



推力矢量极性错误下的飞行控制自主重构技术

潘豪¹, 胡瑞光¹, 宋征宇^{2,3*}, 邵梦晗¹

1. 北京航天自动控制研究所, 北京 100854

2. 中国运载火箭技术研究院, 北京 100076

3. 浙江大学控制科学与工程学院, 杭州 310027

* 通信作者. E-mail: songzhengyu@zju.edu.cn

收稿日期: 2021-09-05; 修回日期: 2021-11-08; 接受日期: 2021-12-15; 网络出版日期: 2022-05-11

国防基础科研 (批准号: JCKY2018203B022) 资助项目

摘要 飞行故障在线自主辨识与控制重构是实现航天智能飞行的一个重要标志. 本文针对运载火箭飞行中的推力矢量极性错误, 研究了基于人工神经网络的故障识别与自主重构方法. 在明确故障模式基础上, 结合扩张状态观测器 (extended state observer, ESO) 观测结果, 提出了考虑模型偏差的仿真训练样本设计方法, 并分别采用基于反向传播 (back propagation, BP) 神经网络和长短时记忆 (long short term memory, LSTM) 网络方法进行了故障辨识设计, 仿真结果表明, 两种方法均具有较高识别准确度, 均可实现推力矢量极性错误下的平稳自主重构, 相比而言, 基于滑窗时间序列的 LSTM 网络方法更具优势, 具有较高的识别准确度.

关键词 极性错误, 自主重构, 扩张状态观测器, 反向传播, 长短时记忆

1 引言

在航天发射中, 尽管飞行前无论是运载火箭还是卫星均经过了充分的测试, 因极性错误导致失利的故障还时有发生. 如何应对极性错误导致的故障, 已愈发引起关注.

最为典型的失利发生在 2013 年 7 月 2 日质子 -M 火箭发射三颗 GLONASS 导航卫星时. 火箭升空离开发射台后就开始偏离轨道, 几秒钟后头部先坠地而后爆炸. 事故调查的结果是, 敏感火箭姿态的 3 个偏航速率陀螺安装不当, 正负极性恰好颠倒¹⁾. 尽管采用了冗余设计, 但至少有两处安装错误在火箭残骸中得到了确认, 且实际飞行状态与这一故障模式下的仿真结果是吻合的.

1) Russia's Proton crashes with a trio of navigation satellites. Published: July 1, 2013, updated: July 2, 3, 4, 5, 9, 11, 15, 18, 19, 23; Aug.11. http://www.russianspaceweb.com/proton_glonass49.html.

引用格式: 潘豪, 胡瑞光, 宋征宇, 等. 推力矢量极性错误下的飞行控制自主重构技术. 中国科学: 信息科学, 2022, 52: 870–889, doi: 10.1360/SSI-2021-0305
Pan H, Hu R G, Song Z Y, et al. Autonomous reconfiguration of flight control under thrust vector polarity errors (in Chinese). Sci Sin Inform, 2022, 52: 870–889, doi: 10.1360/SSI-2021-0305

极性错误不仅仅发生在传感器敏感方向上,也曾发生在控制通道上,如2020年11月16日欧洲Vega火箭发射失利的案例。该火箭四级飞行偏离了标称轨迹,处于失控状态,导致任务失败。ESA的官方声明将问题归因于推力矢量控制系统机电作动器控制通道布线和连接错误²⁾;这导致原本发送到一个作动器的指令被发送到另一个,从而失去控制³⁾。

极性错误在卫星上也有发生,如2016年4月底JAXA的X射线卫星“瞳”彻底失效的案例⁴⁾。在卫星进入安全控制模式后,地面指控中心注入指令启动卫星推进器用于停止卫星的转动。但是指令转换矩阵中共有6个参数的极性本应为正但设置为负,卫星不但没有停转反而加速旋转,最终导致卫星结构破损。

由于在静态测试条件下许多信号处于零位状态,其极性特征不强,给检查带来了不便。俄罗斯航天机构在总结GLONASS导航卫星发射失利的结论中指出,根据目前的设计、技术和操作文件,以及地面准备和试验(火箭)期间的现有质量控制方法,是无法检测到传感器安装不当的。在各种设计准则中,端对端的极性测试也经常会被强调,但实施较为困难或复杂,最终还是采取分段测试、目视检查以及其他人工确认措施,存在着操作失误的可能。

尽管容错飞行控制的研究有众多成果,但关于极性错误的实时诊断和处理还鲜有报道。由于极性错误将产生严重的后果,能否处理此类问题已成为评价运载火箭自主飞行能力的重要因素。极性错误分为两大类:一类是指令对应关系出错,另一类是正负极性出错。这两类错误均可能由于安装或者参数设置出错而导致。对于正负极性出错的情况,有简单且行之有效的在线判别方法,故障模式相对单一,不作为本文研究的重点。本文重点研究指令对应关系出错的情况下对极性错误的故障模式进行故障诊断,并在故障诊断后开展控制重构。

故障诊断的方法一般分为基于模型的方法和数据驱动的方法^[1]。在基于模型的方法中,是否可以获取高度精确和可靠的数学表达形式是施行该方法最大的障碍;其次,为了可以利用线性系统理论的成果,在处理非线性系统时需要在在工作点处对模型进行线性化,但在故障下偏离标称工况时,这种线性化并不总是能提供一个好的模型;此外,基于模型的技术缺乏对未建模动态、模型不确定性、传感器噪声和干扰的鲁棒性,往往需要放宽故障判别门限以避免过大的虚警率,这就导致难以在早期阶段检测到故障,有可能无法适应故障迅速恶化的情况。并且,就本文研究的极性错误而言,基于标称系统模型的诊断无法区分错误的类型,这对控制重构是不利的。

数据驱动的方法使用大量数据来创建能够捕捉复杂系统行为的模型^[2,3],主要应用在难以准确完整地获取数学模型、维数(变量的数量)或复杂性(分布的、非线性的、可变的系统)导致其他技术不可行、存在或可以获得先前记录的经验和案例来推断等场合。

人工神经网络(artificial neural network, ANN)是从数据中学习复杂系统行为的一种重要的无模型方法,已在线性和非线性系统上有了许多研究成果。它通过设置多个处理层实现对数据特性的学习,层级越深,抽象程度越高。目前使用最广泛的ANN架构有基于反向传播(back propagation, BP)神经网络^[7]、长短时记忆网络(long short term memory, LSTM)^[8]和卷积神经网络^[9,10],这三大网络结构极大地促进了人工智能技术在诸多行业的应用。一般地,BP神经网络和卷积神经网络应用于静态数据处理中,比如图像分类、目标检测等^[11~13]。而对于有时间序列特性的应用,长短时记忆网络应用

2) N° 33-2020. Loss of Vega flight VV17: Independent Enquiry Commission announces conclusions. 17 December 2020. https://www.esa.int/Newsroom/Press_Releases/Loss_of_Vega_flight_VV17_Independent_Enquiry_Commission_announces_conclusions.

3) Jeff Foust. Human error blamed for Vega launch failure. November 17, 2020. <https://spacenews.com/human-error-blamed-for-vega-launch-failure/>.

4) JAXA. Hitomi Experience Report: Investigation of Anomalies Affecting the X-ray Astronomy Satellite “Hitomi” (ASTRO-H). May 24, 2016. http://global.jaxa.jp/projects/sat/astro_h/files/topics_20160524.pdf.

更广泛, 效果更好, 这些应用包括但不限于语音识别^[14]、行为识别^[15,16]、故障检测^[17]、目标轨迹预测^[18]等. 国内一些学者尝试利用 ANN 进行飞行器发动机故障、执行机构故障的诊断^[4~6], 例如文献 [4] 将姿控喷管不同故障模式下产生的影响等效成不同的灰度图, 并对这些图片进行分类识别. 这种方式需要进行图片生成, 对箭载计算机的性能要求较高, 在线应用的难度较大.

本文首次对运载火箭上升段飞行中推力矢量控制极性错误开展诊断, 其主要表现形式为某个执行机构的指令错误地发送到另一个执行机构, 具有多种故障模式; 并在故障诊断后开展控制重构. 本文的创新性在于, 将基于模型和数据驱动的 FDI (fault detection and isolation) 方法相结合, 提升了对多类故障模式的诊断准确率; 针对真实故障子样少的实际情况, 利用对模型不确定性和干扰的适应性设计, 提出了有效的训练和检验样本生成方法; 创造性地使用长短时记忆网络挖掘控制量的时间依赖性, 研究利用滑窗序列的形式构造动态样本, 充分考虑了实际飞行在线应用的可能性; 并联合基于 BP 神经网络的静态极性辨识, 设计故障确认和实施重构的判断准则, 提高了应用可靠性.

本文后续内容分为以下章节. 第 2 节介绍极性错误辨识的基本原理. 首先讨论了火箭姿态控制的运动模型, 在此基础上分析了故障模式并开展了样本设计. 考虑到不确定性和干扰等一般是有界的, 通过有界假设下的蒙特卡罗 (Monte Carlo) 仿真和基于最大边界组合的最坏情况仿真, 生成两种训练样本. 最后详述了极性辨识的总体方案, 利用扩展状态观测器 (extended state observer, ESO) 辨识实际控制力矩来辅助决策. 第 3 节介绍了基于 ANN 的静态和动态两种分类方法. 第 4 节通过仿真分析对比两种方法的效果, 每种方法分析了不同学习样本以及有无 ESO 所产生的差异. 第 5 节对全文进行了总结.

