

组合体航天器角速度信号深度学习降噪方法*

初未萌^{1,2} 邬树楠^{1,2†} 刘宇飞³ 吴志刚^{1,2}

(1.大连理工大学 航空航天学院,大连 116024) (2.大连理工大学 工业装备结构分析国家重点实验室,大连 116024)

(3.中国空间技术研究院 钱学森空间技术实验室,北京 100094)

摘要 服务航天器与非合作目标构成组合体航天器后,实际测量的角速度信号往往掺杂了较大噪声,这会严重影响后续控制的精度,但由于非合作目标惯性张量未知,导致无法根据模型信息对其有效降噪.针对上述问题,本文基于深度学习提出一种无需预先构建模型、完全由数据驱动的组合体航天器角速度信号降噪方法.首先给出采用深度学习对方速度进行降噪所需训练数据的生成过程;然后构建组合体航天器角速度信号降噪的深度网络模型,并提出该模型的优化方法和参数初始化方法;最后用测试数据对本文方法和小波降噪方法的降噪效果进行了比较,结果表明本文方法与小波降噪方法相比具有更好的降噪性能.

关键词 深度学习, 组合体航天器, 非合作目标, 信号降噪

DOI: 10.6052/1672-6553-2019-013

引言

随着航天任务的不断拓展,失效航天器与太空垃圾等非合作目标日益增多,面向非合作目标的在轨服务技术逐渐得到了国内外研究人员的广泛关注.在对非合作目标进行在轨维修与清理的过程中,服务航天器需要对非合作目标进行捕获与对接从而构成组合体航天器,并由服务航天器控制整个组合体航天器的运行.由于非合作目标的影响,组合体航天器的惯性张量与服务航天器相比发生了很大变化^[1],导致服务航天器无法有效控制组合体航天器的姿态,目前常用的解决方法是通过服务航天器上安装的敏感器对组合体航天器的姿态信息进行测量,结合上述测量值对组合体航天器惯性张量进行辨识^[2,3]并实现姿态控制^[4];或采用自适应方法设计控制器,使其可以在模型参数不确定的情况下对航天器进行姿态控制^[5,6].然而在实际测量过程中,由于捕获对接导致组合体航天器的结构振动以及空间摄动等因素的影响,测量值往往掺杂了较大、较复杂的测量噪声,这些噪声直接导致航天器辨识与控制精度明显下降,严重影响航天器的系统稳定性,因此需要对实际测量值进行有效的降噪

处理.

Kalman 滤波是目前航天领域主要应用的一种信号滤波方法,它基于最小均方误差准则实现对系统状态的最优估计^[7].Kalman 滤波方法被广泛应用于航天器的状态估计,Agrawal 等^[8]根据星敏感器提供的姿态更新量,利用 Kalman 滤波方法对多体航天器的角速度进行实时估计;Crassidis 等^[9]基于修正 Rodrigues 参数描述航天器姿态,采用扩展 Kalman 滤波估计航天器的姿态;吴云华^[10]基于类 GPS 的相对测量,设计了扩展 Kalman 滤波器与无味 Kalman 滤波器估计编队卫星的相对位置、速度和姿态;曾占魁等^[11]针对具有单目视觉和惯性组件的航天器相对导航问题,提出了基于量测修正的多速率 Kalman 算法实现了对航天器相对姿态角、速度以及位置的估计;何骁等^[12]采用扩展 Kalman 滤波方法实现了对航天器姿态角、角速度以及挠性附件振动模态的估计,并将估计量用于转动惯量参数的辨识;但使用 Kalman 滤波方法需要知道精确的系统模型,而由于非合作目标惯性张量未知,导致无法建立组合体航天器的精确系统模型,因此这一方法并不适用.

基于小波变换的降噪方法已经成功地应用于

2018-04-02 收到第1稿,2018-10-14 收到修改稿.

* 国家自然科学基金资助项目(11502040),大连市高层次人才创新支持计划项目(2017RQ001)

† 通讯作者 E-mail: wushunan@dlut.edu.cn

航天领域中的信号降噪方面,董云峰等^[13]利用小波对机械能合成信号进行多尺度分析,识别隐藏在噪声信号中的机械能变化以判定空间目标是否存在轨道机动;王博等^[14]采用改进了计算结构的平移不变量小波降噪方法对GPS载波相位二次差分观测信号进行降噪,以得到精确的姿态角;但是小波降噪方法的降噪效果对内部参数的选取很敏感,需要预先对待降噪信号的类型以及噪声分布比较了解。

