

# 飞机起落架液压收放系统的故障程度诊断

丰赢政,赵东标,申珂楠,赵世超  
(南京航空航天大学 机电学院,江苏 南京 210016)

**摘要:**飞机起落架液压收放系统故障程度正确诊断可帮助飞行员及时采取行动应对不同程度的故障,避免人员和财产受到损失。针对飞机起落架液压收放系统故障样本少,故障数据时域上的高相关性,提出一种混合条件变分自编码网络和双向长短期记忆神经网络的故障程度诊断模型。建立某型飞机起落架液压收放系统仿真模型并植入不同程度故障,提取故障数据;将故障数据归一化并训练出 CVAE 生成模型;利用 BLSTM 在时域上的双向学习能力,构建 CVAE-BLSTM 混合模型,诊断飞机起落架液压收放系统的故障程度。与其他算法相比,CVAE-BLSTM 具有高准确率与强泛化能力,可对飞机起落架液压收放系统故障程度进行有效诊断。  
**关键词:**飞机起落架;液压收放系统;条件变分自编码;双向长短期记忆神经网络;故障程度诊断  
**中图分类号:**V245.1;TP206+.3 **文献标志码:**B **文章编号:**1671-5276(2022)01-0217-04

## Diagnosis of Failure Degree of Hydraulic Retractable System of Aircraft Landing Gear Based on CVAE-BLSTM

FENG Yingzheng, ZHAO Dongbiao, SHEN Kenan, ZHAO Shichao

(College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

**Abstract:** The correct diagnosis of failure degree of the hydraulic retractable system of aircraft landing gear can help pilots to take timely actions to deal with different degrees of faults in avoidance of the loss of personnel and property. In the light of few failure samples of the hydraulic retractable system of aircraft landing gear and the high correlation of the failure data in the time domain, a hybrid fault degree diagnosis model integrating the conditional variational autoencoder and the bidirectional long short-term memory is proposed. A simulation model of the hydraulic retractable system of aircraft landing gear is built to insert different degrees of faults, and extract fault data. The fault data is normalized and trained to create the CVAE generation model. BLSTM is used to learn bidirectional relation of fault data, and the hybrid model of CVAE-BLSTM is constructed to diagnose the failure degree of the hydraulic retractable system of the aircraft landing gear. Compared with other algorithms, the results show that CVAE-BLSTM has high accuracy and strong generalization ability, with which the failure degree of the hydraulic retractable system of aircraft landing gear can be diagnosed effectively.

**Keywords:** aircraft landing gear; hydraulic retractable system; conditional variational autoencoder; bidirectional long short-term memory; fault diagnosis

## 0 引言

起落架液压收放系统是飞机的重要组成部分,其性能的好坏直接影响飞机的起降安全。从美国国家航空航天局(NASA)发布的报告中分析,起落架系统故障在所有飞机故障中占比较高,而与收放系统相关的故障占到起落架系统故障的35%左右<sup>[1]</sup>。从飞机液压系统故障诊断的方法层面看,对故障的诊断大多数停留在依靠经验和地面试验上<sup>[2]</sup>。目前随着人工智能的成熟,神经网络在故障诊断方面的应用得到了飞速发展。林嘉琦等在航空发动机气路故障诊断中运用深度信念网络提升故障诊断的准确率<sup>[3]</sup>。金棋在直升机行星齿轮箱故障诊断中利用条件变分自编码网络(conditional variational autoencoder, CVAE)捕捉原始样本的分布来生成大量有效样本,以此提高故障

诊断精度<sup>[4]</sup>。宋亚等在涡扇发动机剩余寿命预测中采用双向长短期记忆神经网络(bidirectional long short-term memory, BLSTM)捕捉状态监测数据等时间序列与涡扇发动机寿命的复杂关系,提升预测精度<sup>[5]</sup>。