2 极性错误的辨识

2.1 箭体姿态运动模型

描述运载火箭姿态运动的模型方程, 可以表示为^[19]

$$\mathbf{A}\mathbf{X} + \mathbf{B}\dot{\mathbf{X}} = \mathbf{C}\mathbf{Y} + \mathbf{D}\ddot{\mathbf{Y}} + \mathbf{U}, \quad (1)$$

其中, 状态向量 $\mathbf{X} = [\omega_{x1} \ \omega_{y1} \ \omega_{z1} \ \alpha \ \beta]^T$, 控制输入 $\mathbf{Y} = [\delta_\gamma \ \delta_\psi \ \delta_\varphi]^T$, 结构干扰力矩 $\mathbf{U} = [\bar{M}_\varphi \ \bar{M}_\psi \ \bar{M}_\gamma]^T$, 状态矩阵

$$\mathbf{A} = \begin{bmatrix} 0 & 0 & b_1^\varphi & b_2^\varphi & 0 \\ 0 & b_1^\psi & 0 & 0 & b_2^\psi \\ 0 & 0 & d_1^\gamma & 0 & 0 \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 \end{bmatrix},$$

输入矩阵

$$\mathbf{C} = \begin{bmatrix} 0 & 0 & -b_3^\varphi & 0 & 0 & 0 \\ 0 & -b_3^\psi & 0 & 0 & 0 & 0 \\ -d_3 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}, \quad \mathbf{D} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & -b_3''^\varphi \\ 0 & 0 & 0 & 0 & -b_3''^\psi & 0 \\ 0 & 0 & 0 & -d_3'' & 0 & 0 \end{bmatrix}.$$

上述矩阵中 $\omega_{x1}, \omega_{y1}, \omega_{z1}$ 分别为绕箭体 x_1, y_1, z_1 轴的角速度; α, β 为飞行攻角和侧滑角; $\delta_\varphi, \delta_\psi, \delta_\gamma$ 分别为俯仰、偏航、滚动通道的发动机摆角; $\bar{M}_\varphi, \bar{M}_\psi, \bar{M}_\gamma$ 分别为俯仰、偏航、滚动通道的结构干扰力矩. 状态矩阵中 $b_1^\varphi, b_1^\psi, d_1^\gamma$ 分别为三通道的机动阻尼力矩系数, b_2^φ, b_2^ψ 分别为俯仰、偏航通道气动

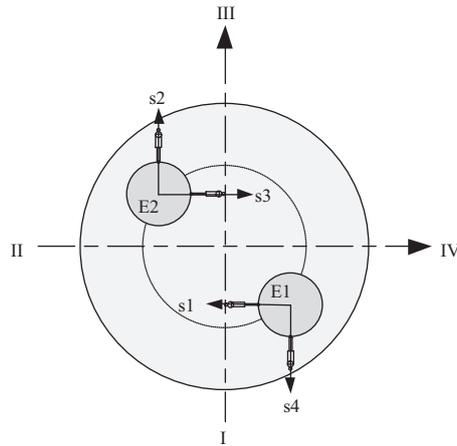


图 1 伺服机构和发动机典型布局示意图

Figure 1 Typical layout of servo mechanisms and engines

力矩系数; 输入矩阵中 $b_3^\varphi, b_3^\psi, d_3$ 分别为三通道的总控制力矩系数, $b_3^{\prime\prime\varphi}, b_3^{\prime\prime\psi}, d_3'$ 分别为三通道发动机摆动部分总惯性力矩系数.

伺服机构带动发动机摆动形成姿态的闭环反馈控制. 经过控制方程解算得到的三通道姿态控制指令 $\delta_m (m = \varphi, \psi, \gamma)$ 与伺服机构驱动发动机的实际摆角 $\delta_i^s (i = 1, 2, \dots, n)$ 的关系可描述为

$$\delta_m = \mathbf{f}(\delta_1^s, \delta_2^s, \dots, \delta_n^s), \tag{2}$$

其中, n 表示伺服机构编号, 映射关系 \mathbf{f} 一般为线性映射.

2.2 故障模式及样本设计

2.2.1 极性故障模式的分析与统计

执行机构指令错位, 意味着式 (2) 映射关系 \mathbf{f} 出错, 而实现控制重构主要通过映射关系的调整. 以可双向“+”字形摆动的发动机构型为讨论对象, 4 台伺服机构和两台发动机布局如图 1 所示.

图 1 中 E1, E2 表示两台发动机, 每台发动机各安装了两台伺服机构用于双向摆动, 其中伺服机构 s2, s4 动作控制箭体俯仰运动, s1, s3 动作控制箭体偏航运动, s1, s2, s3, s4 共同作用控制箭体滚动运动. $\delta_1^c, \delta_2^c, \delta_3^c, \delta_4^c$ 为四路伺服控制指令, 由 δ_m 根据伺服机构的安装形式分解而来, 则姿态控制指令、伺服机构指令与伺服摆角之间的对应关系如式 (3) 和 (4) 所示:

$$\begin{cases} \delta_1^c = -\delta_\psi + \delta_\gamma, \\ \delta_2^c = -\delta_\varphi + \delta_\gamma, \\ \delta_3^c = \delta_\psi + \delta_\gamma, \\ \delta_4^c = \delta_\varphi + \delta_\gamma, \end{cases} \tag{3}$$

$$\begin{bmatrix} \delta_1^s \\ \delta_2^s \\ \delta_3^s \\ \delta_4^s \end{bmatrix} = \mathbf{S} \cdot \begin{bmatrix} \delta_1^c \\ \delta_2^c \\ \delta_3^c \\ \delta_4^c \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix} \begin{bmatrix} \delta_1^c \\ \delta_2^c \\ \delta_3^c \\ \delta_4^c \end{bmatrix}, \tag{4}$$

其中矩阵 \mathbf{S} 是单位矩阵.

在正常情况下, 实际作用于箭体的三通道控制摆角 $\delta_\varphi^s, \delta_\psi^s, \delta_\gamma^s$ 与指令 $\delta_\varphi, \delta_\psi, \delta_\gamma$ 一致:

$$\begin{pmatrix} \delta_\varphi^s \\ \delta_\psi^s \\ \delta_\gamma^s \end{pmatrix} = \begin{pmatrix} \delta_\varphi \\ \delta_\psi \\ \delta_\gamma \end{pmatrix} = \mathbf{f}(\delta_1^s, \delta_2^s, \delta_3^s, \delta_4^s) = \begin{pmatrix} 0.5(\delta_4^s - \delta_2^s) \\ 0.5(\delta_3^s - \delta_1^s) \\ 0.25(\delta_1^s + \delta_2^s + \delta_3^s + \delta_4^s) \end{pmatrix}. \quad (5)$$

若伺服控制指令和实际伺服机构动作之间的对应关系出现错误, 则 \mathbf{S} 不是单位矩阵, 例如当

$$\mathbf{S} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix},$$

即有

$$\begin{cases} \delta_1^s = \delta_3^c, \\ \delta_2^s = \delta_4^c, \\ \delta_3^s = \delta_1^c, \\ \delta_4^s = \delta_2^c, \end{cases}$$

这就是极性错误或指令错位的含义所在.

若 \mathbf{S} 不是单位矩阵 (即对应关系错位), 将导致俯仰、偏航和滚动 3 个通道的姿态控制指令错误地分配到伺服机构上, 影响箭体稳定性. 这种错误可分为两大类:

- (1) 同一通道内的错位, 如俯仰控制通道内的伺服机构 s2 与 s4 指令错位.
- (2) 不同通道间的错位, 如俯仰控制通道的伺服机构 s4 与偏航控制通道的伺服机构 s1 指令错位.

结合伺服机构安装和线缆长度等实际情况, 工程中最有可能出现错位的具体形式主要分为 8 种, 如表 1 所示. 下面讨论这 8 种故障的可诊断性与可识别性. 首先给出两个定义.

定义1 对线性映射关系 \mathbf{f} , 若因故障导致的实际线性映射关系 $\mathbf{f}' \neq \mathbf{f}$, 则称该故障是可诊断的; 若 $\mathbf{f}' = \mathbf{f}$, 则称该故障是不可诊断的.

定义2 考虑不同故障导致的映射关系, 如果存在任何两种 \mathbf{f}'_1 和 \mathbf{f}'_2 , 使得 $\mathbf{f}'_1 = \mathbf{f}'_2$, 则称这两种故障是不可识别的.

故障可诊断意味着故障产生了新的映射关系, 并能通过姿态运动特征进行诊断. 从式 (3) 可以看出, 上述 8 种故障均能产生不同于正常状态的映射关系, 驱动箭体产生不同于正常状态的绕心运动. 可识别性意味着任意两种故障可互相区分, 这就要求故障产生的映射关系是不相同的. 而对于 Mode3 和 Mode4 两类故障模式, 其分别包含的两种故障错位形式之间是无法区分的. 以 Mode3 为例, 当发生故障编号 3 “s1, s4 错位” 时, 即有 $\delta_1^s = \delta_4^c, \delta_4^s = \delta_1^c$, 根据式 (5) 得到实际控制摆角 $\delta_\varphi^s = 0.5(\delta_1^c - \delta_2^c)$, $\delta_\psi^s = 0.5(\delta_3^c - \delta_4^c)$; 当发生故障编号 4 “s2, s3 错位” 时, 即 $\delta_2^s = \delta_3^c, \delta_3^s = \delta_2^c$, 根据式 (5) 有 $\delta_\varphi^s = 0.5(\delta_4^c - \delta_3^c)$, $\delta_\psi^s = 0.5(\delta_2^c - \delta_1^c)$. 联合指令分解式 (3), 可以发现两种故障下实际作用于箭体的三通道控制摆角是一样的, 均为 $\delta_\varphi^s = 0.5(\delta_\varphi - \delta_\psi)$, $\delta_\psi^s = 0.5(\delta_\psi - \delta_\varphi)$, $\delta_\gamma^s = \delta_\gamma$, 因此这两种极性故障无法识别. 类似地, Mode4 对应的故障编号 5 “s1, s2 错位” 与故障编号 6 “s3, s4 错位” 同样不可区分. 因此, 8 种故障共产生

表 1 控制指令和伺服摆角对应关系错误分类
Table 1 Error classification between control commands and servo swing angles

Failure no.	Specific form	Error type	Diagnosability	Identifiability	Mode no.
1	s2, s4 reversed	Reversed in the same channel	Yes	Yes	Mode1
2	s1, s3 reversed		Yes	Yes	Mode2
3	s1, s4 reversed	Reversed between different channels	Yes	No	Mode3
4	s2, s3 reversed		Yes	No	Mode4
5	s1, s2 reversed				
6	s3, s4 reversed				
7	s1, s3 reversed and s2, s4 reversed	Reversed in the same channel	Yes	Yes	Mode5
8	s1, s2 reversed and s3, s4 reversed	Reversed between different channels	Yes	Yes	Mode6

了 6 种明显区别于正常状态的映射关系, 记为 Mode1~Mode6, 它们均是可诊断的. 其中有 4 种模式 Mode1, Mode2, Mode5, Mode6 是可识别的, 而 Mode3, Mode4 是无法识别具体的错位关系的.

2.2.2 仿真样本设计

采用 ANN 进行分类辨识需要有训练和检验样本, 这可根据 2.1 小节的姿态运动模型通过仿真得到, 故统称为仿真样本. 仿真样本是基于大量闭环仿真得到的, 其所用控制律与实际飞行相同, 所用模型是通过各种地面试验计算获取的, 模型参数包括标称参数及其偏差取值, 从而确保实际模型参数在偏差包络范围内. 同时, 通过改变姿态控制指令与伺服机构的信号传输关系, 实现对故障的模拟.