近年来,深度学习在图像^[15,16]与语音^[17]等领域获得了巨大成功。深度学习采用由多个数据处理层组成的计算模型学习并获得多层次的数据抽象特征表达,其模型结构可理解为深层神经网络,它可以通过误差反向传播算法不断改变模型参数,使得模型每一个数据处理层得到比前一层更高、更抽象的数据特征表达形式,从而发现数据内部的复杂结构关系,并利用得到的结构关系完成特定的任务^[18,19]。在航天领域,它成功应用于对卫星故障的预测^[20,21],但在其他方向的应用仍有待拓展。如信号降噪方向,目前深度学习主要应用于对语音信号的降噪,以实现将语音信号从噪声干扰中分离出来的目的,传统建模方法当输入的语音或噪声信号与模型不匹配时分离性能会严重下降^[22],而采用深度学习方法可以在语音模型与噪声统计特性不确定的情况下,通过监督学习方式自动提取训练数据中的声学特征进行建模,并使用训练好的模型实现非平稳噪声与低信噪比条件下的语音分离^[23];同样,对组合体航天器角速度信号进行降噪也需要面对动力学模型和测量噪声统计特性未知的问题,而基于深度学习这种无需预先构建模型、完全由数据驱动的降噪方法与其他降噪方法相比具有明显的优势。

根据以上分析,本文基于深度学习提出了一种面向非合作目标的组合体航天器角速度信号降噪方法,以提高在非合作目标惯性张量未知、无法构建组合体航天器系统精确模型情况下角速度信号的估计精度。本文结构如下:第1节,详细说明了采用深度学习方法对角速度进行降噪所需训练数据的生成过程;第2节,介绍了如何构建用于组合体航天器角速度信号降噪的深度神经网络模型;第3节,在给定的仿真条件下,采用测试数据校验训练完成后深度神经网络模型的降噪效果。

1 训练数据生成

根据深度学习方法构建深度神经网络模型以达成特定的学习任务,需要大量数据对其进行训练,这些数据称为训练数据,它们的集合即为训练集,其中每一个训练数据都是由一个输入数据和一个与之对应的标签数据组成,而且输入数据与标签数据的维度确定了深度神经网络模型的输入输出维度。同样,构建用于空间组合体角速度信号降噪的深度神经网络模型也需要大量的训练数据,本节将对训练数据的生成过程进行详细说明,主要内容为:首先建立组合体航天器姿态动力学模型,并通过该模型计算获得不同惯性张量下的角速度仿真数据,最后根据这些角速度仿真数据生成足量的训练数据。

1.1 组合体航天器姿态动力学模型

服务航天器在对非合作目标行对接后形成一个组合体航天器,如图1所示,服务航天器本体坐标系 $O_{Ser}-XYZ$ 位于服务航天器的质心, X_{Ser} 轴指向飞行速度方向, Z_{Ser} 轴指向地心, Y_{Ser} 轴通过右手定则确定;设定形成的组合体航天器为刚体,为方便分析,构建组合体航天器的本体坐标系 $O_{Com}-XYZ$ 与 $O_{Ser}-XYZ$ 一致。其中服务航天器上装载了用于测量角速度的传感器。

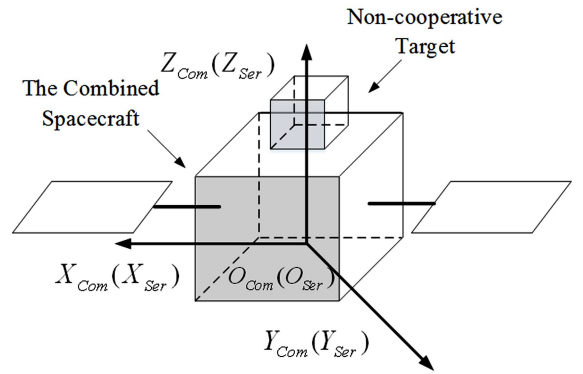


图1 组合体航天器

Fig.1 The combined spacecraft

服务航天器惯性张量 J_{Ser} 为已知常量,假设在形成组合体航天器后其惯性张量 J_{Com} 也为常量,得到组合体航天器的惯性张量 J_{Com} 为:

$$J_{Com} = \begin{bmatrix} I_x + \Delta_x & -I_{xy} + \Delta_{xy} & -I_{xz} + \Delta_{xz} \\ -I_{xy} + \Delta_{xy} & I_y + \Delta_y & -I_{yz} + \Delta_{yz} \\ -I_{xz} + \Delta_{xz} & -I_{yz} + \Delta_{yz} & I_z + \Delta_z \end{bmatrix} \quad (1)$$

式(1)中 $\Delta_x, \Delta_y, \Delta_z$ 为非合作目标与服务航天器组

合后所产生的转动惯量变化量, $\Delta_{xy}, \Delta_{yz}, \Delta_{xz}$ 为惯量积变化量, 由于非合作目标的惯性张量未知, 故式(1)中 $\Delta_x, \Delta_y, \Delta_z, \Delta_{xy}, \Delta_{yz}, \Delta_{xz}$ 为未知参数。

结合上述 J_{Com} 提出组合体航天器的姿态动力学模型:

$$J_{Com} \cdot \dot{\omega} + \omega \times J_{Com} \cdot \omega = \tau \quad (2)$$

