

DOI: 10.13382/j.jemi.B2205798

# 基于 DaLSTM 组合模型的电动舵机故障诊断方法<sup>\*</sup>

张晓瑜<sup>1</sup> 邓佐青<sup>1</sup> 唐黎伟<sup>1</sup> 郭润夏<sup>1</sup> 吴 军<sup>2</sup>  
(1. 中国民航大学电子信息与自动化学院 天津 300300; 2. 中国民航大学航空工程学院 天津 300300)

**摘 要:**为了实现电动舵机工作过程中多种故障的一体化诊断,提出了一种基于双阶段注意力的长短期记忆网络(DaLSTM)组合模型的故障诊断方法。首先,将电动舵机的多源传感器信号作为输入,采用基于输入注意力和时间注意力的长短期记忆网络(LSTM)自适应提取原始多源传感器数据中的相关特征,并通过 DaLSTM 组合模型实现多源传感器的时间序列预测。其次,在故障诊断时间窗口内,以不同工作状态下 DaLSTM 组合模型预测值与采样值的差值最小为决策函数诊断电动舵机的故障类型。最后,利用公开的美国国家航空航天局(National Aeronautics and Space Administration, NASA)数据集进行时间序列预测和故障诊断实验,对故障类别的平均识别率达到了 98.76%,证明了该方法的有效性。

**关键词:**电动舵机;故障诊断;组合模型;长短期记忆网络

**中图分类号:** TP391.4; TN609      **文献标识码:** A      **国家标准学科分类代码:** D510.4

## Fault diagnosis method of electro-mechanical actuators based on DaLSTM combined model

Zhang Xiaoyu<sup>1</sup> Deng Zuoqing<sup>1</sup> Tang Liwei<sup>1</sup> Guo Runxia<sup>1</sup> Wu Jun<sup>2</sup>  
(1. College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China;  
2. College of Aeronautical Engineering, Civil Aviation University of China, Tianjin 300300, China)

**Abstract:** In order to realize the integrated diagnosis of multiple faults in the working process of electro-mechanical actuators (EMA), a fault diagnosis method of EMA based on dual-stage attention-based long short term memory (DaLSTM) combined model was proposed. Firstly, the multi-source sensor signal of the EMA is used as the input. The long short term memory (LSTM) neural network based on input attention and time attention is used to adaptively extract the relevant features in the original multi-source sensor data, and the time series prediction of multi-source sensors is realized by the DaLSTM combination model. Secondly, in the fault diagnosis time window, the minimum difference between the predicted value and the sampled value of the DaLSTM combination model under different states is used as the decision function to diagnose the fault type of EMA. Finally, time series prediction and fault diagnosis experiments are conducted using the public National Aeronautics and Space Administration (NASA) dataset, and the average recognition rate of fault categories reaches 98.76%, which proves the effectiveness of the proposed method.

**Keywords:** electro-mechanical actuators; fault diagnosis; combined model; LSTM

## 0 引 言

舵机作为飞机飞行控制系统的核心执行机构,负责控制方向舵、升降舵等主要舵面和缝翼、襟翼等辅助舵面的运行<sup>[1]</sup>,如果舵机发生故障,会直接影响飞行控制系统的稳定运行,造成巨大的经济损失和人员伤亡。近年来,

随着多电飞机技术在先进民航客机上的实际应用,电动舵机(electro-mechanical actuators, EMA)系统将在民航飞机上得到日益广泛的应用<sup>[2]</sup>。当前,波音 787 飞机的扰流板和起落架刹车已经开始使用电动舵机作为执行机构<sup>[3]</sup>。随着电动舵机需求的增加,其故障诊断的研究工作已成为学术界和工业界的热点问题。

针对电动舵机的故障诊断问题,国内外很多学者对

其进行研究。Avram 等<sup>[4]</sup>提出了一种基于非线性故障检测估计器和非线性自适应故障隔离估计器的舵机系统故障诊断方法,通过设计故障检测和隔离的自适应阈值增强故障诊断算法的鲁棒性。Jing 等<sup>[5]</sup>考虑电动舵机传感器信号之间的相关性,提出了一种基于改进长短期记忆网络(long short term memory, LSTM)的电动舵机故障检测方法,并利用滑动窗口法提高诊断模型在故障隔离中的性能。Pizzi 等<sup>[6]</sup>提出了一种基于概率神经网络的舵机故障诊断方法,能够在无界扰动的情況下实现舵机的故障诊断。Saravanakumar 等<sup>[7]</sup>提出了一种基于层次符号分析和粒子群优化卷积神经网络(hierarchical symbolic analysis and particle swarm optimization with a convolutional neural network, HPC)模型的电动舵机故障诊断方法,首先利用层次符号分析(hierarchical symbolic analysis, HSA)提取传感器信号的特征,然后利用粒子群优化卷积神经网络(particle swarm optimization with a convolutional neural network, PSO-CNN)模型实现对电动舵机的故障诊断。Wang 等<sup>[8]</sup>提出一种融合联合最大均值差异(joint maximum mean discrepancy, JMMD)和卷积神经网络(convolutional neural network, CNN)的自适应电动舵机故障诊断方法,通过减小标记源域与未标记目标域之间的域差,提高电动舵机故障诊断精度。