在标称情况下, 正常和故障状态各只有一种飞行样本数据, 这对于 ANN 的训练是不够的. 由于姿控设计时往往要考虑各类模型偏差和干扰等情况, 因此, 仿真中考虑对模型参数 (包括刚体、弹性和晃动模型参数)、结构干扰、控制增益等参数进行上下限或随机拉偏, 生成两类样本: 第 1 类按照各个参数的偏差取上下限值进行随机组合, 并包含姿控设计中的上下极限组合, 该样本标识为 D. 例如, 将参数 b_2^ψ , b_2^ϕ , b_3^ψ , b_3^ϕ , d_3 分别在额定值基础上取 20%, -20%, -20%, 20%, -20% 的偏差, 弹性系数、晃动系数、控制增益分别取 50%, -30%, -20% 的偏差, 即每个系数的偏差均取上极限或下极限. 第 2 类按照各个参数的偏差在上下限范围内采用蒙特卡洛采样随机选取, 该样本标识为 M. 例如, b_2^ψ , b_2^ϕ , b_3^ψ , b_3^ϕ , d_3 分别在额定值基础上取 -5%, 8%, 10%, 15%, 6% 的偏差, 弹性系数、晃动系数、控制增益分别取 -25%, -3%, 15% 的偏差, 即每个系数的偏差均是在上下极限内随机取值. 两类样本的生成方式如表 2 所示.

2.3 极性辨识的总体方案

2.3.1 方案的基本构成

姿态角加速度直接反映了箭体当前所受的总力和力矩大小, 因此辨识姿态角加速度有助于故障模式的分类. 箭体所受总力和力矩包括控制力矩、气动干扰力矩、弹性干扰力矩、晃动干扰力矩、结构干扰力矩等, 辨识过程中作出以下合理假设:

- (1) 在火箭起飞后的短暂几秒时间内, 火箭速度较小, 气动干扰力矩可以忽略.

表 2 两类样本生成方式
Table 2 Generation methods of two types of samples

Parameters	D samples	M samples
Aerodynamic disturbance b_2^φ, b_2^ψ	$\pm 20\%$ of nominal values	Random selection within $[-20\%, 20\%]$ of nominal values
Structural disturbance $\bar{M}_\varphi, \bar{M}_\psi, \bar{M}_\gamma$	$\pm 20\%$ of nominal values	Random selection within $[-20\%, 20\%]$ of nominal values
Rigid body equation coefficients $b_3^\varphi, b_3^\psi, d_3$	$\pm 20\%$ of nominal values	Random selection within $[-20\%, 20\%]$ of nominal values
Elastic equation coefficients	$\pm 50\%$ of nominal values	Random selection within $[-50\%, 50\%]$ of nominal values
Slosh equation coefficients	$\pm 30\%$ of nominal values	Random selection within $[-30\%, 30\%]$ of nominal values
Control gains	$\pm 20\%$ of nominal values	Random selection within $[-20\%, 20\%]$ of nominal values

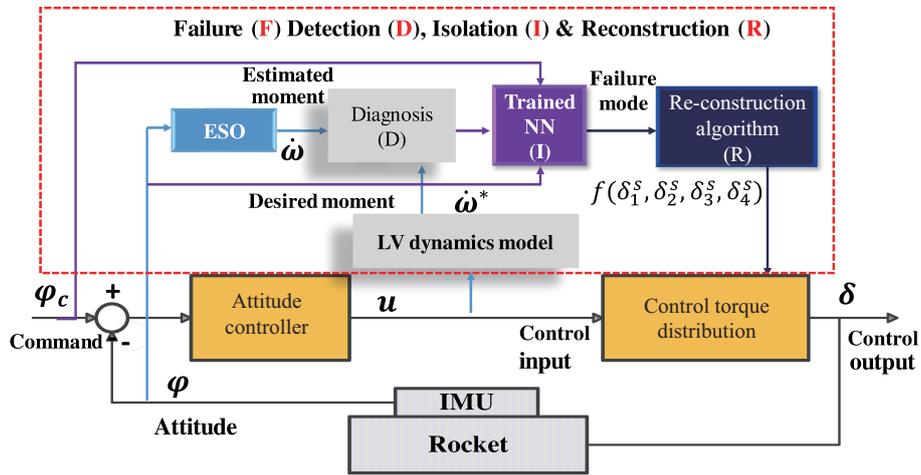


图 2 推力矢量极性辨识与控制重构方案

Figure 2 Thrust vector polarity identification and control reconstruction scheme

(2) 结构干扰力矩与控制力矩相比仅占 1% 左右, 同样可以忽略。
 (3) 弹性、晃动干扰力矩在模型偏差范围内, 故不考虑因弹性、晃动发散造成飞行失控的情况^[20]。
 因此, 起飞段总和力矩的主要组成就是由发动机摆动产生的控制力矩. 通过在线对箭体所受总和力矩的估计, 并结合当前控制指令, 判断当前指令实现的正确性. 由此构成了推力矢量极性辨识与控制重构的总体方案, 如图 2 所示。

图 2 中 ANN 的输入样本数据包括箭体姿态、控制指令, 以及姿态角加速度 (可选), 输出量则为故障模式. 将训练好的神经网络装载至飞行软件中进行实时的故障辨识, 相当于在原控制回路中增加在线故障检测隔离与重构 (fault detection, isolation and reconstruction, FDIR) 的并行模块. 采用扩张状态观测器 (ESO) 估计火箭实际受到的总和力矩, 这是一种基于模型的诊断技术, 其实际效果将在仿真中进行分析. ANN 根据实时飞行过程一小段时间序列的输入进行故障分类与辨识, 在判断出故障模式后, 对指令的映射关系进行重新分配。

2.3.2 扩张状态观测器

自抗扰控制是在辨识干扰的同时进行补偿控制, 其在许多应用领域均取得了成功应用和理论成果^[21,22], 其技术核心是扩张状态观测器. 本文采用基于扩张状态观测器的辨识方法实时估计箭体的角加速度^[23,24]. 取式(1)中状态向量的前三项即箭体角速度 $\mathbf{x}_1 = [\omega_{x1} \ \omega_{y1} \ \omega_{z1}]^T$ 作为扩张状态观测器的状态变量, 由于不确定发动机摆动极性的正确性, 此处将发动机摆动产生的控制力矩作为干扰的一部分, 这里将发动机摆角定义为 $\mathbf{u} = [\delta_\gamma \ \delta_\psi \ \delta_\varphi]$, 控制力矩系数为 $\mathbf{b} = [-d_3 \ -b_3^\psi \ -b_3^\varphi]^T$. 将式(1)中的气动干扰和结构干扰对应相加作为外部扰动 $\mathbf{w}(t) = [\bar{M}_{BX} \ b_2^\psi \beta + \bar{M}_{BY} \ b_2^\varphi \alpha + \bar{M}_{BZ}]^T$, 将发动机摆动产生的惯性干扰项作为内部扰动 $\mathbf{r}(\mathbf{x}_1)$. 从而方程(1)可以改写为

$$\dot{\mathbf{x}}_1 = \mathbf{r}(\mathbf{x}_1) + \mathbf{w}(t) + \mathbf{b}\mathbf{u}. \quad (6)$$

把箭体角加速度扩张为新的状态变量 $\mathbf{x}_2 = [\dot{\omega}_{x1} \ \dot{\omega}_{y1} \ \dot{\omega}_{z1}]^T$, 令 $\mathbf{g} = \mathbf{r}(\mathbf{x}_1) + \mathbf{w}(t) + \mathbf{b}\mathbf{u}$ 为扰动的总和力矩, 那么就把原一阶控制系统扩展为二阶:

$$\begin{cases} \dot{\mathbf{x}}_1 = \mathbf{x}_2, \\ \dot{\mathbf{x}}_2 = \hat{\mathbf{g}}, \end{cases} \quad (7)$$

其中, $\hat{\mathbf{g}}$ 为总扰动的微分. 设 $\mathbf{y} = [\omega_{x1}^{rg} \ \omega_{y1}^{rg} \ \omega_{z1}^{rg}]^T$ 为三通道速率陀螺观测输出, 以观测输出与状态估计的差——总干扰 \mathbf{e}_1 作为驱动, 对箭体的角加速度实现估计, 即有状态观测器 ESO(\mathbf{z}):

$$\begin{cases} \mathbf{e}_1 = \mathbf{z}_1 - \mathbf{y}, \\ \dot{\mathbf{z}}_1 = \mathbf{z}_2 - l_1 \mathbf{e}_1, \\ \dot{\mathbf{z}}_2 = -l_2 \mathbf{e}_1, \end{cases} \quad (8)$$

其中, $\mathbf{z}_1, \mathbf{z}_2$ 分别为估计的角速度、角加速度, 是新设计的系统的状态变量. ESO 设计的目的就是合理设计参数 l_1, l_2 使得 $\mathbf{e}_1 \Rightarrow 0$, 就有 $\mathbf{z}_1 \Rightarrow \mathbf{x}_1, \mathbf{z}_2 \Rightarrow \mathbf{x}_2$.

这里, \mathbf{z}_2 表示箭体运动所产生的总干扰, 包括不确定的控制力矩、气动干扰、结构干扰和模型偏差等带来的不确定性, 其可以为后续的 ANN 训练提供实时的力矩信息, 辅助 ANN 进行分类判别.

3 基于 ANN 的分类方法

3.1 静态分类辨识

静态分类是指根据某一具体时刻的参数来判断属于哪类模态. 本文采用 BP 神经网络作为静态分类器. BP 网络通常是指基于误差反向传播算法的多层前馈人工神经网络, 也称为多层感知器. BP 网络采用的反向传播算法是当前在前馈型神经网络中研究得最为成熟且应用最广的一种有监督学习算法, 具有良好的非线性逼近能力和泛化能力.

根据万能逼近定理, 如果 BP 网络的各节点选用非线性传递函数, 则任何相关问题从理论上都可以用三层前馈网络来解决. 所以, 单隐层 BP 网络的应用最为普遍, 如图 3 所示, 其学习可分为两个过程: 输入信号的正向传播和误差信号的反向传播^[7]. 基于 BP 神经网络的故障辨识方法, 就是对某一时刻的姿态控制量进行分类; 也就是说, 在姿态控制量和具体的故障模式之间用 BP 神经网络建立一种映射关系. 姿态控制量就是 BP 神经网络的输入, 故障模式就是 BP 神经网络的输出.