式(2)中的 ω 为组合体航天器的角速度, τ 为作用于组合体航天器上的控制力矩, 且 ω 与 τ 在坐标系 $O_{Com} - XYZ$ 下分别包含三个自由度 $\omega = [\omega_x, \omega_y, \omega_z]^T$ 和 $\tau = [\tau_x, \tau_y, \tau_z]^T$ 。

1.2 基于姿态动力学模型的训练数据生成

在构建组合体航天器姿态动力学模型后, 接下来基于该模型计算不同惯性张量下的组合体航天器角速度仿真数据。

组合体航天器角速度的仿真数据包含目标角速度数据与实际角速度数据两部分, 目标角速度数据是通过已知 J_{Com} 构建组合体航天器姿态动力学模型计算得到的精确角速度数据, 而实际角速度数据是包含随机噪声的, 在此, 通过在上述目标角速度数据基础上加入随机噪声, 生成以模拟由传感器实测的具有较大测量噪声的角速度数据。首先生成目标角速度数据, 因 $\Delta_x, \Delta_y, \Delta_z, \Delta_{xy}, \Delta_{yz}, \Delta_{xz}$ 未知, 故在一定范围内随机生成 N 组不同的 $\Delta_x, \Delta_y, \Delta_z, \Delta_{xy}, \Delta_{yz}, \Delta_{xz}$ 组合, 并计算相应的组合体航天器惯性张量 J_{Com} , 然后根据式(2)对不同的 J_{Com} 输入相同的控制力矩 τ_c , 解算出一段时长 L 固定的精确角速度序列 $\omega(k)_{p,1:L} = [\omega(k)_{p,1}, \omega(k)_{p,2}, \dots, \omega(k)_{p,L}]$, $k=1, 2, \dots, N$ 作为目标角速度数据; 获得目标角速度数据后, 在其基础上加入服从 $N(0, R)$ 分布的高斯白噪声 δ_N 作为实际角速度数据 $\omega(k)_{m,1:L} = [\omega(k)_{m,1}, \omega(k)_{m,2}, \dots, \omega(k)_{m,L}]$, $k=1, 2, \dots, N$ 。

上文中目标角速度数据与实际角速度数据在坐标系 $O_{Com} - XYZ$ 下都具有三个自由度, 故在此构建三个深度网络模型, 每个深度网络模型对应一个自由度, 并将目标角速度数据 $\omega(k)_{p,1:L} = [\omega(k)_{p_x,1:L}, \omega(k)_{p_y,1:L}, \omega(k)_{p_z,1:L}]^T$, $k=1, 2, \dots, N$ 与实际角速度数据 $\omega(k)_{m,1:L} = [\omega(k)_{m_x,1:L}, \omega(k)_{m_y,1:L}, \omega(k)_{m_z,1:L}]^T$, $k=1, 2, \dots, N$ 同样按三个自由度进行分解。

最后, 基于分解后的数据生成训练数据。训练

数据中的输入数据选取实际角速度数据 $\omega(k)_{m,1:L}$, $k=1, 2, \dots, N$ 中维度为 D 的时间序列 $s(k)_{M,t} = [\omega(k)_{M,t-D}, \omega(k)_{M,t-D+1}, \dots, \omega(k)_{M,t}]$, 由 Takens 定理^[24-26]可知, 对于一大类非线性系统, 当其某一特定时刻状态空间维度为 d 维时, 利用系统在该时刻之前一段时间序列的输出, 输出个数达到 $2d+1$ 便可以实现对该时刻系统状态的有效重构, 故如果时间序列 $s(k)_{M,t}$ 的维度足够大, 就可以重构出序列末尾 $\omega(k)_{M,t}$ 中的全部状态信息, 包括动力学与噪声特征; 训练数据中的标签数据选取与 $\omega(k)_{M,t}$ 对应的 t 时刻目标角速度 $\omega(k)_{p,t}$, 深度网络模型通过标签数据的训练有选择性的将 $\omega(k)_{M,t}$ 中动力学特征部分进行重构, 实现对 t 时刻实际角速度 $\omega(k)_{M,t}$ 的降噪。获得训练数据后按三个自由度整合成三个训练集分别训练对应的深度网络模型。

2 角速度信号降噪的深度网络模型

本节给出了构建组合体航天器角速度信号降噪的深度网络模型的具体过程, 并提出了构建深度网络模型的优化方法和参数初始化方法。

2.1 深度 ReLU 网络模型

随着深度网络模型层数的增加, 模型的训练难度也逐渐增大。模型训练困难的一个主要原因是由于所选取的激活函数的导数不等于 1, 当模型层数较多时经链式求导后引起的梯度消失或爆炸。

深度 ReLU (Rectified Linear Units) 网络模型即激活函数为 ReLU 函数的深度网络模型, ReLU 激活函数如图 2 所示, 其表达式为:

$$ReLU(x) = \max(0, x) \quad (3)$$




图2 ReLU 激活函数

Fig.2 ReLU activation function

ReLU 激活函数将负数直接置零, 正数则激活

网络按照原值输出,使深度网络模型更加容易实现对输入数据特征的稀疏表示^[27],而且由于 ReLU 激活函数在大于零时其导数为 1,有效的缓解了深度网络模型训练中的梯度消失或爆炸问题。