## 1 算法理论介绍

### 1.1 条件变分自编码器

条件变分自编码器的结构如图1所示。左半部分表示编码结构,右半部分表示解码结构。

CVAE本质上是通过编码改变输入数据集的分布,使之成为已知的分布函数,再从这个分布函数中随机取样本,通过解码过程生成符合输入数据集规律的新数据。通常,数据集 $x$ 的分布是未知且复杂的,而任何复杂分布都

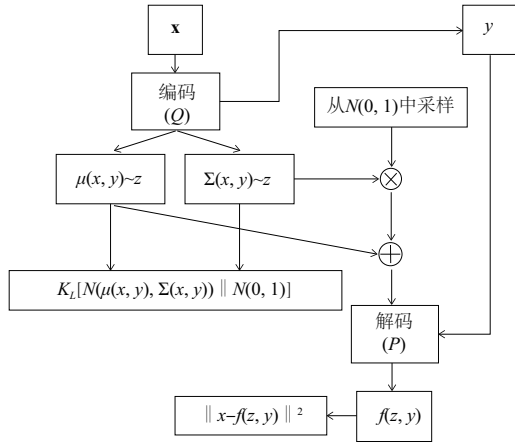


图1 条件变分自编码器结构

可以通过已知的简单分布映射得到。CVAE 编码的目的就是改变输入数据集  $\mathbf{x}$  的分布,使之尽可能地贴合已知分布,再从已知分布中采样,通过解码部分生成数据。在编码与解码的过程加入标签  $y$ ,可使模型根据标签生成不同类别的数据。

输入数据集  $\mathbf{x}$  和标签  $y$  通过编码过程  $Q$  映射到隐变量  $z$ ,其中编码后产生的数据  $\mu(x,y)$  和  $\Sigma(x,y)$  分别代表隐变量  $z$  的均值和方差。假设使之贴合的已知分布为标准正态分布  $N(0,1)$ ,通过计算隐变量  $z$  与标准正态分布  $N(0,1)$  的  $K_L$  离散度,可知两个分布之间的差异,并由此优化编码器。编码器的损失函数如式(1)所示。

$$l_e = K_L[N(\mu(x,y), \Sigma(x,y)) || N(0,1)] = \frac{1}{2}(-\ln(\Sigma(x,y)) + (\mu(x,y))^2 + (\Sigma(x,y)) - 1) \quad (1)$$

解码部分将隐变量  $z$  和标签  $y$  通过解码过程  $P$  生成重构数据  $f(z,y)$ ,再计算  $f(z,y)$  与输入  $x$  的平方差来优化解码器部分。其中  $z$  由式(2)获得,解码器损失函数如式(3)所示。

$$z = \mu(x,y) + \varepsilon \cdot \Sigma(x,y) \quad (2)$$

$$l_d = [x - f(z,y)]^2 \quad (3)$$

CVAE 损失函数如式(4)所示。

$$l_i = l_e + l_d \quad (4)$$

CVAE 模型训练完成后,可将模型的解码部分作为生成模型,将  $N(0,1)$  中随机采样的数据与标签  $y$  相组合来生成与训练数据集类似的数据。

## 1.2 BLSTM 神经网络

为了充分利用输入数据的前后依赖关系,本文选用双向长短期记忆神经网络 (BLSTM) 进行故障程度诊断。BLSTM 是在长短期记忆神经网络 (LSTM) 的基础上发展而来,由两层方向相反的 LSTM 构成。它既能避免传统循环神经网络在处理时间序列上距离较远节点时带来的梯度消失或者梯度膨胀问题,又能解决 LSTM 捕捉不了时间序列的反向规律问题。LSTM 神经网络的细胞结构如图 2 所示。