传统 LSTM 神经网络<sup>[9-13]</sup>捕捉时间序列特征的能力会随着时间序列长度的增加而逐渐降低,通过结合注意力机制<sup>[14]</sup>为传感器特征分配不同的权重,使其在长时间序列中获取良好的预测效果。基于 LSTM 的电动舵机故

障诊断算法一般是对单一模型进行分析,通过单传感器信号建立的模型没有充分考虑各传感器输入信号之间的相关性和同步性,使得预测性能极易受到环境干扰,难以获得高精度的故障诊断模型。

综上所述,本文提出了一种基于双阶段注意力的长短周期记忆网络(dual-stage attention-based long short term memory, DaLSTM)组合模型的电动舵机故障诊断方法。首先,采用输入注意力的 DaLSTM 编码器和时间注意力的 DaLSTM 解码器自适应地提取电压、电流、加速度等多源传感器数据的输入特征和相关编码层的隐藏状态;然后,在模型训练过程中,建立 DaLSTM 组合模型,利用组合模型在故障诊断时间窗口内进行多源传感器时间序列预测;最后以采样数据预测值与采样值的差值最小为决策函数进行故障分类,判别电动舵机的故障类型。

## 1 基于 DaLSTM 组合的故障诊断模型

给定  $K$  组电动舵机传感器时间序列数据,  $\mathbf{X}^{(k)} = (\mathbf{x}_{:,1}^{(k)}, \mathbf{x}_{:,2}^{(k)}, \dots, \mathbf{x}_{:,T}^{(k)}) = (\mathbf{x}_{1,:}^{(k)}, \mathbf{x}_{2,:}^{(k)}, \dots, \mathbf{x}_{N,:}^{(k)})^T \in \mathbb{R}^{N \times T}$ , 其中  $k \in \{1, 2, \dots, K\}$  为第  $k$  类故障,  $\mathbf{x}_{i,:}^{(k)} = (x_{i,1}^{(k)}, x_{i,2}^{(k)}, \dots, x_{i,T}^{(k)})^T \in \mathbb{R}^T$  为第  $i$  个传感器在第  $k$  类故障中采样长度为  $T$  的时间序列,  $\mathbf{x}_{:,t}^{(k)} = (x_{1,t}^{(k)}, x_{2,t}^{(k)}, \dots, x_{N,t}^{(k)})^T \in \mathbb{R}^N$  为第  $k$  类故障中  $N$  个传感器在  $t$  时刻的采样值,  $x_{i,t}^{(k)}, 1 \leq i \leq N, 1 \leq t \leq T$  为第  $k$  类故障中第  $i$  个传感器在  $t$  时刻的采样值。DaLSTM 组合的故障诊断模型结构如图 1 所示。



图 1 DaLSTM 组合的故障诊断模型结构图

Fig. 1 Structure diagram of DaLSTM combined fault diagnosis model

由图 1 可知,  $DaLSTM_i^{(k)}$  为第  $k$  类故障中第  $i$  个传感器的预测模型, 给定目标序列为  $(y_{i,1}^{(k)}, y_{i,2}^{(k)}, \dots, y_{i,T-1}^{(k)})$ ,  $y_{i,t}^{(k)} \in \mathbb{R}$ , 预测输出  $\tilde{y}_{i,T}^{(k)} = DaLSTM_i^{(k)}(y_{i,1}^{(k)}, \dots, y_{i,T-1}^{(k)}, \mathbf{x}_{:,1}^{(k)}, \dots, \mathbf{x}_{:,T}^{(k)})^T$ , 其中  $\tilde{y}_{i,T}^{(k)}$  为第  $k$  类故障中第  $i$  个传感器在采样长度为  $T$  的预测值。DaLSTM 组合模型以  $K$  组电动机传感器信号为输入, 采用  $N \times K$  个 DaLSTM 子模型自适应提取多源传感器数据的相关特征和隐藏状态; 在故障诊断时间检测窗口内, 利用不同故障下预测值与采样值之间差值最小为决策函数识别电动舵机的故障类型, 并给出诊断结果。