如图 3 所示,深度 ReLU 网络模型由输入层、多个 ReLU 隐藏层、以及输出层组合而成。




图3 X轴方向的深度 ReLU 网络模型

Fig.3 Deep ReLU network model in the X direction

网络输入层接收需要进行降噪的数据,在训练阶段接收的是训练数据中的实际角速度序列数据 $s(k)_{M,t} = [s(k)_{Mx,t}, s(k)_{My,t}, s(k)_{Mz,t}]^T, k = 1, 2, \dots, N$,并根据自由度的不同将 $s(k)_{Mx,t}, s(k)_{My,t}, s(k)_{Mz,t}$ 分别作为三个深度网络模型的输入。

ReLU 隐藏层的作用是提取输入层中数据的特征,隐藏层通过使用训练数据进行训练获得序列 $s(k)_{M,t}$ 中 t 时刻的动力学特征与噪声特征,单层 ReLU 隐藏层模型为:

$$\begin{cases} \mathbf{x}_i = \mathbf{W}_i^T \mathbf{y}_{i-1} + \mathbf{B}_i \\ \mathbf{y}_i = \text{ReLU}(\mathbf{x}_i) \end{cases} \quad (4)$$

其中 \mathbf{y}_{i-1} 为上一层的输出向量, $\mathbf{W}_i, \mathbf{B}_i$ 为第 i 隐藏层的权值矩阵与偏置向量,计算 \mathbf{y}_{i-1} 与 $\mathbf{W}_i, \mathbf{B}_i$ 的线性组合 $\mathbf{W}_i^T \mathbf{y}_{i-1} + \mathbf{B}_i$ 即可得到第 i 隐藏层的输入向量 $\mathbf{x}_i, \mathbf{y}_i$ 为 \mathbf{x}_i 代入到 ReLU 激活函数后的输出值。

最后,网络输出层根据隐藏层获取的特征信息对序列 $s(k)_{M,t}$ 中 t 时刻的动力学特征部分进行重构,重构方法是将隐藏层最后一层输出 \mathbf{y}_f 与输出层权值矩阵 \mathbf{W}_o 和偏置向量 \mathbf{B}_o 直接进行线性计算,得到:

$$\omega_{D,t} = \mathbf{W}_o^T \mathbf{y}_f + \mathbf{B}_o \quad (5)$$

$\omega_{D,t}$ 为计算后的输出值,在训练过程中计算 $\omega_{D,t}$ 与 t 时刻目标角速度 $\omega_{p,t}$ 之间的误差,并根据误差反向调整深度网络模型的内部参数,不断迭代优化直至

$\omega_{D,t}$ 与 $\omega_{p,t}$ 之间误差小于一定范围内时模型训练完成,具体优化过程将在 2.2 节进行介绍,训练完成后模型所输出的 $\omega_{D,t}$ 即为经过降噪后的 t 时刻角速度。

2.2 模型优化

深度网络模型的训练过程即是通过优化模型参数使其达到既定目标的过程。一般来说,模型优化过程主要有以下几个步骤:

(1) 构建一个代价函数并设立优化目标;

(2) 基于梯度方法确定模型参数的优化方向。当数据量较大时,可以随机选取训练集中固定数量的样本来计算每个参数的优化方向,这些样本被称为 min-batch;

(3) 设定学习率与每个参数的优化方向相乘,得到每个参数的更新量对其进行更新;

(4) 不断进行(2)(3)迭代过程直至达到优化目标;

在本文中设定的优化目标为最小化模型输出值与训练集标签数据之间的均方误差,即:

$$\begin{cases} L(\theta) = \sum_{i=1}^U \frac{1}{U} \|\omega_{D,t}^i - \omega_{p,t}^i\|^2 \\ \min_{\theta} L(\theta) \end{cases} \quad (6)$$

其中, $L(\theta)$ 为代价函数, θ 代表深度 ReLU 网络模型中参数 $\mathbf{W}, \mathbf{B}, U$ 为训练集中的样本总个数。基于式(6)本文采用 Adam(Adaptive moment estimation)方法^[28]对深度 ReLU 网络模型进行优化。Adam 方法是一种基于梯度的随机优化方法,它通过估计代价函数中每个参数梯度的一阶矩与二阶矩,自适应调节学习率的大小,并采用偏差修正方法使每次迭代的参数更新量限定在一定范围内,解决了在梯度稀疏情况下所导致的参数更新量过大的问题。

2.3 参数初始化

在对深度网络模型进行优化之前,需要初始化模型中的各个参数。参数初始化是模型训练过程中的一个极为重要的步骤,初始化的好坏直接影响模型训练的收敛效率。比较常用的初始化方法是根据固定标准差的高斯分布随机产生模型参数^[29],但这种方法往往造成模型在层数较多时很难收敛;目前较常用的 Xavier 初始化方法^[30]通过调整模型每层的输出方差,使深层模型实现快速收敛,不过 Xavier 初始化方法推导过程中假设激活是线性的,这对于 ReLU 激活函数并不适用;为此 He 等人基于 ReLU 激活函数性质提出了一种初始化深度 Re-