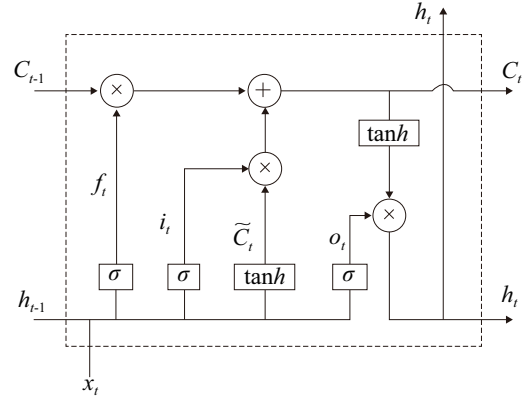


图2 LSTM 细胞结构

LSTM 细胞结构相较于传统循环神经网络加入了忘记门、输入门和输出门,其公式如式(5)~式(10)所示。

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (5)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (7)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (9)$$

$$h_t = o_t \times \tanh(C_t) \quad (10)$$

式中: $f_t$  表示忘记门运算结果; $i_t$  为输入门层; $o_t$  为输出门层; $x_t$  为  $t$  时刻的输入; $h_{t-1}$  为  $t-1$  时刻的输出; $h_t$  为  $t$  时刻的输出; $\tilde{C}_t$  为记忆细胞候选值; $C_t$  为更新后的细胞状态; $f_t \times C_{t-1}$  表示丢弃忘记门所确定的信息; $i_t \times \tilde{C}_t$  表示该轮细胞更新中所需的新信息; $W$  和  $U$  为权重矩阵; $b$  为偏置向量; $\sigma$  为 sigmoid 函数。

BLSTM 展开结构如图 3 所示。BLSTM 模型计算公式如式(11)~式(13)所示。

$$h_t = L_{\text{STM}}(x_t, h_{t-1}) \quad (11)$$

$$h'_t = L_{\text{STM}}(x_t, h'_{t+1}) \quad (12)$$

$$y_t = W_1 h_t + W_2 h'_t + b_y \quad (13)$$

式中: $h_t$  为正向 LSTM 细胞输出; $h'_t$  为反向 LSTM 细胞输出; $W_1$  为正向 LSTM 到输出层的权值; $W_2$  为反向 LSTM 到输出层的权值; $b_y$  为输出层偏置。




图3 BLSTM 展开结构

BLSTM 的损失函数为

$$l_{\text{loss}_2} = \frac{-\sum_{i=1}^n y'_i \log(y_i)}{n} \quad (14)$$

式中: $y_i$  为 BLSTM 最后一个时间节点的输出结果  $\mathbf{y}$  向量

中第  $i$  个元素;  $y'_i$  为实际标签  $y'$  向量中第  $i$  个元素;  $n$  为每个标签向量中元素个数。

## 2 建模与仿真

图 4 为某型飞机起落架液压收放系统 AMESim 仿真模型<sup>[6]</sup>。该仿真模型包括收放作动模块、锁作动模块和液压源模块。模型具体参数设置来自文献[7-8]。选取收放作动筒内泄漏进行不同故障程度仿真来验证算法有效性。故障程度设置如表 1 所示。

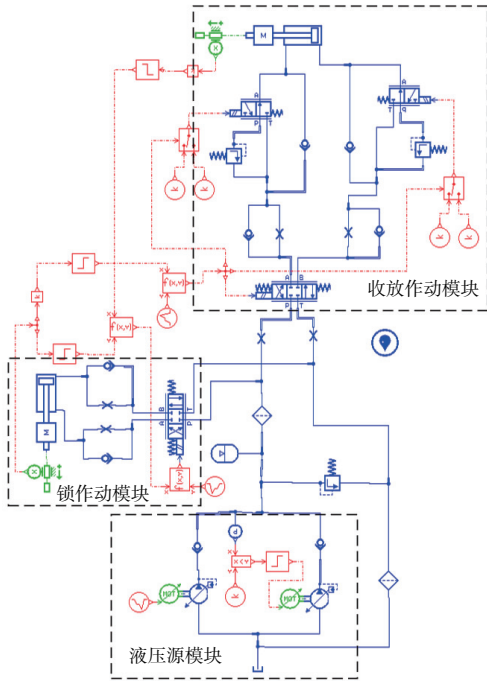


图 4 某型飞机起落架液压收放系统 AMESim 仿真模型

表 1 故障程度设置

参数类型	设置
故障类型	收放作动筒内泄漏
故障值	0.02~0.05
故障程度分类区间	0.020~0.025, 0.025~0.030, 0.030~0.035, 0.035~0.040, 0.040~0.045, 0.045~0.050