### 1.1 DaLSTM 编码器

DaLSTM 编码器采用输入注意力自适应提取各传感器间的数据特征, 并根据注意力值的大小分配权重更新输入信号, 其计算公式如式(1)~(3)所示<sup>[15-16]</sup>:

$$e_{i,t}^{(k)} = \mathbf{v}_e^{(k)T} * \tanh(\mathbf{W}_e^{(k)} * \mathbf{h}_{t-1}^{(k)} + \mathbf{U}_e^{(k)} * \mathbf{x}_{i,t}^{(k)} + \mathbf{b}_e^{(k)}) \quad (1)$$

$$\alpha_{i,t}^{(k)} = \frac{\exp(e_{i,t}^{(k)})}{\sum_{j=1}^N \exp(e_{j,t}^{(k)})} \quad (2)$$

$$\tilde{\mathbf{x}}_t^{(k)} = (\alpha_{1,t}^{(k)} x_{1,t}^{(k)}, \alpha_{2,t}^{(k)} x_{2,t}^{(k)}, \dots, \alpha_{N,t}^{(k)} x_{N,t}^{(k)})^T \quad (3)$$

其中,  $\mathbf{h}_{t-1}^{(k)} \in \mathbb{R}^p$  为第  $k$  类故障在  $t-1$  时刻编码器 LSTM 神经网络的隐藏状态,  $p$  为编码器 LSTM 神经网络隐藏层神经元的数量。  $\mathbf{v}_e^{(k)}, \mathbf{b}_e^{(k)} \in \mathbb{R}^T, \mathbf{W}_e^{(k)} \in \mathbb{R}^{T \times p}$  和  $\mathbf{U}_e^{(k)} \in \mathbb{R}^{T \times T}$  为模型通过训练学习的参数。  $\alpha_{i,t}^{(k)}$  为第  $k$  类故障中第  $i$  个传感器在  $t$  时刻的注意力权重,  $\tilde{\mathbf{x}}_t^{(k)}$  为输入信号通过输入注意力加权后得到的值。

$t$  时刻编码器的隐藏状态  $\mathbf{h}_t^{(k)}$  采用 LSTM 单元进行更新, 如式(4)所示:

$$\mathbf{h}_t^{(k)} = LSTM(\mathbf{h}_{t-1}^{(k)}, \tilde{\mathbf{x}}_t^{(k)}) \quad (4)$$

其中,  $LSTM(\cdot, \cdot)$  为标准 LSTM 单元。

### 1.2 DaLSTM 解码器

DaLSTM 解码器采用时间注意力在所有时间步中自适应选择相关编码器的隐藏状态信息, 其计算公式如式(5)~(7)所示<sup>[15-16]</sup>:

$$\ell_{o,t}^{(k)} = \mathbf{v}_\ell^{(k)T} * \tanh(\mathbf{W}_\ell^{(k)} * \mathbf{d}_{t-1}^{(k)} + \mathbf{U}_\ell^{(k)} * \mathbf{h}_o^{(k)}), 1 \leq o \leq T \quad (5)$$

$$\beta_{o,t}^{(k)} = \frac{\exp(\ell_{o,t}^{(k)})}{\sum_{m=1}^T \exp(\ell_{m,t}^{(k)})} \quad (6)$$

$$\mathbf{c}_t^{(k)} = \sum_{o=1}^T \beta_{o,t}^{(k)} \mathbf{h}_o^{(k)} \quad (7)$$

其中,  $\mathbf{d}_{t-1}^{(k)} \in \mathbb{R}^q$  为第  $k$  类故障下  $t-1$  时刻解码器 LSTM 神经网络的隐藏状态,  $q$  为解码器 LSTM 神经网络中隐藏层神经元的数量。  $\mathbf{v}_\ell^{(k)} \in \mathbb{R}^p, \mathbf{W}_\ell^{(k)} \in \mathbb{R}^{p \times q}$  和  $\mathbf{U}_\ell^{(k)}$

$\in \mathbb{R}^{p \times p}$  为模型通过训练学习的参数。  $\beta_{o,t}^{(k)}$  为第  $k$  类故障下  $t$  时刻的注意力权重,  $\mathbf{c}_t^{(k)}$  为第  $k$  类故障下  $t$  时刻注意力加权后的向量。

$t$  时刻解码器的隐藏状态  $\mathbf{d}_t^{(k)}$  采用 LSTM 单元进行更新, 如式(8)所示:

$$\mathbf{d}_t^{(k)} = LSTM(\mathbf{d}_{t-1}^{(k)}, [\mathbf{y}_{i,t-1}^{(k)}; \mathbf{c}_{t-1}^{(k)}]) \quad (8)$$

其中,  $[\mathbf{y}_{i,t-1}^{(k)}; \mathbf{c}_{t-1}^{(k)}] \in \mathbb{R}^{p+1}$  为  $\mathbf{y}_{i,t-1}^{(k)}$  与  $\mathbf{c}_{t-1}^{(k)}$  的拼接矩阵。