LU网络模型参数的方法^[15]——MSRA初始化,并通过实验验证了该方法能够使极深的ReLU网络模型收敛并提高其收敛速度。

鉴于本文模型为深度ReLU网络模型,故采用MSRA初始化方法对模型参数进行初始化.具体实施方法是先依高斯分布 $N(0,1)$ 随机产生深度ReLU网络模型内的所有参数,包括隐藏层和输出层的权值矩阵与偏置向量,此时权值矩阵与偏置向量的方差 $Var(\mathbf{W})$ 和 $Var(\mathbf{B})$ 都为1;然后按照MSRA初始化方法将每一层的权值矩阵的方差 $Var(\mathbf{W}_i)$ 由1变为上一层输入节点数 n_{i-1} 倒数的2倍,即:

$$Var(\mathbf{W}_i) = \frac{2}{n_{i-1}} \quad (7)$$

由此得到MSRA初始化权值矩阵 \mathbf{W}_i 为:

$$\mathbf{W}_i = \mathbf{W}_i \cdot \sqrt{\frac{2}{n_{i-1}}} \quad (8)$$

3 仿真验证

基于上述深度网络模型构建方法,本节在给定的仿真条件下,采用测试数据对该方法与无需组合体航天器动力学模型的小波降噪方法进行对比验证,以证明本文所提出方法的有效性。

3.1 模型训练

本文使用的模型结构为7层的ReLU网络模型,一共三个对应不同的自由度,每个网络模型都由一个输入层、一个输出层、及五个隐藏层组成,其中五个隐藏层的节点数依次为2048,512,128,32和8,输入层与输出层节点数由训练数据的维度确定.模型参数初始化的方法已经在2.3节详细说明。

训练数据按1.2节所描述方法生成.服务航天器惯性张量为:

$$\mathbf{J}_{Ser} = \begin{bmatrix} 1166 & -38.9 & -60.3 \\ -38.9922 & 9562.3 & \\ -60.362 & 3734.8 & \end{bmatrix} \text{kg} \cdot \text{m}^2$$

$\Delta_x, \Delta_y, \Delta_z$ 在 $[100, 200]$ 范围内、 $\Delta_{xy}, \Delta_{yz}, \Delta_{xz}$ 绝对值在 $[10, 20]$ 范围内随机产生了500组不同的组合,控制力矩为 $\tau = [100, 100, 100]^T \text{N} \cdot \text{m}$,角速度初始值为 $\omega_0 = [0, 0, 0]^T \text{rad/s}$,对每一组 $\Delta_x, \Delta_y, \Delta_z, \Delta_{xy}, \Delta_{yz}, \Delta_{xz}$ 根据式(2)求得时长为50s的目标角速度序列,采样频率为10Hz,然后对得到的目标角速度数据加入服从 $N(0, 0.25)$ 分布的高斯白噪声 δ_N 得到实际角速度数据;训练数据中的输入数据维度 D

为201,标签维度为1,将训练数据按自由度个数整合成三个训练集,每个训练集中有150000个样本。

采用Adam方法对模型进行优化需要预先设定3个超参数,包括学习率 α ,一阶矩估计指数衰减率 β_1 和二阶矩估计指数衰减率 β_2 ,本文根据文献[23]中提供的默认设置设定参数值: $\alpha = 0.001, \beta_1 = 0.9, \beta_2 = 0.999$.优化过程中每次迭代的minibatch大小为50,对每个训练集一共训练20次,训练完成共需60000次迭代。

3.2 测试集对比验证

为校验本方法的有效性,本文采用与生成训练数据相同的方法,随机产生了5组与训练集不同的 $\Delta_x, \Delta_y, \Delta_z, \Delta_{xy}, \Delta_{yz}, \Delta_{xz}$ 组合,在其他参数一致的情况下构建测试集校验训练后的深度ReLU网络模型对组合体航天器角速度降噪效果.在对比分析方面,本文将深度ReLU网络模型的降噪结果与无需动力学模型的小波降噪方法进行了对比,而由于航天领域状态估计方法中较常应用的Kalman滤波方法需要较精确系统模型,在此处并不适用.这两种方法的降噪效果评价统一以均方误差(MSE)为标准.但采用小波降噪方法并不意味着不需要任何关于待降噪信号的先验知识,其仍然需要根据信号类型选取相应的小波基函数并设置适当的阈值门限与分解级数;而深度ReLU网络模型可以直接从数据中学习其隐含的动力学特征而不需要先验知识的指导,能够在训练完成后自适应的对未知信号进行降噪。

表1 降噪效果对比(MSE)

Table 1 Comparison of denoising effects(MSE)

Angular rate signals	Untreated	Wavelet denoising	Deep learning denoising
X-axis	0.2426	5.36×10^{-3}	4.23×10^{-3}
Y-axis	0.2476	1.414×10^{-2}	9.11×10^{-3}
Z-axis	0.2485	1.476×10^{-2}	9.93×10^{-3}