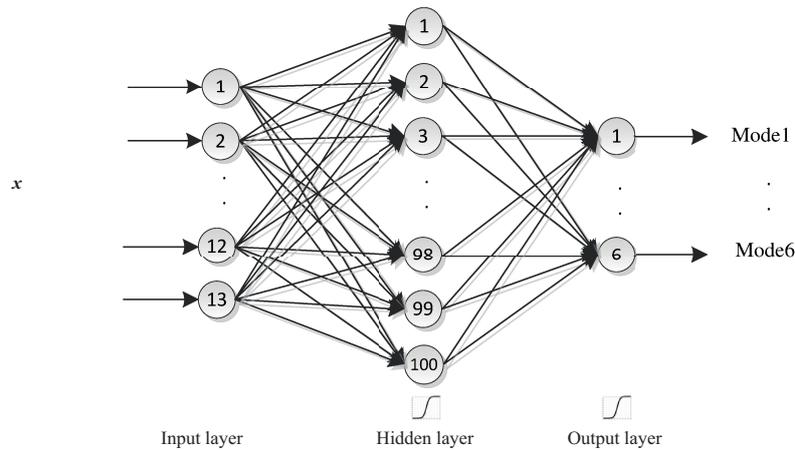


图 3 本文所用 BP 网络结构
Figure 3 BP network structure used in this paper

若同时利用 ESO 估计信息和姿态测量信息, 输入节点数为 13, 分别为: 三通道姿态角偏差、三通道姿态角速度、ESO 估计的三通道姿态角加速度、四路伺服摆角信息; 若只利用姿态测量信息, 输入节点数为 10. 只包含一个隐层, 节点个数为 100. 输出层节点数为 6, 每个节点对应一个模式, 即表 1 中的 6 种故障模式.

隐含层和输出层的传递函数皆为 logsig 函数:

$$\text{logsig}(x) = \frac{1}{1 + e^{-x}}, \quad (9)$$

其中, x 为前一层信号的加权和. 损失函数为 MSE 函数:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (10)$$

其中 y_i 为训练样本 i 的标签, \hat{y}_i 为 BP 网络对训练样本 i 的预测值, N 为训练样本个数. 训练样本的类别标签分别为 $[1, 0, 0, 0, 0, 0]$, $[0, 1, 0, 0, 0, 0]$, $[0, 0, 1, 0, 0, 0]$, $[0, 0, 0, 1, 0, 0]$, $[0, 0, 0, 0, 1, 0]$ 和 $[0, 0, 0, 0, 0, 1]$, 按序分别对应 6 种故障模式.

静态分类辨识所使用的方法如下:

- (1) 根据图 3 构建网络模型;
- (2) 初始化网络: 给输入层与隐含层之间的权重矩阵、隐含层与输出层之间的权重矩阵、隐含层偏置向量、输出层偏置向量逐个赋值 $[-1, 1]$ 内的随机数, 并设定训练误差、学习率、最大学习次数;
- (3) 选取训练样本: 采用批量梯度下降法 (batch gradient descent, BGD), 即在一次训练中使用所有的样本进行参数优化;
- (4) 前向计算: 根据样本值、权重和偏置值, 采用传递函数计算网络输出;
- (5) 求偏导数: 根据样本标签和输出值, 计算损失函数值, 并根据链式法则计算损失函数对网络权重和偏置的偏导数;
- (6) 修正权值和偏置值: 根据学习率、动量项、偏导数, 修正当前权值和偏置值;
- (7) 重新计算全局误差: 根据修正过的权值和偏置值, 对训练样本计算新模型的全局误差;

(8) 判断模型性能: 若全局误差小于设定的训练误差阈值, 说明 BP 网络满足要求; 否则转到步骤 (4), 开始下一次学习, 直到满足训练误差或者达到最大学习次数。

3.2 动态分类辨识

在运载火箭飞行过程中, 每个时刻的参数之间并不是相互独立的, 当前时刻的参数与之前时刻的参数具有较强的相关性. 因此, 参数之间的动态时间依赖特性也是模态分类效果的主要影响因素之一, 可以对参数的时间序列进行分类来判断模态类别。

时间序列分类也是 ANN 的主要应用领域之一, 应用最广泛的是长短时记忆网络^[8]. LSTM 通过引入长时间的“记忆单元”避免循环神经网络 (recurrent neural network, RNN) 中的梯度消失和爆炸的问题, 还能够自动学习时间序列的动态信息. 基于 LSTM 网络的故障辨识方法, 就是对某一段时间内的姿态控制量进行分类; 即在某一段时间内的姿态控制量和具体的故障模式之间用 LSTM 网络建立一种映射关系. 某一段时间内的姿态控制量就是 LSTM 网络的输入, 故障模式就是 LSTM 网络的输出。

本文所用 LSTM 网络结构如图 4 所示. 图 4 中包含输入层、一个 LSTM 单元层、全连接层和输出层 (SoftMax). 输入层设计为包含 50 个控制量采样样本, 即动态分类样本的时长为 1 s (其中每个样本代表 20 ms 内的所有参数). LSTM 层共包含 50 个 LSTM 单元 (注意: LSTM 单元数量与输入层包含的采样样本数量并无必然的相等关系). SoftMax 层包含 6 个节点, 输出属于每类模态的概率, 对应概率值最高的即为网络最终的输出类别. SoftMax 函数如下:

$$p_j = \frac{e^{a_j}}{\sum_{k=1}^C e^{a_k}}, \quad (11)$$

其中 a_j 为全连接后第 j 个节点的输出, p_j 为第 j 个节点经过 SoftMax 函数以后输出的概率值. a_k 为全连接后第 k 个节点的输出, C 为类别个数, 本文中 $C = 6$, 可以看出, SoftMax 函数的作用就是将 LSTM 网络的输出概率化, 为接下来计算损失函数提供简洁清晰并非常有利于计算的输入。

损失函数为交叉熵 (cross entropy) 函数:

$$E_i = - \sum_{j=1}^C y_j \log p_j, \quad (12)$$

其中 y_j 为训练样本 i 在第 j 个节点上的标签值, E_i 为训练样本 i 的交叉熵损失值。

对于动态分类, 样本的选取非常关键. 影响训练和诊断效果的一个最重要因素是每个动态样本所包含的时间, 若时间太短, 则激励不充分, 容易和实际干扰, 使动态过程混淆, 从而产生误判; 若延长动态样本的时间, 虽对故障辨识准确性有利, 但故障影响飞行的时间也越长, 诊断并重构的时间推后, 存在失控的风险. 一般地, 对于特别长的时间序列, 可采用滑窗法截取其不同部分作为训练样本, 如图 5 所示。

动态分类辨识所使用的方法如下:

- (1) 根据图 4 构建网络模型;
- (2) 根据图 5 提取动态训练和测试样本;
- (3) 初始化网络: 给 50 个 LSTM 单元的权值、全连接层的权重矩阵、全连接层的偏置向量分别逐个赋值为 $[-1, 1]$ 内的随机数, 并设定训练误差、学习率、最大学习次数;
- (4) 选取训练样本: 由于网络结构比较复杂, 以及动态训练样本占用内存空间大, 本文采用小批量梯度下降法, 也就是在一次训练中使用小批量的样本进行参数优化, $\text{MiniBatchSize} = 1000$;

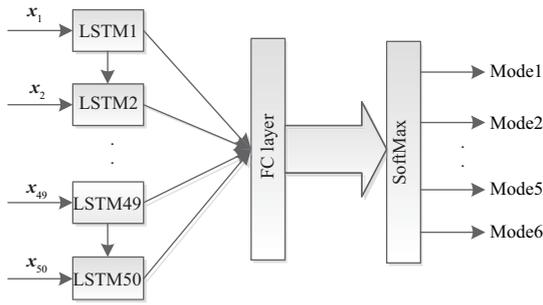


图 4 本文所用 LSTM 网络结构

Figure 4 LSTM network structure used in this paper

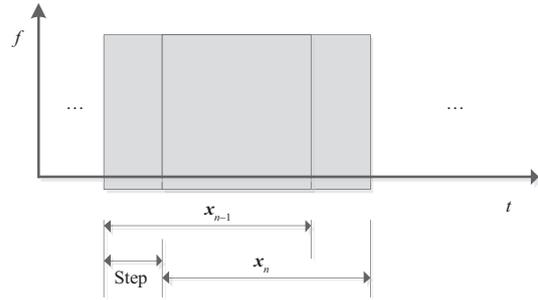


图 5 滑窗处理提取时间序列样本

Figure 5 Sliding window processing to extract time series samples

- (5) 前向计算: 根据样本值、权重和偏置值, 计算网络输出;
- (6) 更新网络参数: 根据样本标签和网络输出值, 计算损失函数值, 并采用截断时间反向传播方法更新网络参数;
- (7) 重复步骤 (4)~(6), 直至遍历所有训练样本;
- (8) 重新计算全局误差: 根据修正过的权值和偏置值, 对所有训练样本计算新模型的全局误差;
- (9) 判断模型性能: 若全局误差小于设定的训练误差阈值, 说明 LSTM 网络满足要求; 否则转到步骤 (4), 开始下一次学习, 直到满足训练误差或者达到最大学习次数。

4 仿真实验和讨论

4.1 样本生成

按照图 1 的布局和 6 种故障模式, 通过仿真生成 D 和 M 两类仿真数据. 其中每种故障模式下仿真生成 50 组姿态运动数据作为神经网络的输入. 每组输入为仿真飞行 10 s 数据, 采样间隔为 0.02 s.

选择某参数偏差组合下正常状态 (Mode0) 和 6 种故障模式 (Mode1~Mode6) 的姿态参数和伺服摆角作为示例, 仿真曲线如图 6 和 7 所示, 这也就是 ANN 的学习或检验样本.

正常状态下可以看出起控后姿态角偏差、角速度、角加速度迅速收敛, 发动机摆角受控并小幅摆动. 分析不同极性故障下的姿态特征:

(1) 对于 Mode1 和 Mode2, 相应的俯仰姿态角和偏航姿态角会快速发散, 其对应俯仰和偏航的角偏差、角速度、角加速度快速增大, 直到发动机摆角达到饱和后, 角加速度不再有增大的趋势. 此外, 滚动通道也会受到间接影响而逐渐发散.

(2) 对于 Mode3 和 Mode4, 三通道姿态角也呈发散趋势, 但由于起飞段姿态角偏差较小, 俯仰和偏航的控制指令均较小, 指令错误导致的干扰不大, 因此短时间内故障表现不明显.