对于 DaLSTM 组合模型, 其目标序列预测值  $\tilde{\mathbf{y}}_{i,T}^{(k)}$  的公式如式(9)所示:

$$\tilde{\mathbf{y}}_{i,T}^{(k)} = DaLSTM_i^{(k)}(y_{i,1}^{(k)}, \dots, y_{i,T-1}^{(k)}, \mathbf{x}_{:,1}^{(k)}, \dots, \mathbf{x}_{:,T}^{(k)})^T = \mathbf{v}_w^{(k)T} * (\mathbf{W}_w^{(k)} [\mathbf{c}_T^{(k)}; \mathbf{d}_T^{(k)}] + \mathbf{b}_w^{(k)}) + \mathbf{b}_v^{(k)} \quad (9)$$

其中,  $[\mathbf{c}_T^{(k)}; \mathbf{d}_T^{(k)}] \in \mathbb{R}^{p+q}$  为  $\mathbf{c}_T^{(k)}$  与  $\mathbf{d}_T^{(k)}$  的拼接矩阵,  $\mathbf{W}_w^{(k)} \in \mathbb{R}^{q \times (p+q)}, \mathbf{b}_w^{(k)} \in \mathbb{R}^q, \mathbf{v}_w^{(k)} \in \mathbb{R}^q$  和偏置  $\mathbf{b}_v^{(k)} \in \mathbb{R}$  为模型通过训练学习的参数。

### 1.3 决策函数

在故障诊断时间检测窗口内, 利用 DaLSTM 组合模型得到的预测值, 与采样值的误差最小来构建电动舵机的故障诊断决策函数, 如式(10)所示:

$$f(k) = \arg \min_k \sqrt{\sum_{i=1}^N \sum_{\lambda=1}^H (\tilde{\mathbf{y}}_{i,T+\lambda}^{(k)} - x_{i,T+\lambda})^2} \quad (10)$$

其中,  $H$  为检测窗口长度,  $x_{i,T+\lambda}$  为第  $i$  个传感器在  $T + \lambda$  时刻的采样值,  $\tilde{\mathbf{y}}_{i,T+\lambda}^{(k)}$  为  $DaLSTM_i^{(k)}$  在  $T + \lambda$  时刻的预测值,  $f(k)$  表示 DaLSTM 组合模型的诊断结果。

## 2 实验验证与结果分析

### 2.1 实验数据与评价指标

本文实验主要包括时间序列预测实验和电动舵机故障诊断实验两部分。在时间序列预测实验中, 以不同故障类型下的多个传感器参数作为预测目标, 通过与各种基础模型的实验对比, 验证 DaLSTM 组合模型的预测性能。在故障诊断实验中, 通过故障诊断时间窗口的影响分析、决策函数的有效性分析以及与其他模型的对比分析, 验证 DaLSTM 组合模型的故障诊断能力。

本文所有仿真实验的运行环境为 Windows10, 计算机配置为 Intel(R) Core(TM) i7-10700 CPU@2.90 GHz, 16 GB 内存, 深度学习框架为 PyTorch<sup>[17]</sup>。

#### 1) EMA 数据集

选取美国国家航空航天局 Ames 研究中心采集的电动舵机数据集<sup>[18]</sup>作为实验数据, 在所有实验中均选取位置、电流、电压、温度和负载等 12 个传感器信号作为模型输入, 如表 1 所示。

表 1 电动舵机传感器信号

Table 1 The signal of EMA sensors

| 电动舵机传感器信号 |                     |    |                     |
|-----------|---------------------|----|---------------------|
| 1         | Actuator Z position | 7  | Motor Y voltage     |
| 2         | Measured load       | 8  | Motor X temperature |
| 3         | Motor X current     | 9  | Motor Y temperature |
| 4         | Motor Y current     | 10 | Motor Z temperature |
| 5         | Motor Z current     | 11 | Nut X temperature   |
| 6         | Motor X voltage     | 12 | Nut Y temperature   |

在实验中,电动舵机的工作状态共分为 5 类,包括正常、阻塞故障、破损故障、传感器故障和电机故障。设定每种故障的样本点为 1 500 个,其中训练数据样本采样点为 1 000 个,测试数据样本采样点为 500 个,如表 2 所示。

表 2 实验数据集设定

Table 2 The setting of experimental dataset

| 故障类型  | 训练集   | 测试集 |
|-------|-------|-----|
| 正常    | 1 000 | 500 |
| 阻塞故障  | 1 000 | 500 |
| 破损故障  | 1 000 | 500 |
| 传感器故障 | 1 000 | 500 |
| 电机故障  | 1 000 | 500 |