为尽量避免小波降噪方法中参数选取所造成的影响,本文将由44种小波基函数、24种阈值选取方式与最高到8级的分解级数所能产生的全部参数组合对测试集中三个自由度的实际角速度信号逐一进行降噪,并直接计算其与对应目标角速度之间的MSE,选取其中降噪效果最好的作为对比对象.表1为两种降噪方法对整个训练集进行降噪的全局MSE对比,从表1中可以看到实际角速度信

号在经过两种降噪方法降噪后 MSE 都大幅降低,其中深度学习降噪方法的降噪效果明显优于小波降噪方法,在 X 轴、Y 轴和 Z 轴方向,降噪后角速度信号与最优参数设置下小波降噪方法相比分别降低了 21.1%、35.6% 和 32.7%,表明了深度 ReLU 网络模型从数据中学习到的动力学特征可以对组合体航天器角速度信号进行有效降噪。

为进一步展示两种降噪方法的对比效果,本文选取了其中一组测试数据进行分析.图 4(a)和图 4(b)分别为一组测试数据中的目标角速度信号与实际角速度信号,该数据所对应的转动惯量变化量 $\Delta_x, \Delta_y, \Delta_z, \Delta_{xy}, \Delta_{yz}, \Delta_{xz}$ 分别为 156、104、105、-13、12 和 11,从图中可以看出,由于噪声较强,实际角速度信号中的有用信息基本上被湮没在噪声中。





图 4 测试数据中的目标角速度信号与实际角速度信号

Fig.4 The target angular velocity signals and the actual angular velocity signals from the test data

图 5 为两种降噪方法的降噪效果对比图,由图可知,采用小波降噪方法降噪后的角速度信号较为平滑,但失真问题比较严重,信号中的一些分量没有很好地重构出来,降噪后 X 轴方向信号基本是一条直线,而 Y 轴和 Z 轴方向信号与目标信号波形相比匹配度也较低;而采用深度学习降噪方法降噪后三个方向的角速度信号波形与目标信号匹配度都

有较为明显的提高,如 X 轴方向中的微小波动也得到了很好的匹配;但是也可以看到降噪信号中含有许多毛刺,不够平滑,这主要是因为本文方法是基于输入数据实现对降噪目标的估计,每个估计值虽然比较精确,但仍然存在微小的估计误差,这些估计误差便形成了降噪信号中的毛刺现象,不过它们对整体降噪效果影响不大。