(3) 对于 Mode5 和 Mode6, 这两种情况是相当恶劣的, 极性全部错误, 姿态呈现快速发散趋势.

4.2 静态分类结果

在静态分类中, 检验样本均取自 M, 而训练样本则分为两种情况, 取自 M 或取自 D; 此外在输入参数中, 可以不包含 ESO 估计的力矩信息 (该分类状态标记为 N), 或包含 ESO 的信息 (该分类状态标记为 E). 则共有 4 种组合的分类状态, 分别标识为 MMN, MME, DMN, DME.

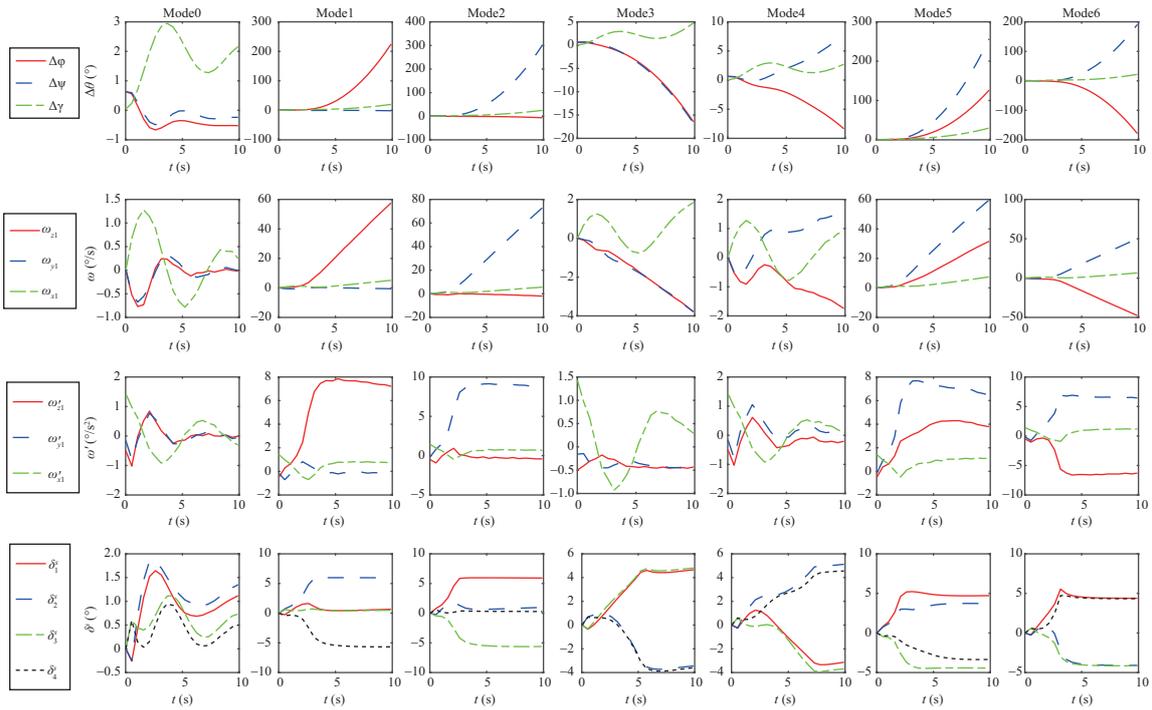


图 6 各种极性故障下火箭姿态特征 (10 s 样本数据)

Figure 6 Rocket attitude characteristics of various polarity faults in 10 s

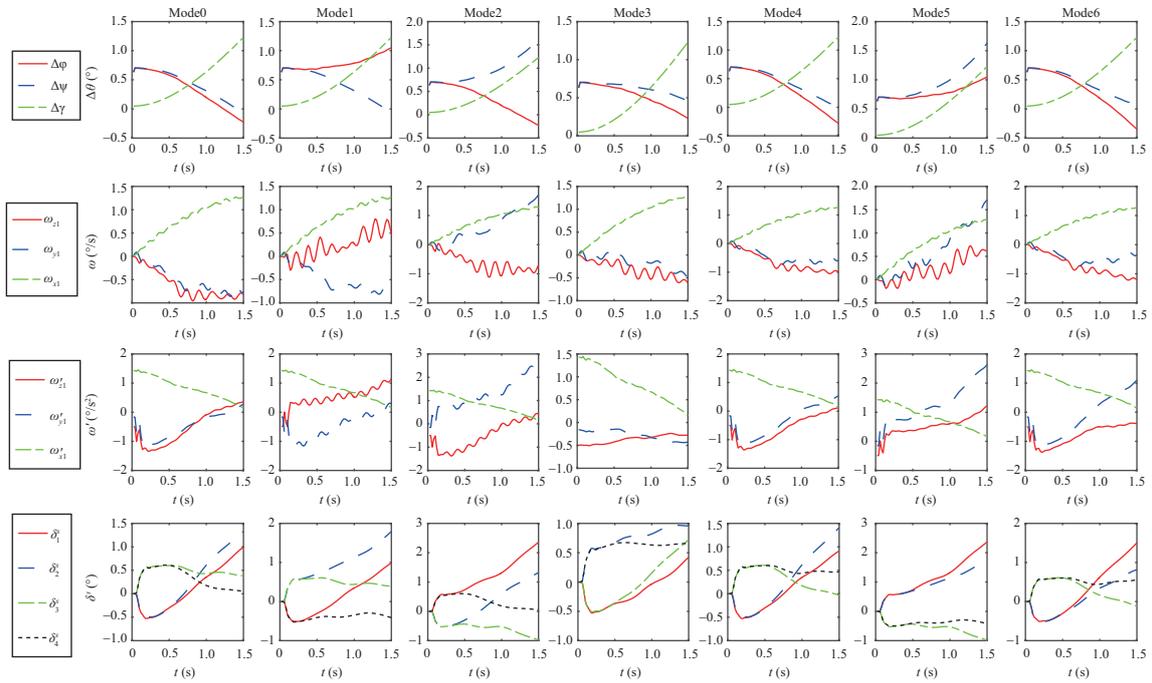


图 7 各种极性故障下火箭姿态特征 (1.5 s 局部放大)

Figure 7 Rocket attitude characteristics of various polarity faults in 1.5 s (zoomed-in)

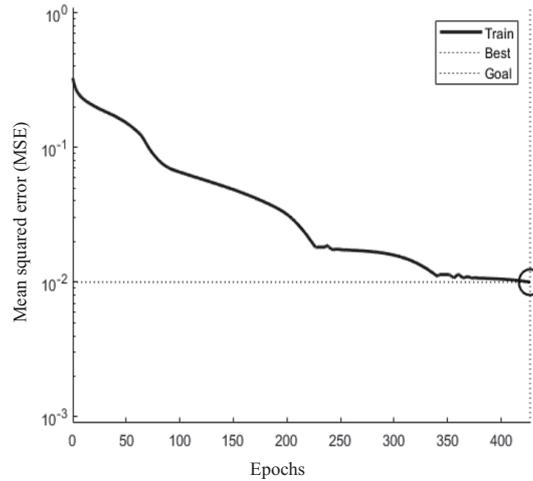


图 8 静态分类训练误差 (MMN)

Figure 8 The training error for static classification (MMN)

以 MMN 为例 (训练样本来自 M, 检验样本也来自 M, 不考虑 ESO 估计的力矩信息). 根据故障辨识要求, 将训练误差设置为 0.01; 训练误差是指分类模型在训练集上的错分样本比率, 即某次迭代后在训练集本身上进行预测得到的错分率. 学习率设为 0.003, 学习率指的是改变网络参数时对梯度值的调制, 合适的学习率能够使损失函数在合适的时间内收敛到最小值或局部极小值, 如果学习率过大, 损失函数值会在最小值附近来回振荡, 无法收敛; 反之如果学习率过小, 优化的效率可能过低, 算法收敛时间较长. 为了避免无法获得最优解, 采用增加动量项的方式来改善训练过程, 具体方式如下:

$$\Delta w(n) = -\eta \frac{\partial \text{MSE}(w)}{\partial w(n)} + \alpha \Delta w(n-1), \quad (13)$$

其中 n 为迭代次数, $\Delta w(n)$ 为第 n 次迭代的权值变化量, $\Delta w(n-1)$ 为第 $n-1$ 次迭代的权值变化量, 学习率 $\eta = 0.003$, $\alpha \Delta w(n-1)$ 为动量项, 动量项参数 $\alpha = 0.9$. 经过 427 次迭代, BP 网络达到训练误差阈值. 此时, 学习步长为 1.76484×10^{-6} , 如此小的学习步长也充分说明了网络损失函数值基本上无法再“下降”. 分类正确率 96.23%, 训练误差曲线如图 8 所示.

将 ESO 估计结果与姿态测量信息共同作为神经网络输入, 其他参数设置相同. 经过 234 次迭代, BP 网络达到训练误差, 网络收敛, 分类正确率为 97.56%.

采用训练集 D, 检验集 M 并暂不考虑 ESO 估计值, 其他参数设置相同. 经过 8123 次迭代, 分类正确率为 96.72%. 在此基础上考虑 ESO 估计值, 经过 3124 次迭代, 分类正确率为 98.40%. 以上 4 种状态的混淆矩阵如图 9 所示. 可以看出, 加入 ESO 估计的力矩信息后, 神经网络分类正确率得到了提高.

4.3 动态分类结果

以 1 s 的动态样本作为训练样本, 分别选取时长为 1 s, 0.5 s, 0.2 s 的动态样本作为测试样本, 并同样考虑 4 种组合的分类状态.