2) 评价指标

时间序列预测实验中采用均方根误差 (root mean squared error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 作为衡量不同方法有效性的评价指标。计算公式如式 (11) ~ (12) 所示:

$$RMSE = \sqrt{\frac{1}{H} \sum_{\lambda=1}^H (\tilde{y}_{i,T+\lambda}^{(k)} - x_{i,T+\lambda})^2} \quad (11)$$

$$MAE = \frac{1}{H} \sum_{\lambda=1}^H |\tilde{y}_{i,T+\lambda}^{(k)} - x_{i,T+\lambda}| \quad (12)$$

故障诊断实验采用准确率和  $\kappa$  系数作为评估实验结果的指标。准确率的计算公式如式 (13) 所示:

$$p_{acc} = \frac{Num_{Correct}}{Num_{All}} \times 100\% \quad (13)$$

其中,  $Num_{Correct}$  为分类正确的实验次数,  $Num_{All}$  为总共实验次数。

$\kappa$  系数是用于一致性检验的指标,对于分类问题,一致性就是模型预测结果和实际分类结果是否一致<sup>[19]</sup>。假设每一类故障的训练样本分别为  $Num_{Fault1}, Num_{Fault2}, \dots, Num_{Faultk}$ , 而预测出来的每一类的测试样本个数分别为  $Num_{Fault1}^{Pred}, Num_{Fault2}^{Pred}, \dots, Num_{Faultk}^{Pred}$ 。  $\kappa$  系数的计算公式如式 (14) ~ (15) 所示:

$$\kappa = \frac{p_{acc} - p_e}{1 - p_e} \quad (14)$$

$$p_e = \frac{\sum_{i=1}^K Num_{Fault_i} \cdot Num_{Fault_i}^{Pred}}{(\sum_{j=1}^K Num_{Fault_j})^2} \quad (15)$$

$\kappa$  系数的一致性程度分为 5 个不同区间,如表 3 所示。

表 3  $\kappa$  系数的一致性等级分区

Table 3 Level partition of  $\kappa$  coefficient

| Kappa 系数区间  | 一致性程度  |
|-------------|--------|
| 0.00 ~ 0.20 | 极低     |
| 0.21 ~ 0.40 | 一般     |
| 0.41 ~ 0.60 | 中等     |
| 0.61 ~ 0.80 | 高度     |
| 0.81 ~ 1.00 | 几乎完全一致 |


2.2 实验验证

1) 时间序列预测实验


为了验证 DaLSTM 组合模型在电动舵机传感器预测方面的性能,选择了 LSTM、Encoder-Decoder<sup>[20]</sup>、Input-Attn (encoder-decoder with input-attention)、Temporal-Attn (encoder-decoder with temporal-attention)<sup>[21]</sup> 等 4 种模型与 DaLSTM 组合模型进行性能比较。为了得到实验的最优结果,避免偶然性,提高实验的可信度,通过网格搜索法确认 4 种模型的参数,其主要参数设定如下:输入的传感器采样数据长度  $T = 20$ ,隐藏层神经元的数量  $p = q = 128$ ,采用均方误差作为损失函数,神经网络优化器为 Adam,学习率设定为 0.001。所有模型都进行 10 次实验,取 10 次结果的平均值代表模型的真实性能。

以 5 种工作状态下 Motor Y voltage 参数为例, DaLSTM 组合模型的预测值和采样值的统计分布如图 2 所示。


从图 2 结果可以清晰发现, DaLSTM 组合模型在正常状态和故障状态下的时间序列预测结果与采样值无显著差异,且统计分布非常相近,证明 DaLSTM 组合模型故障诊断算法具有良好的电动舵机时间序列预测性能。




(a) 正常状态的预测结果  
(a) Predicted results of normal state




(b) 正常状态下Motor Y voltage的统计分布  
(b) Statistical distribution of Motor Y voltage under normal state




(f) 电机故障下Motor Y voltage的统计分布  
(f) Statistical distribution of Motor Y voltage under motor fault




(c) 阻塞故障的预测结果  
(c) Prediction results of jam fault




(g) 传感器故障的预测结果  
(g) Prediction results of sensor fault




(d) 阻塞故障下Motor Y voltage的统计分布  
(d) Statistical distribution of Motor Y voltage under jam fault




(h) 传感器故障下Motor Y voltage的统计分布  
(h) Statistical distribution of Motor Y voltage under sensor fault