(a) Comparison of denoising effect of X-axis

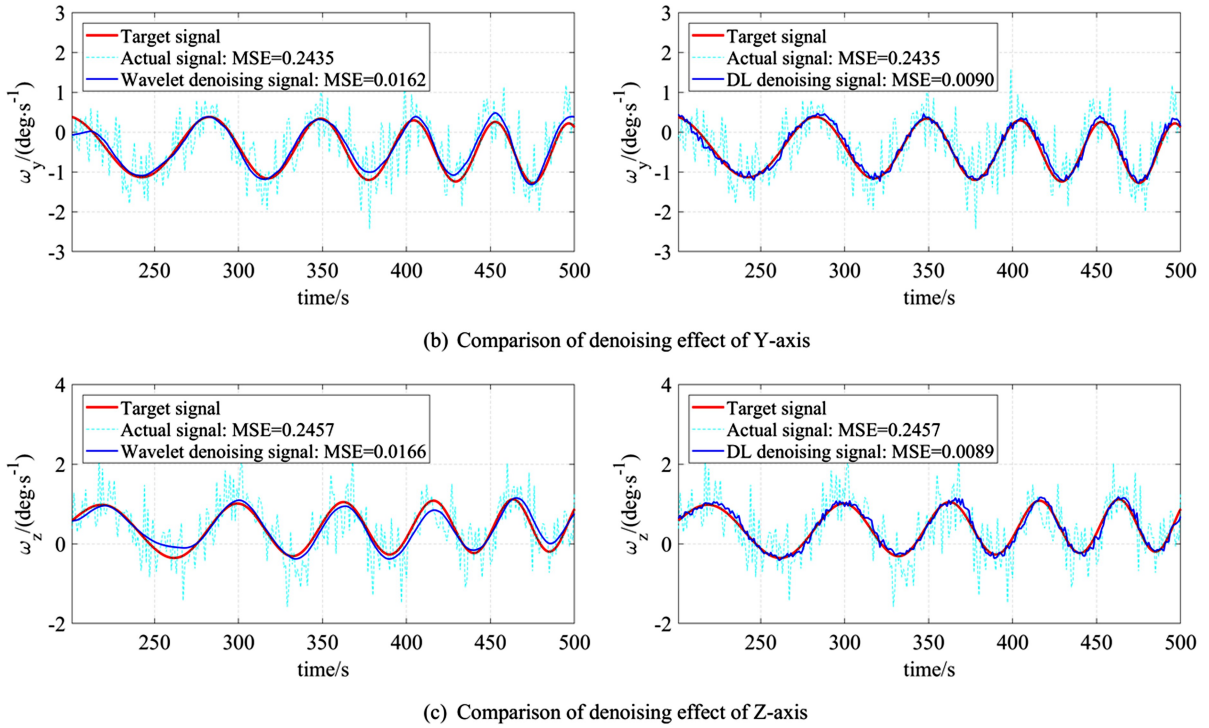


图5 降噪效果对比图

Fig.5 Compared graph of denoising effects

4 结论

针对由于非合作目标惯性张量未知而无法根据组合体航天器模型信息对角速度信号进行降噪的问题,本文基于深度学习方法提出了一种无需预先构建模型、完全由数据驱动的组合体航天器角速度信号降噪方法.仿真校验结果表明,本方法在动力学模型和测量噪声统计特性未知情况下的降噪效果明显优于最优参数设置下的小波降噪方法,在X轴、Y轴和Z轴方向,降噪后角速度信号的MSE分别降低了21.1%、35.6%和32.7%.此外,本文方法具有良好的适用性,对于姿态角等其他状态量同样可以采用本文的方法进行降噪.

参 考 文 献

- Mohan S, Miller D W. Operational impact of mass property update for on-orbit assembly. In: AIAA SpaceOps 2006 Conference, Rome, 2006;5658
- 王明,黄攀峰,常海涛. 非合作目标航天器质量特性参数辨识. 飞行力学, 2014, 32(6):536~540 (Wang M, Huang P F, Chang H T. Identification of mass characteris-
- 王明,黄攀峰,常海涛,等. 基于机械臂运动的组合体航天器惯性参数在轨辨识. 西北工业大学学报, 2014, 32(5):811~816 (Wang M, Huang P F, Chang H T, et al. On-orbit identification of inertia parameters of compound spacecraft using space manipulator. *Journal of Northwestern Polytechnical University*, 2014, 32(5):811~816(in Chinese))
- 王明,黄攀峰,孟中杰,等. 空间机器人抓捕目标后姿态接管控制. 航空学报, 2015, 36(9):3165~3175 (Wang M, Huang P F, Meng Z J, et al. Attitude takeover control after capture of target by a space robot. *Acta Aeronautica et Astronautica Sinica*, 2015, 36(9):3165~3175 (in Chinese))
- 梁捷,秦开宇,陈力. 捕获目标卫星后组合体航天器模糊神经网络滑模控制. 动力学与控制学报, 2018, 16(2):180~192 (Liang J, Qin K Y, Chen L. Fuzzy neural network sliding mode control for assembled spacecraft after capture target satellite. *Journal of Dynamics and Control*, 2018, 16(2):180~192 (in Chinese))
- 岳宝增,李晓玉. 航天器平移及姿态机动自适应终端滑模控制. 动力学与控制学报, 2018, 16(4):332~337 (Yue B Z, Li X Y. Adaptive terminal sliding mode control

tic parameters for non-cooperative target spacecraft. *Flight Dynamics*, 2014, 32(6):536~540 (in Chinese))