每 1 s 包含 50 个静态样本, 动态样本采样间隔为 0.2 s, 即滑窗取样间隔为 10 个静态样本. 每组 10 s 的数据共有 500 个静态样本, 可生成 46 个动态样本; 50 组共包含 $50 \times 46 = 2300$ 个动态样本; 六

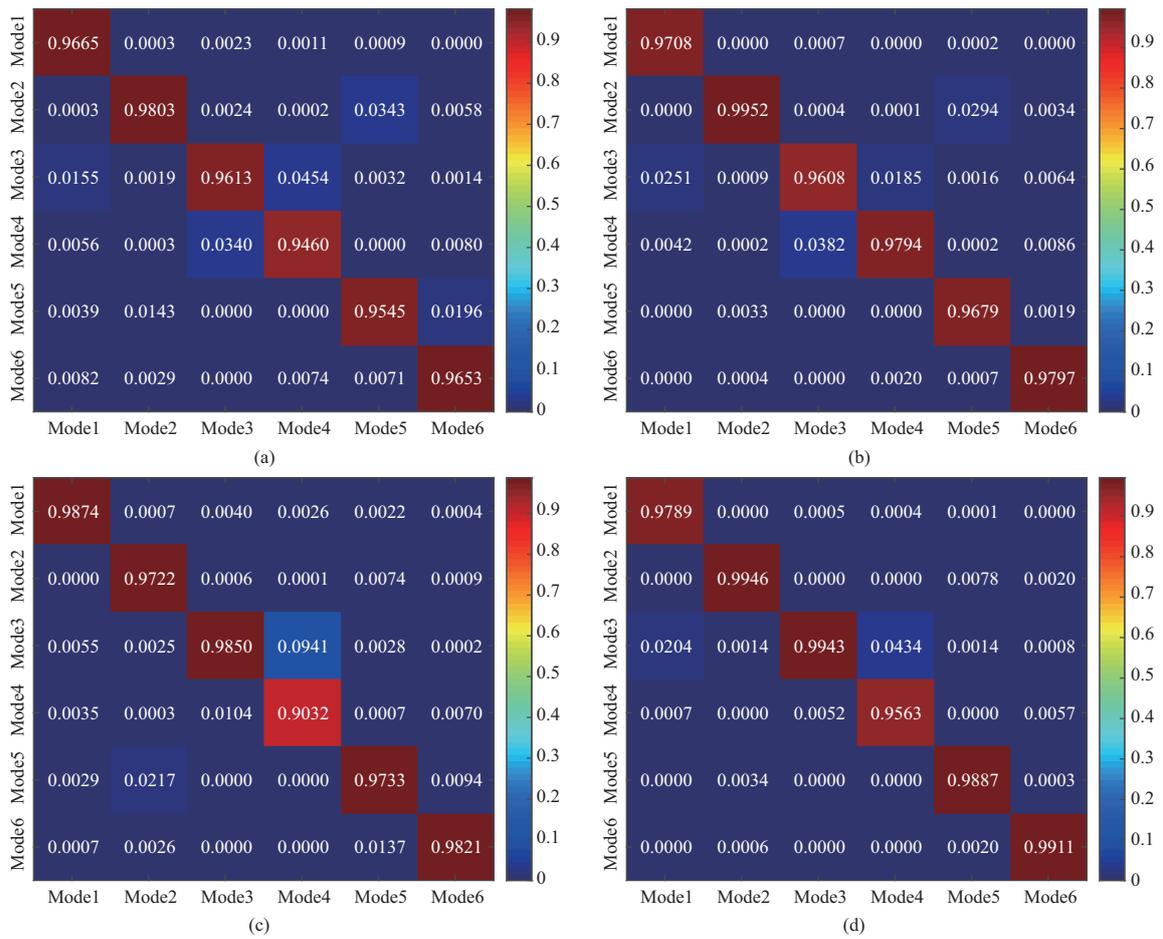


图 9 静态分类混淆矩阵相对值

Figure 9 Relative values of the confusion matrix for static classification. (a) MMN (96.23%); (b) MME (97.56%); (c) DMN (96.72%); (d) DME (98.40%)

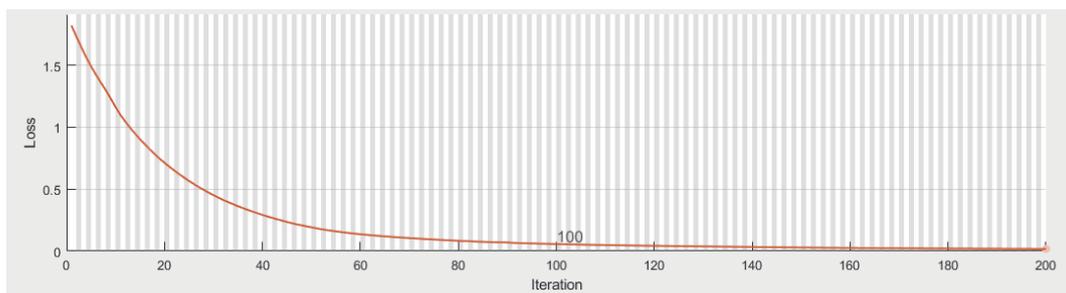


图 10 动态分类训练误差 (MMN)

Figure 10 The training error for dynamic classification (MMN)

类故障数据共包含 $2300 \times 6 = 13800$ 个样本. 因此, 本小节实验训练样本 13800 个. 采用单层 LSTM 模块, 数量为 50 个, 输入特征维数为 10, 输入特征长度为 1 s. MMN 状态训练误差如图 10 所示.

LSTM 网络可以采用不同时长的数据进行测试, 其中采样间隔均统一为 0.2 s. 首先采用与训练样

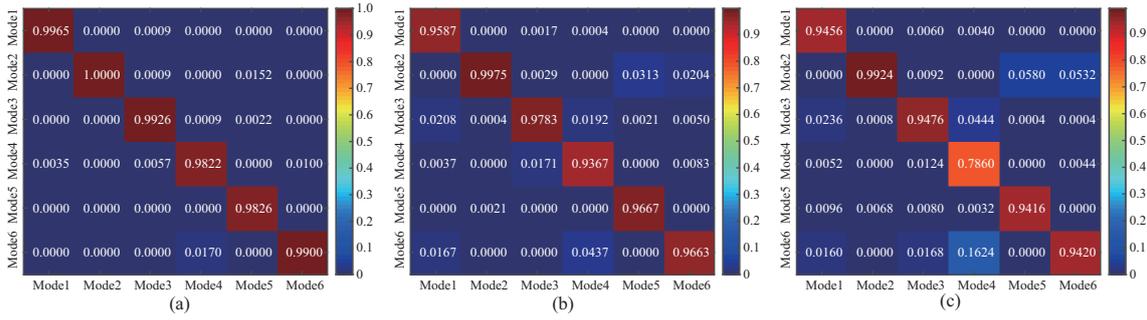


图 11 MMN 条件下动态分类混淆矩阵相对值

Figure 11 Relative values of the confusion matrix for dynamic classification under MMN condition. (a) MMN_1 (99.07%); (b) MMN_0.5 (96.74%); (c) MMN_0.2 (92.59%)

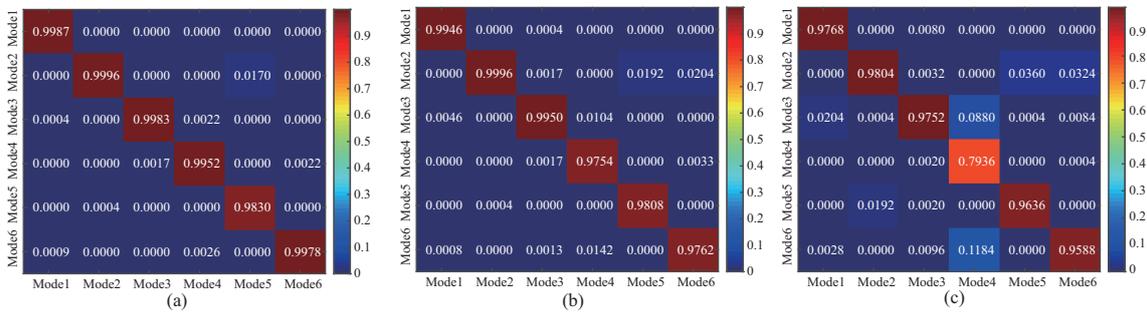


图 12 MME 条件下动态分类混淆矩阵相对值

Figure 12 Relative values of the confusion matrix for dynamic classification under MME condition. (a) MME_1 (99.54%); (b) MME_0.5 (98.69%); (c) MME_0.2 (94.14%)

本时长相同的测试样本进行测试, 即测试样本时长也为 1 s, 数量也为 13800 个, 分类正确率为 99.07%; 采用 0.5 s 长度的测试样本测试, 则每类测试样本为 2400, 共 $6 \times 2400 = 14400$ 个, 分类正确率为 96.74%; 采用 0.2 s 长度的测试样本测试, 则每类测试样本为 2500, 共 $6 \times 2500 = 15000$ 个, 可以看出, Mode4 分类效果不太理想, 分类正确率为 92.59%。3 种测试时长的混淆矩阵如图 11 所示。

采用同样的训练和检验集, 并考虑 ESO 的估计结果。测试样本时长也为 1 s, 分类正确率为 99.54%; 采用 0.5 s 长度的测试样本, 分类正确率为 98.69%; 采用 0.2 s 长度的测试样本, 分类正确率为 94.14%, Mode4 分类效果不太理想。3 种测试时长的混淆矩阵如图 12 所示。

将学习样本取自极限偏差仿真结果, 测试样本取自蒙特卡洛仿真结果, 重复上述动态分类过程。首先不考虑 ESO 估计值, 测试样本时长为 1 s, 分类正确率为 97.75%; 测试样本时长为 0.5 s, 分类正确率为 95.83%; 测试样本时长为 0.2 s, 分类正确率为 93.31%。3 种测试时长的混淆矩阵如图 13 所示。

考虑 ESO 估计值, 在测试样本时长分别为 1 s, 0.5 s 和 0.2 s 的情况下, 分类正确率分别为 99.38%, 98.28% 和 96.02%, 3 种测试时长的混淆矩阵如图 14 所示。

4.4 讨论

根据 4.2 和 4.3 小节的仿真结果可以得到以下信息。

(1) 动态分类成功率高于静态分类。训练和测试均采用样本 M 时, 有无 ESO 估计信息的静态分类成功率分别为 97.56% 和 96.23%, 动态分类成功率是 99.54% 和 99.07%; 训练采用样本 D、测试采用

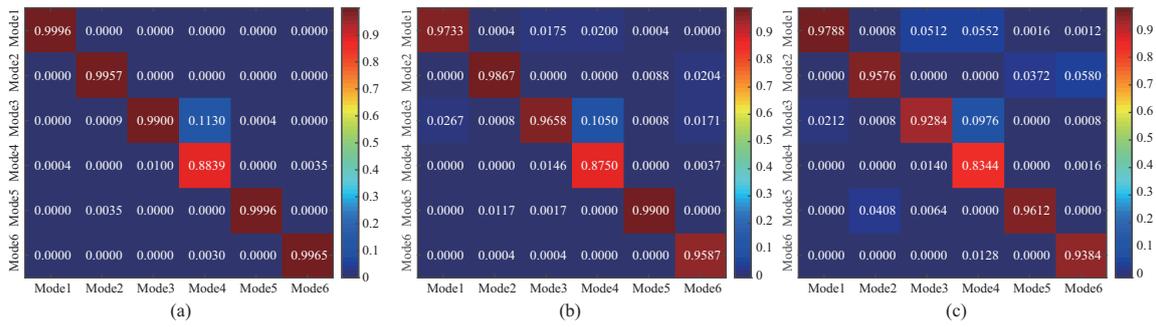


图 13 DMN 条件下动态分类混淆矩阵相对值

Figure 13 Relative values of the confusion matrix for dynamic classification under DMN condition. (a) DMN_1 (97.75%); (b) DMN_0.5 (95.83%); (c) DMN_0.2 (93.31%)