将仿真时长设置为 40 s, 其中 0~3 s 开始仿真, 3~14 s 起落架收上, 到位后上锁, 20 s 开始解锁, 解锁后起落架立即放下, 40 s 仿真停止。本文将作动筒有杆腔压力作为故障程度识别数据。

如表 1 所示, 根据故障程度划分了多个分类区间。仿真时, 每个分类区间等间距取 100 个数值。调整故障参数进行多次故障仿真, 根据分类区间得到 6 组仿真数据, 作为训练集数据, 每组数据作为一个类别。每个分类区间随机取 30 个与训练集不同的数值进行仿真, 得到 6 组仿真数据, 作为测试集数据。

## 3 CVAE-BLSTM 故障程度诊断

### 3.1 数据预处理

将数据的采样时间设为 0.1 s, 即每条曲线采样 400 个数据点。每个分类区间各取 1 条曲线组成如图 5 所示。




图 5 不同故障程度有杆腔压力曲线

从图 5 可看出, 10~14 s 曲线有一个小凸起, 表明起落架收上到位后, 有杆腔压力达到最大值。而不同故障程度的作动筒内泄漏到达的压力最大值的时间不同, 泄漏程度大的有更明显的延时现象。14~21 s 压力曲线有不同程度的下降, 表明在换向阀中位时, 出现高压油腔向低压油腔泄漏的现象, 且泄漏程度越大, 压力下降得越快。25~33 s 压力曲线接近于 0, 表明起落架放下到位。而这段时间也出现泄漏延时现象。本文将 40 s 曲线作故障程度诊断模型的训练数据, 共 400 个数据点。

为了加快模型训练速度和收敛速度, 采用式 (15) 进行归一化处理。

$$x_i^{\text{norm}} = \frac{x_i - x^{\min}}{x^{\max} - x^{\min}} \quad (15)$$

式中:  $x_i$  为数据曲线中第  $i$  个数据点;  $x^{\max}$  和  $x^{\min}$  为数据曲线中最大值和最小值;  $x^{\text{norm}}$  为  $x_i$  归一化后的值。

### 3.2 CVAE-BLSTM 模型

CVAE-BLSTM 模型结构如图 6 所示。

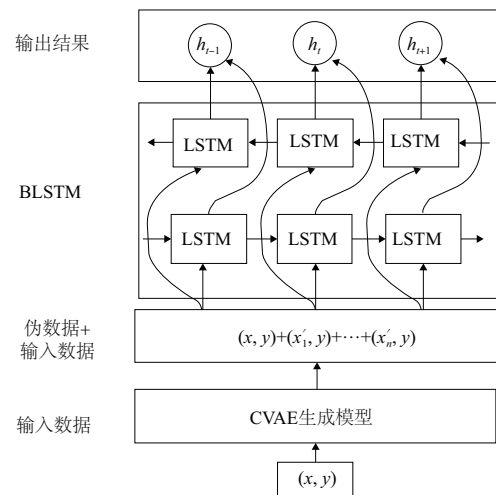


图 6 CVAE-BLSTM 模型结构

本文先用训练集训练 CVAE 模型,再截取 CVAE 的解码器作为生成模型,与 BLSTM 相结合,混合成 CVAE-BLSTM 模型,并再次使用训练集训练。输入带标签的原始数据后,CVAE 生成模型将根据标签生成  $n$  个与输入标签同一类型的伪数据,并将  $n$  个伪数据与原始数据一同输入 BLSTM 训练该模型,取 BLSTM 最后一个时间步输出节点作为最终结果与输入标签相比较,更新网络权值。