- for spacecraft with translation and attitude maneuvers. *Journal of Dynamics and Control*, 2018, 16(4): 332~337 (in Chinese))
- 7 Welch G, Bishop G. An introduction to the Kalman Filter. *University of North Carolina at Chapel Hill*, 2010, 8(7): 127~132
- 8 Agrawal B N, Palermo W J. Angular rate estimation for gyroless satellite attitude control. In: AIAA Guidance, Navigation, and Control Conference and Exhibit, Monterey, 2002
- 9 Crassidis J L, Markley F L. Attitude Estimation Using Modified Rodrigues Parameters. In: Proceedings of the Flight Mechanics/Estimation Theory Symposium, Greenbelt, 1996
- 10 吴云华. 编队飞行卫星相对姿态确定与控制方法研究[硕士学位论文]. 哈尔滨: 哈尔滨工业大学, 2006 (Wu Y H. Research on relative attitude determination and control for formation flying satellites[Master Thesis]. Harbin: Harbin Institute of Technology, 2006 (in Chinese))
- 11 曾占魁, 曹喜滨, 张世杰, 等. 航天器相对视觉/IMU 导航量测修正多速率滤波. 哈尔滨工业大学学报, 2015, 47(3): 1~7 (Zeng Z K, Cao X B, Zhang S J, et al. Vision/IMU based multi-rate filtering for spacecraft relative navigation using measurement correction. *Journal of Harbin Institute of Technology*, 2015, 47(3): 1~7 (in Chinese))
- 12 何骁, 谭述君, 吴志刚. 大角度机动下带挠性附件航天器转动惯量在轨辨识. 宇航学报, 2017, 38(9): 927~935 (He X, Tan S J, Wu Z G. On-orbit identification of the moment of inertia for a spacecraft with flexible appendages during a large-angle maneuver. *Journal of Astronautics*, 2017, 38(9): 927~935 (in Chinese))
- 13 董云峰, 苏建敏. 利用小波分析识别空间目标的轨道机动. 宇航学报, 2004, 25(2): 213~218 (Dong Y F, Su J M. Detection of space target orbit maneuver by wavelet analysis. *Journal of Astronautics*, 2004, 25(2): 213~218 (in Chinese))
- 14 王博, 缪玲娟, 汪顺亭. 改进的小波降噪方法在 GPS 姿态测量中的应用. 宇航学报, 2008, 29(4): 1267~1271 (Wang B, Miao L J, Wang S T. Application of improved wavelet denoising method in GPS attitude determination. *Journal of Astronautics*, 2008, 29(4): 1267~1271 (in Chinese))
- 15 He K, Zhang X, Ren S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In: Proceedings of the IEEE international conference on computer vision, Santiago, 2015: 1026~1034
- 16 Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines. In: Proceedings of the 27th international conference on machine learning, Haifa, 2010: 807~814
- 17 Hinton G, Deng L, Yu D, et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 2012, 29(6): 82~97
- 18 LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521(7553): 436~444
- 19 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望. 自动化学报, 2016, 42(5): 643~654 (Duan Y J, Lv Y S, Zhang J, et al. Deep learning for control: the state of the art and prospects. *Acta Automatica Sinica*, 2016, 42(5): 643~654 (in Chinese))
- 20 许寅. 基于机器学习方法的航天器在轨状态异变趋势预测算法研究[硕士学位论文]. 成都: 电子科技大学, 2017 (Xu Y. Research on prediction algorithm of machine learning methods for spacecraft in orbit mutation status [Master Thesis]. Chengdu: University of Electronic Science and Technology of China, 2017 (in Chinese))
- 21 钟足华. 卫星遥测时序数据中预测算法研究[硕士学位论文]. 南京: 南京航空航天大学, 2015 (Zhong Z H. Research on prediction methods for telemetry time series of the satellite [Master Thesis]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2015 (in Chinese))
- 22 刘文学, 聂帅, 梁山, 等. 基于深度学习语音分离技术的研究现状与进展. 自动化学报, 2016, 42(6): 819~833 (Liu W J, Nie S, Liang S, et al. Deep learning based speech separation technology and its developments. *Acta Automatica Sinica*, 2016, 42(6): 819~833 (in Chinese))
- 23 Wang Y, Wang D L. A deep neural network for time-domain signal reconstruction. In: IEEE International Conference on Acoustics, Speech and Signal Processing, Brisbane, 2015: 4390~4394
- 24 Takens F. Detecting strange attractors in turbulence. *Lecture notes in Mathematics*, 1981, 898(1): 366~381
- 25 Robinson J C. A topological delay embedding theorem for infinite-dimensional dynamical systems. *Nonlinearity*, 2005, 18(5): 2135
- 26 Punjani A, Abbeel P. Deep learning helicopter dynamics

- models. In: IEEE International Conference on Robotics and Automation, Seattle, 2015:3223~3230
- 27 Glorot X, Bordes A, Bengio Y. Deep sparse rectifier neural networks. In: Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, Fort Lauderdale, 2011:315~323
- 28 Kingma D, Ba J. Adam: A method for stochastic optimization. In: International Conference on Learning Representations, San Diego, 2015
- 29 Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks. In: Advances in Neural Information Processing Systems, Lake Tahoe, 2012:1097~1105
- 30 Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks. In: Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, Sardinia, 2010:249~256

ANGULAR RATE SIGNALS DENOISING METHOD OF THE COMBINED SPACECRAFT BASED ON DEEP LEARNING *

Chu Weimeng^{1,2} Wu Shunan^{1,2†} Liu Yufei³ Wu Zhigang^{1,2}

(1. School of Aeronautics and Astronautics, Dalian University of Technology, Dalian 116024, China)

(2. State Key Laboratory of Structural Analysis for Industrial Equipment, Dalian University of Technology, Dalian 116024, China)

(3. China Academy of Space Technology, Qian Xuesen Laboratory of Space Technology, Beijing 100094, China)

Abstract For the combined spacecraft consisting of the servicing spacecraft and non-cooperative target, the measured angular rate signals of the combined spacecraft are often affected by large noises, which will influence the sub-sequent control accuracy seriously. Due to the unknown inertia tensor of the non-cooperative target, the signal cannot be effectively denoised using model information. To solve the above-mentioned problem, an angular rate signals denoising method of the combined spacecraft based on the deep learning method is proposed in this paper, which do not require the model information in advance, and is absolutely data-driven. Based on the deep learning, the generative process of the training data which is needed for angular rate denoising is firstly presented, and then a deep network model for angular rate signals denoising of the combined spacecraft is constructed, including the methods of optimization and parameter initialization of the model. Finally, denoising effects are compared between the proposed method and the wavelet denoising method using test data. The result shows that the proposed deep learning method has a better denoising effect than the wavelet method.

Key words deep learning, combined spacecraft, non-cooperative target, signal denoising