(e) 电机故障的预测结果  
(e) Prediction results of motor fault



(i) 破损故障的预测结果  
(i) Prediction results of spall fault



(j) 破损故障下Motor Y voltage的统计分布

(j) Statistical distribution of Motor Y voltage under spall fault

图 2 DaLSTM 组合模型的预测结果和统计分布


Fig. 2 Prediction results and statistical distribution of DaLSTM combined model

以 5 种工作状态下 Motor Y voltage 参数为例,统计 RMSE 和 MAE 两个评价指标,如表 4、图 3 所示(图 3 为


表 4 不同状态下 RMSE、MAE 比较结果

Table 4 Comparison results of RMSE and MAE under different states


| Model         | 正常状态    |         | 阻塞故障    |         | 破损故障    |         | 传感器故障   |         | 电机故障    |         |
|---------------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|
|               | RMSE    | MAE     | RMSE    | MAE     | RMSE    | MAE     | RMSE    | MAE     | RMSE    | MAE     |
| LSTM          | 0.551 3 | 0.374 0 | 0.341 4 | 0.691 7 | 0.425 6 | 0.543 4 | 0.686 9 | 0.401 6 | 0.737 4 | 0.385 6 |
| Encode-Decode | 0.385 6 | 0.324 0 | 0.384 9 | 0.301 1 | 0.158 3 | 0.130 6 | 0.400 2 | 0.368 1 | 0.410 5 | 0.343 3 |
| Input-Attn    | 0.383 2 | 0.322 1 | 0.429 4 | 0.306 1 | 0.153 1 | 0.129 1 | 0.409 7 | 0.377 2 | 0.404 9 | 0.337 3 |
| Temporal-Attn | 0.427 2 | 0.381 0 | 0.382 1 | 0.272 1 | 0.511 1 | 0.494 7 | 0.670 2 | 0.544 5 | 0.260 1 | 0.225 6 |
| DaLSTM        | 0.358 9 | 0.321 0 | 0.246 9 | 0.189 1 | 0.150 1 | 0.119 1 | 0.264 6 | 0.218 9 | 0.235 7 | 0.218 7 |




(a) 传感器故障下RMSE  
(a) RMSE of sensor fault



(b) 传感器故障下MAE  
(b) MAE of sensor fault



(c) 电机故障下RMSE  
(c) RMSE of motor fault



(d) 电机故障下MAE  
(d) MAE of motor fault

图 3 两种故障下 RMSE 和 MAE 结果

Fig. 3 RMSE and MAE under two faults

表 4 中传感器故障和电机故障两种工作状态下的评价指标数据)。

从表 4 和图 3 中可以清晰发现,DaLSTM 组合模型在不同工作状态中的 MAE 和 RMSE 均为最小。在传感器故障下,DaLSTM 组合模型的 MAE 比 LSTM 减少了 0.182 7,比 Encode-Decode 模型减少了 0.149 2,比 Input-Attn 模型减少了 0.158 3,比 Temporal-Attn 模型减少了 0.325 6。在电机故障下,DaLSTM 组合模型的 RMSE 比 LSTM 模型减少了 0.501 7,比 Encode-Decode 模型减少了 0.174 8,比 Input-Attn 模型减少了 0.169 2,比 Temporal-Attn 模型减少了 0.024 4。

2)故障诊断实验

(1)故障诊断窗口对电动舵机故障诊断的影响

为验证故障诊断窗口长度  $H$  对故障诊断精度的影响,设定检测窗口长度  $H = \{1, 3, 5, 7, 11, 15, 20, 30\}$ ,在不同故障诊断窗口长度下,统计 5 种工作状态下的准确率均值和  $\kappa$  系数均值,如图 4 所示。




图 4 不同故障诊断窗口的诊断性能

Fig. 4 Diagnosis performance of different fault diagnosis windows

图 4 结果表明,在故障诊断窗口  $H=1$  时, DaLSTM 组合的故障诊断模型的准确率均值为 95.16%,  $\kappa$  系数均值为 0.950。随着故障诊断窗口长度的增加,故障诊断准确率进一步提升,当  $H \geq 11$  时,故障诊断准确率均值为 100%,  $\kappa$  系数均值为 1。

(2) 决策函数的有效性分析

为了直观地展示决策函数对 DaLSTM 组合故障诊断模型的影响,记录故障诊断实验中 5 种工作状态对应的预测值与采样值的差值即决策误差,如图 5 所示。




图 5 不同工作状态的决策误差

Fig. 5 Decision errors of different states



图 5 结果表明,5 种工作状态下的决策误差在对应工作状态下均为最小。以正常状态的决策误差为例,正常状态比阻塞故障低 1.059 3,比破损故障低 0.712 8,比传感器故障低 0.400 8,比电机故障低 0.539 3,直观证明了 DaLSTM 组合故障诊断模型的决策函数可以有效区分电动机各种故障类型。

(3) 对比实验

为了证明 DaLSTM 组合故障诊断模型的有效性,选取 LSTM 模型和支持向量机 (support vector machine, SVM) 模型<sup>[22-23]</sup>作为基线模型进行故障诊断效果分析。

在 SVM 故障诊断模型中,训练样本采样点数目为 1 000,测试样本采样点数目为 500,故障诊断窗口长度为 20;在 LSTM 故障诊断模型中,训练样本采样点数目为 1 000,测试样本采样点数目为 500,故障诊断窗口长度为 20;在 DaLSTM 组合故障诊断模型中,训练样本采样点数目为 1 000,测试样本采样点数目为 500,故障诊断窗口长度分别为 5 和 11。SVM、LSTM 和 DaLSTM 组合故障诊断的混淆矩阵如图 6 所示。