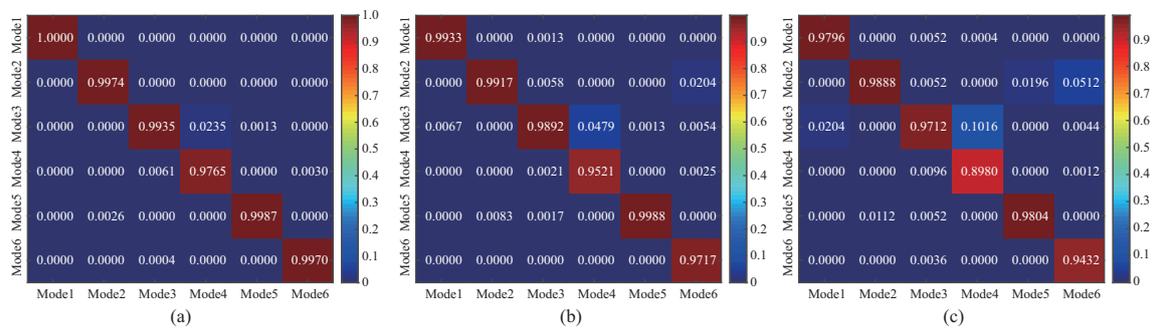


图 14 DME 条件下动态分类混淆矩阵相对值

Figure 14 Relative values of the confusion matrix for dynamic classification under DME condition. (a) DME_1 (99.38%); (b) DME_0.5 (98.28%); (c) DME_0.2 (96.02%)

样本 M 时, 有无 ESO 估计信息的静态分类成功率分别为 98.4% 和 96.72%, 动态分类成功率是 99.38% 和 97.75%. 上述动态分类的数据样本均是截取 1 s 时长的连续时间序列, 不再是与时间无关的孤立的点, 相当于增加了一个维度的信息; 在类似的神经网络结构下, 能取得更优的训练效果. 故障的发生、传导是与时间相关的, 因此以时间序列作为神经网络样本更符合客观逻辑.

(2) 静态分类下, 基于训练样本 D 的分类成功率更高. 但在动态分类下, 结论与测试样本时长相关联. 当测试样本为 1 s 或者 0.5 s 时, 采用训练样本 M 的分类成功率更高; 当测试样本时长为 0.2 s 时, 基于训练样本 M 的分类成功率低于采用训练样本 D 的分类成功率.

(3) 输入样本包含 ESO 估计力矩信息的分类成功率较高. 箭体实时所受的力矩信息包含了发动机摆动产生的控制力矩, 与通过惯性敏感装置测量的姿态信息相比更直接、灵敏.

ESO 估计的信息同样可以作为同步辅助的判别手段. 例如, 当 ESO 估计的力矩超出正常范围, 同时神经网络判别结果显示发生故障, 则可以充分理由相信系统确实存在故障. 为避免极性错误对火箭飞行的致命性影响, 对 ANN 在线故障辨识的要求是在火箭姿态发生大幅发散 (不可拯救)、伺服机构已经达到限幅值 (控制能力不够) 之前, 就要完成故障辨识. 根据本文训练结果, 可以认为 ANN 具备这样的能力. 具体分析如下.

(1) 在静态分类中, 所有分类错误样本皆集中在每组数据时间线的开始部分. 具体地, Mode1 和 Mode4 的错分样本绝大多数分布在前 10 个采样周期, 即 0.2 s 的时间以内, 而且 Mode1 和 Mode4 的错分样本大都被判断为 Mode3, 如图 15(a) 所示. 从 4.1 小节图 7 可以直观地看出起飞后 0.2 s, Mode1,

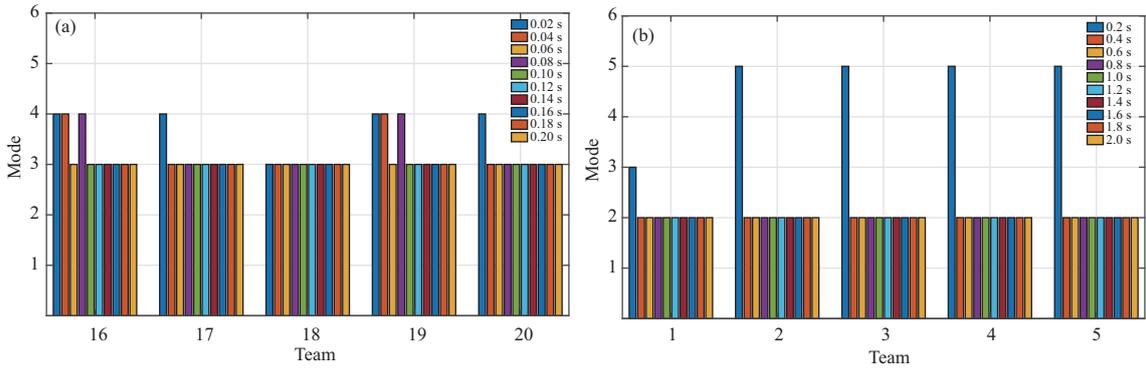


图 15 (a) Mode3 部分静态预测结果 (5 组数据前 10 个样本) 和 (b) Mode2 部分动态预测结果 (5 组数据前 10 个样本)

Figure 15 (a) Partial static prediction results of Mode3 (the first 10 samples of 5 groups of data) and (b) partial dynamic prediction results of Mode2 (the first 10 samples of 5 groups of data)

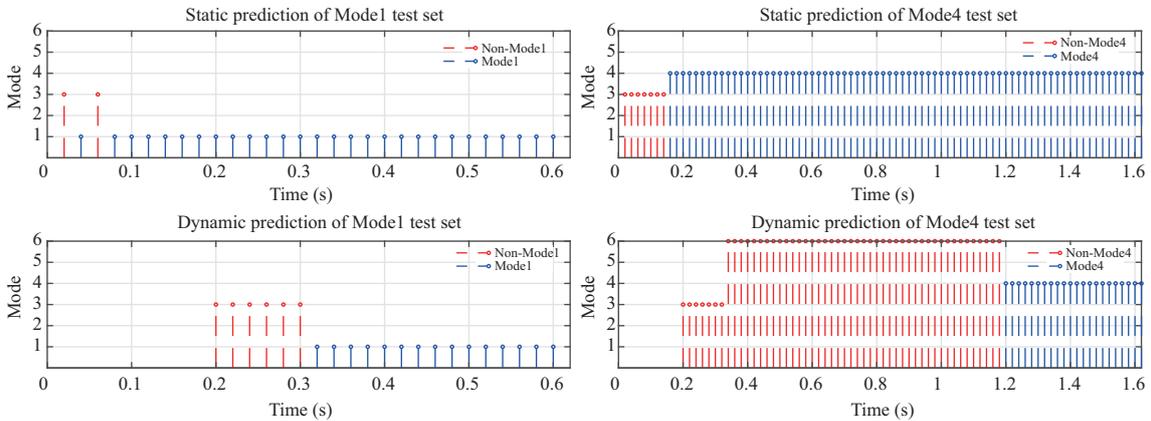


图 16 不同故障下 BP 和 LSTM 的辨识过程

Figure 16 Identification process of BP and LSTM of different faults

Mode3 和 Mode4 姿态曲线变化相似; 其余 4 个模式的错分样本绝大多数分布在前 5 个采样周期, 即 0.1 s 的时间以内. 可以认为, 在 0.2 s 以后, 静态分类器能够全部辨识正确.

(2) 在动态分类中, 所有分类错误样本集中在每组数据时间线的开始部分. 为了公平对比, 对 1 s 训练、0.2 s 测试的结果进行分析. 具体地, Mode1~Mode6 的错分样本绝大多数为每组的第一个样本, 即第一个 0.2 s 的时间段, 后续样本绝大多数分类正确, 如图 15(b) 所示. 可以认为, 在 0.2 s 以后, 动态分类器能够全部辨识这 5 类模式. Mode4 的测试性能较差, 与 Mode6 和 Mode3 有一部分混淆, 原因是三者均属于通道间极性错误, 且 Mode6 包含 Mode4 的故障模式, 但错分样本大部分集中在每组的前 6 个, 即 1.2 s 以后可以准确判断对应极性. 同时, Mode4 的测试性能一方面与样本有关, 一方面与分类器的设计有关, 即如果采用 0.2 s 训练、0.2 s 测试, 性能会有提高.

4.5 控制重构

将 BP 网络参数和 LSTM 网络参数闭合到飞行控制中, 当两种方法连续 10 个控制周期同时给出相同的故障模式时, 认为系统发生了该模式的故障, 实施故障重构. 重构的方法为: 根据辨识出的故障

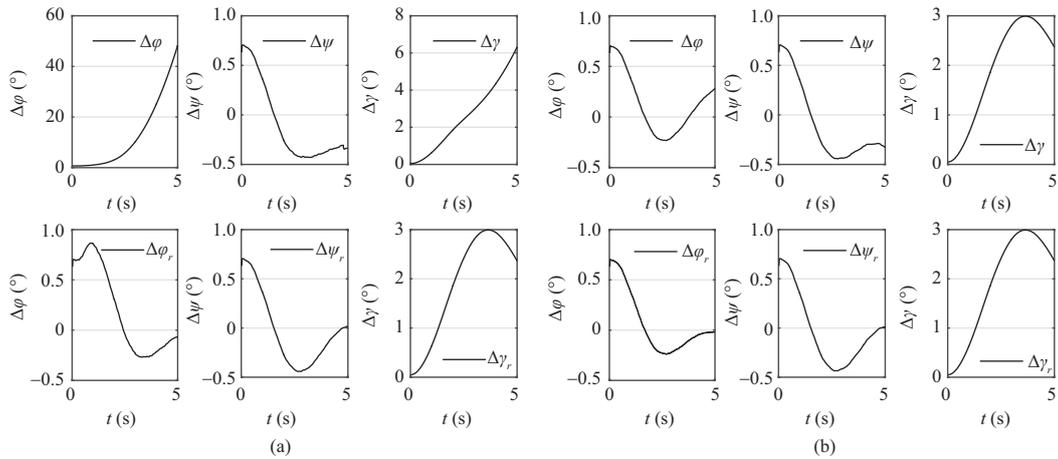


图 17 不重构和重构后的角偏差对比

Figure 17 Comparison of angular deviation between non-reconstruction and reconstruction. (a) Mode1; (b) Mode4

