dropout methods for deep neural networks[J]. arXiv preprint arXiv:1904.13310, 2019.
- [19] KUMAR A, TOMAR H, MEHLA V K, et al. Stationary wavelet transform based ECG signal denoising method[J]. ISA transactions, 2021,114: 251-262.
- [20] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. arXiv preprint arXiv:1412.6980, 2014.
- [14] 马新江, 刘如飞, 蔡永宁, 等. 一种基于路缘特征的点 云道路边界提取方法[J]. 遥感信息, 2019, 34(02): 80-85 Ma X, Liu R, Cai Y, et al. A point cloud road boundary

extraction method based on curb features[J]. Remote Sensing Information, 2019, 34(02): 80-85.

- [15] Lu B, Wang Q, Li A. Massive point cloud space management method based on octree-like encoding[J]. Arabian Journal for Science and Engineering, 2019, 44(11): 9397-9411.
- [16] Deng D. DBSCAN clustering algorithm based on density[C]//2020 7th International Forum on Electrical Engineering and Automation (IFEEA). Hefei, China, September 25-27, 2020: 949-953.
- [17] Behley J, Garbade M, Milioto A, et al. Semantickitti: A dataset for semantic scene understanding of lidar sequences[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019: 9297-9307.
- [18] Wang Z, Yu B, Chen J, et al. Research on lidar point cloud segmentation and collision detection algorithm[C]//2019 6th International Conference on Information Science and Control Engineering (ICISCE). Shanghai, China, December 20-22, 2019: 475-479.