图 6 结果表明, DaLSTM 组合故障诊断模型 ( $H=5$ ) 的平均故障诊断准确率为 97.3%, SVM 模型的平均故障诊断准确率为 97.4%, LSTM 模型的平均故障诊断准确率为 95.7%。由此可见, DaLSTM 组合故障诊断模型在故障诊断方面有良好的性能。随着故障诊断窗口长度的增加, DaLSTM 组合故障诊断模型的故障诊断性能逐步提高。当故障诊断窗口  $H=11$  时,其平均故障诊断准确率达到 100%,当  $H > 11$  时,诊断结果保持 100%,故障诊断效果优越于 LSTM 模型和 SVM 模型。






图 6 不同分类模型的混淆矩阵

Fig. 6 Confusion matrix of different classification models

3 结论

本文提出了一种基于 DaLSTM 组合模型的电动舵机故障诊断方法,引入全新的决策函数,自动对故障进行分类。不同于单一模型的电动舵机故障诊断方法, DaLSTM 组合模型无需考虑外部环境因素即可自适应提取时间序列特征。在故障诊断窗口内,利用不同故障条件下 DaLSTM 组合模型预测值与采样值差值最小为决策函数,自动对电动舵机故障进行分类。通过分析得到如下结论:

1) DaLSTM 组合算法可以实现较为优异的时间序列预测。DaLSTM 组合模型在不同工作状态下的  $RMSE$  和  $MAE$  的平均值,比 LSTM 模型减少 0.297 3 和 0.265 9,比

Encode-Decode 模型减少 0.096 7 和 0.080 1,比 Input-Attn 模型减少 0.104 8 和 0.081,比 Temporal-Attn 模型减少 0.198 9 和 0.170 2。

2) DaLSTM 组合的故障诊断算法在故障诊断窗口  $H = 11$  时,故障诊断准确率达到 100%,比 LSTM 模型提高 4.3%,比 SVM 模型提高 2.6%。

由于没有考虑微小故障对 DaLSTM 组合故障诊断模型的影响,其故障诊断结果可能存在偏差,在后期的研究中,考虑将微小故障引入 DaLSTM 组合故障诊断模型中,提升电动舵机的故障诊断性能。

参考文献

[ 1 ] AREERAK K N, WU T, BOZHKO S, et al. Aircraft power system stability study including effect of voltage control and actuators dynamic [ J ]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47 ( 4 ): 2574-2589.

[ 2 ] 曹洪涛, 陈锋, 陈佳. 集成一体化舵机技术研究综述[ J ]. 舰船科学技术, 2017, 39(13): 1-7.

CAO H T, CHEN F, CHEN J. Review of the research on integrated steering gear technology[ J ]. Ship Science and Technology, 2017, 39(13): 1-7.

[ 3 ] FU J, MARE J C, FU Y. Modelling and simulation of flight control electromechanical actuators with special focus on model architecting, multidisciplinary effects and power flows[ J ]. Chinese Journal of Aeronautics, 2017, 30(1): 47-65.

[ 4 ] AVRAM R C, ZHANG X D, MUSE J A. Quadrotor actuator fault diagnosis and accommodation using nonlinear adaptive estimators[ J ]. IEEE Transactions on Control Systems Technology, 2017, 25(6): 1-8.

[ 5 ] YANG J, GUO Y Q, ZHAO W L. Long short-term memory neural network based fault detection and isolation for electro-mechanical actuators [ J ]. Neurocomputing, 2019, 360(3): 85-96.

[ 6 ] PIZZI N, KOFMAN E J, SERON M, et al. Actuator fault diagnosis using probabilistic ultimate bounds[ J ]. IEEE Latin America Transactions, 2016, 14(6): 2550-2555.

[ 7 ] SARAVANAKUMAR R, KRISHNARAJ N, VENKATRAMAN S, et al. Hierarchical symbolic analysis and particle swarm optimization based fault diagnosis model for rotating machineries with deep neural networks[ J ]. Measurement, 2021, 171(11): 108771.

[ 8 ] WANG J Y, ZHANG Y J, LUO C, et al. Deep learning domain adaptation for electro-mechanical actuator fault diagnosis under variable driving waveforms [ J ]. IEEE Sensors Journal, 2022, 22(11): 10783-10793.

[ 9 ] WANG Z M, ZHANG L, DING Z M. Hybrid time-aligned and context attention for time series prediction [ J ]. Knowledge-Based Systems, 2020, DOI: 10.1016/j.