模式 (即指令对应关系) 调整姿控指令与伺服机构摆角的对应关系, 并据此发送控制指令。

由 2.2.1 小节介绍可知, 在正常工作状态下, 伺服机构的控制指令 δ^c 与伺服机构动作指令 δ^s 之间的对应关系为 $\delta^s = \mathbf{I} \cdot \delta^c$, 其中 \mathbf{I} 为单位矩阵. 在极性错误的情况下, 对应关系变为 $\delta^s = \mathbf{S} \cdot \delta^c$, 其中 \mathbf{S} 不再是单位矩阵, 而是由单位矩阵行列交换而来, 属于酉矩阵. 故障诊断的目的就是确认 \mathbf{S} 的形式. 在 \mathbf{S} 被辨识后, 硬件连接关系已无法更改, 因此将控制指令 δ^c 更新为 $\mathbf{S}^{-1} \cdot \delta^c$, 则

$$\delta^s = \mathbf{S} (\mathbf{S}^{-1} \cdot \delta^c) = \mathbf{I} \cdot \delta^c, \quad (14)$$

与正常控制需求相一致, 达到重构目的。

根据 4.4 小节的讨论, 本文选取两种分类方法中最慢辨识出故障的情形进行说明. 故以 Mode1 和 Mode4 故障为例, 静态和动态分类的辨识过程如图 16 所示。

将未能重构与实施控制重构的姿态偏差进行对比, 如图 17 所示. 可以看出, 发生 Mode1 故障时, 基于 BP 的静态分类方法在起飞后 0.06 s 就不再出现错误分类, 基于 LSTM 的动态分类方法则是在起飞 0.3 s 后不再出现错误分类. 综合两种方法, 当两种方法连续 10 个控制周期 (0.2 s) 均定位于 Mode1 时, 即在 0.5 s 时确认了故障模式, 此后进行控制重构, 姿态角偏差减小, 系统趋于稳定. 对比未采用重构的情况, 俯仰姿态角偏差快速增大到 40° 以上, 系统已开始发散. 若发生 Mode4 模式的故障时, 其对应两种可能的极性错误, 这两种无法区分; 若仿真中假设能够正确调整错位关系, 那么系统是可挽救的, 如图 17(b) 所示, 在 1.4 s 时确认了故障模式并完成重构。

5 小结

本文针对运载火箭推力矢量极性错误在线辨识与重构问题, 研究了基于 ANN 的解决方案. 共梳理了 6 种故障模式, 并考虑运载火箭运动模型不确定性和干扰等导致偏差的随机组合和最坏情况组合, 通过仿真生成了样本. 利用 ESO 辨识火箭飞行的实时角加速度, 以辅助故障模式的识别. 设计 BP 网络进行静态识别分析, 设计 LSTM 网络进行动态识别分析。

论文研究发现: 静态识别和动态识别方法均可及时识别错误. LSTM 动态方法提取了一段时间序列信息上的特征, 识别率更高; 但在首个时间序列信息完整获取之前, 无法作出判断, 其对故障发散的

影响需要关注. 在训练样本设计方面, 在直接输入可测量信息基础上, 增加基于模型估计 (ESO 方法) 的间接信息, 可以提高识别成功率. 将静态和动态识别结果融合, 可提高识别方案可靠性.

极性错误相当于模型结构与标称状态发生了突变, 其对系统的影响远远超过了参数偏差或不确定等所能涵盖的极限范畴; 同时, 无论是动力系统或执行机构均工作正常, 没有发生性能下降或停摆、关机等故障. 因此, 基于模型且主要考虑参数超差、性能退化或丧失等的容错控制方法无法有效应对这一问题, 尤其在有多种故障模式的情况下. 本文提出了一种有效的方法可用于实时控制.

此外, 对于本文提到的 Mode3 和 Mode4 这两种不可区分的故障模式, 后续考虑采用试错重构的方式, 或考虑增设新的故障错位形式 “s1, s4 错位且 s2, s3 错位”. 本文研究建立在运载火箭各设备正常工作的前提下, 否则将进一步增加问题的复杂度. 但随着传感器配置的不断完善, 在线健康监测将为故障诊断和控制重构提供基础, 从而可以应对更为多样性的突发情况, 提升飞行自主性.

参考文献

- 1 Gertler J. *Fault Detection and Diagnosis in Engineering Systems*. New York: Marcel Dekker, 1998
- 2 Korbicz J, Kosscielny J M, Kowalczyk Z, et al. *Fault Diagnosis: Models, Artificial Intelligence, Applications*. Berlin: Springer, 2004
- 3 Nelles O. *Nonlinear System Identification From Classical Approaches to Neural Networks and Fuzzy Models*. Berlin: Springer, 2001
- 4 Yu C M, Li T Y, Wang S, et al. Fault diagnosis technology of attitude control nozzle based on neural network. In: *Proceedings of the China Automation Congress (CAC2020)*, 2020. 8 [禹春梅, 李天涯, 王硕, 等. 基于神经网络的姿控喷管故障诊断技术. 见: 中国自动化大会 (CAC2020), 2020. 8]
- 5 Li N N, Xue W, Zhao S B, et al. Application of improved PSO-BP neural network in fault detection of liquid-propellant rocket engine. In: *Proceedings of IEEE International Conference on Mechatronics and Automation (ICMA)*, 2018
- 6 Sun C Z, Yan X D. Fault diagnosis of rocket engine based on neural network and evidence theory. *Astronaut Syst Engin Technol*, 2020, 4: 20–30 [孙成志, 闫晓东. 基于神经网络和证据理论的火箭发动机故障诊断. *宇航总体技术*, 2020, 4: 20–30]
- 7 Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors. *Nature*, 1986, 323: 533–536
- 8 Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, 9: 1735–1780
- 9 LeCun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1989, 1: 541–551
- 10 LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521: 436–444
- 11 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. 2014. ArXiv:1409.1556
- 12 He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016. 770–778
- 13 Redmon J, Farhadi A. YOLOv3: an incremental improvement. 2018. ArXiv:1804.02767
- 14 Jo J, Hwang S, Lee S, et al. Multi-mode LSTM network for energy-efficient speech recognition. In: *Proceedings of International SoC Design Conference (ISOCC)*, 2018. 133–134
- 15 Shu X, Zhang L, Sun Y, et al. Host-parasite: graph LSTM-in-LSTM for group activity recognition. *IEEE Trans Neural Netw Learn Syst*, 2021, 32: 663–674
- 16 Tang J, Shu X, Yan R, et al. Coherence constrained graph LSTM for group activity recognition. *IEEE Trans Pattern Anal Mach Intell*, 2022, 44: 636–647
- 17 Mao Z H, Gu Y X, Jiang B, et al. Incipient fault diagnosis for high-speed train traction systems via improved LSTM. *Sci Sin Inform*, 2021, 51: 997–1012 [冒泽慧, 顾彧行, 姜斌, 等. 基于改进 LSTM 的高速列车牵引系统微小渐变故障诊断. *中国科学: 信息科学*, 2021, 51: 997–1012]
- 18 Xie G, Shangguan A Q, Fei R, et al. Motion trajectory prediction based on a CNN-LSTM sequential model. *Sci China Inf Sci*, 2020, 63: 212207
- 19 Xu Y W. *Design and Analysis of Ballistic Missile and Launch Vehicle Control System*. Beijing: Aerospace Press, 1999 [徐延万. 弹道导弹, 运载火箭控制系统设计与分析. 北京: 宇航出版社, 1999]
- 20 Yang Y F, Li D, Tan S J, et al. A study of longitudinal-lateral-torsional coupling dynamics of launch vehicles. *Sci Sin*

- Tech, 2014, 44: 510–516 [杨云飞, 李东, 谭述君, 等. 运载火箭纵横扭大回路耦合动力学研究. 中国科学: 技术科学, 2014, 44: 510–516]
- 21 Zhong S, Huang Y, Guo L. A parameter formula connecting PID and ADRC. *Sci China Inf Sci*, 2020, 63: 192203
- 22 Jin H Y, Song J C, Lan W Y, et al. On the characteristics of ADRC: a PID interpretation. *Sci China Inf Sci*, 2020, 63: 209201
- 23 Han J Q. *Active Disturbance Rejection Control Technology*. Beijing: National Defense Industry Press, 2008. 243–287 [韩京清. 自抗扰控制技术. 北京: 国防工业出版社, 2008. 243–287]
- 24 Pan H, Wang G H, Shao M H, et al. Design and implementation of attitude control nozzle fault identification of launch vehicle based on ESO. *Missiles Space Vehicles*, 2021, 7: 72–75 [潘豪, 王光辉, 邵梦晗, 等. 基于 ESO 的运载火箭姿态喷管故障辨识设计及实现. 导弹与航天运载技术, 2021, 7: 72–75]

Autonomous reconfiguration of flight control under thrust vector polarity errors

Hao PAN¹, Ruiguang HU¹, Zhengyu SONG^{2,3*} & Menghan SHAO¹

1. *Beijing Aerospace Automatic Control Institute, Beijing 100854, China;*
 2. *China Academy of Launch Vehicle Technology, Beijing 100076, China;*
 3. *College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, China*
- * Corresponding author. E-mail: songzhengyu@zju.edu.cn

Abstract Online failure autonomous identification and control reconfiguration are important features of aerospace intelligent flights. Aiming at handling thrust vector polarity errors in the flights of launch vehicles, this paper studies the fault identification and autonomous reconstruction method based on artificial neural networks (ANNs). On the basis of clarifying the fault modes and combining the observation results of an extended state observer (ESO), a design method for learning/verifying samples through simulations and considering model uncertainties and disturbances is proposed. Then, a fault identification design is carried out based on a back propagation (BP) network and a long short term memory (LSTM) network, respectively. The simulation results show that both methods can meet the requirements for failure mode identification, which provide the basis for a stable and autonomous reconstruction under thrust vector polarity errors. By contrast, the LSTM network method based on the sliding window has more advantages and higher recognition accuracy.

Keywords polarity errors, autonomous reconstruction, extended state observer (ESO), back propagation (BP), long short term memory (LSTM)