- knosys. 2020. 105937.
- [10] 李振鹏,董明利,于明鑫,等. Encoder-Decoder LSTM 网络的输电母排触点温度预测方法[J]. 电子测量与仪器学报, 2022, 36(4):32-39.  
LI ZH P, DONG M L, YU M X, et al. Transmission busbar contact temperature prediction method for Encoder-Decoder LSTM networks [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(4): 32-39.
- [11] 魏昱洲,许西宁. 基于 LSTM 长短期记忆网络的超短期风速预测[J]. 电子测量与仪器学报, 2019, 33(2): 64-71.  
WEI Y ZH, XU X N. Ultra-short-term wind speed prediction model using LSTM networks [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 64-71.
- [12] 谭峰,李成南,萧红,等. 基于 LSTM 循环神经网络的数控机床热误差预测方法[J]. 仪器仪表学报, 2020, 41(9): 79-87.  
TAN F, LI CH N, XIAO H, et al. A thermal error prediction method for CNC machine tool based on LSTM recurrent neural network [J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 79-87.
- [13] 姚栋方,吴瀛,罗磊,等. 基于深度学习的短期电力负荷预测[J]. 国外电子测量技术, 2020, 39(1): 44-48.  
YAO D F, WU Y, LUO L, et al. Short-term load forecasting based on deep learning algorithm[J]. Foreign Electronic Measurement Technology, 2020, 39(1): 44-48.
- [14] 谢锦阳,姜媛媛,王力. 基于 RA-LSTM 的轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(6): 213-219.  
XIE J Y, JIANG Y Y, WANG L. RA-LSTM based bearing fault diagnosis method[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 213-219.
- [15] QIN Y, SONG D J, CHENG H F, et al. A dual-stage attention-based recurrent neural network for time series prediction[C]. International Joint Conference on Artificial Intelligence (IJCAI). AAAI Press, 2017: 2627-2633.
- [16] FENG S, FENG Y. A dual-staged attention based conversion-gated long short term memory for multivariable time series prediction [J]. IEEE Access, 2022, 10: 368-379.
- [17] PASZKE A, GROSS S, MASSA F, et al. Pytorch: An imperative style, high-performance deep learning library[J]. Advances in Neural Information Processing Systems, 2019, 32.
- [18] BALABAN E, SAXENA A, NARASIMHAN S, et al. Prognostic health-management system development for electromechanical actuators [J]. Journal of Aerospace Information Systems, 2015, 12(3): 329-344.
- [19] 徐树良,王俊红. 基于 Kappa 系数的数据流分类算法[J]. 计算机科学, 2016, 43(12): 173-178.  
XU SH L, WANG J H. Data stream classification algorithm based on Kappa coefficient [J]. Computer Science, 2016, 43(12): 173-178.
- [20] BAHDANA D, CHO K H, BENGIO Y. Neural machine translation by jointly learning to align and translate[C]. 3rd International Conference on Learning Representations, ICLR 2015, 2015.
- [21] DU S D, LI T R, YANG Y, et al. Multivariate time series forecasting via attention-based encoder-decoder framework[J]. Neurocomputing, 2020, 388: 269-279.
- [22] 叶杨,徐志伟,陈仁文,等. 基于 KPCA 和 SVM 的直升机旋翼桨叶损伤源定位[J]. 电子测量与仪器学报, 2020, 34(4): 118-123.  
YE Y, XU ZH W, CHEN R W, et al. Damage source location of helicopter rotor blade based on KPCA and SVM [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(4): 118-123.
- [23] 刁宁昆,马怀祥,王金师,等. 基于 MPE 与 PSO-SVM 的滚动轴承故障诊断[J]. 电子测量技术, 2021, 44(21): 44-48.  
DIAO N K, MA H X, WANG J SH, et al. Fault diagnosis of rolling bearing based on MPE and PSO-SVM [J]. Electronic Measurement Technology, 2021, 44(21): 44-48.

## 作者简介



张晓瑜(通信作者),2003 年于中国民航航空学院获得学士学位,2008 年于中国民航大学获得硕士学位,现为中国民航大学副教授,主要研究方向为机载设备故障诊断与寿命预测。

E-mail: xy\_zhang@cauc.edu.cn

**Zhang Xiaoyu** (Corresponding author) received her B. Sc. degree from Civil Aviation University of China in 2003, M. Sc. degree from Civil Aviation University of China in 2008, respectively. Now she is an associate professor in Civil Aviation University of China. Her main research interests include fault diagnosis and life prediction of airborne equipment.



邓佐青,2021 年于西安航空学院获得学士学位,现为中国民航大学在读研究生,主要研究方向为机载设备故障诊断。

E-mail:1719989996@qq.com

**Deng Zuoqing** received her B. Sc. degree from Xi'an Aeronautical Institute in 2021. Now she is a M. Sc. candidate in Civil Aviation University of China. Her main research interest includes Fault diagnosis of airborne equipment.