## 4 结果分析

### 4.1 模型参数设定

CVAE-BLSTM 模型主要参数设置如表 2 所示。

表 2 模型主要参数设置

参数	数值
CVAE 第一隐藏层节点数	128
CVAE 第二隐藏层节点数	2
CVAE 的初始学习率	0.001
BLSTM 的时间步	20
BLSTM 的初始学习率	0.001

### 4.2 与其他模型对比

将 CVAE-BLSTM 的测试集准确率与 BP 神经网络、CVAE-BP 神经网络、CNN<sup>[9]</sup> 模型、CVAE-CNN 模型、LSTM<sup>[10]</sup> 模型、CVAE-LSTM 模型等其他算法进行比较,结果如表 3 所示。

表 3 与其他模型对比

诊断模型	准确率/%
BP	57.9
CVAE-BP	59.2
CNN	63.9
CVAE-CNN	82.4
LSTM	83.6
CVAE-LSTM	90.7
BLSTM	84.1
CVAE-BLSTM(本文方法)	94.8

BP 神经网络采用双隐藏层, sigmoid 激活函数; CNN 训练时将输入数据 reshape 组成  $20 \times 20$  二维数据,并采用两个卷积层、两个池化层和一个全连接层组成; LSTM 模型参数与本文 BLSTM 中的 LSTM 单元设置相同。各 CVAE 混合模型的 CVAE 参数设置相同。

由表 3 对比结果可知, CNN、LSTM 和 BLSTM 混合了 CVAE 生成模型后,测试集准确率有明显上升,而对 BP 神经网络的提升不大,说明 CVAE 可以提升其他深度学习算法的泛化能力,但对传统机器学习算法提升不明显。

CVAE-BLSTM 模型与 CVAE-LSTM 模型的测试集准确率大于 CVAE-CNN 模型,说明循环神经网络比卷积神经网络更适合处理时间序列数据。本文所提的 CVAE-BLSTM 模型较 CVAE-LSTM 提升了 4%,较 BLSTM 提升了 10%,这得益于 BLSTM 模型对数据进行双向学习能力和 CVAE 生成模型伪数据生成能力。这两项能力增加了模型诊断的准确率与泛化能力,使模型具有高准确率和对未仿真故障参数带的学习诊断能力。

## 5 结语

针对飞机起落架液压收放系统故障样本少,故障数据时域上的高相关性以及故障数据集样本不足的问题,本文提出一种基于 CVAE-BLSTM 的混合模型来进行故障程度诊断。首先建立某型飞机起落架液压收放系统 AMESim 仿真模型,植入故障,提取故障数据,其次利用故障样本训练 CVAE 生成模型,最后组成 CVAE-BLSTM 混合模型进行故障程度诊断。与其他算法相比,CVAE-BLSTM 混合模型具有高准确率与强泛化能力,可对飞机起落架液压收放系统故障程度进行有效诊断。

### 参考文献:

- [1] REVELEY M S, BRIGGS J L, EVANS J K, et al. Causal factors and adverse conditions of aviation accidents and incidents related to integrated resilient aircraft control [R]. US: NASA/TM, 2011.
- [2] 唐有才,刘振岗,王占勇,等. 飞机液压系统故障多的原因探讨及对策[J]. 液压与气动,2009(10):84-87.
- [3] 林嘉琦,徐建国,刘星怡,等. 基于深度信念网络的航空发动机气路故障诊断技术研究[J]. 机械制造与自动化,2019,48(5):179-182.
- [4] 金棋. 基于生成网络的行星齿轮箱故障诊断技术研究[D]. 南京:南京航空航天大学,2019.
- [5] 宋亚,夏唐斌,郑宇,等. 基于 Autoencoder-BLSTM 的涡扇发动机剩余寿命预测[J]. 计算机集成制造系统,2019,25(7):1611-1619.
- [6] WANG S. Commercial aircraft hydraulic systems [M]. Shanghai: Shanghai Jiao Tong University Press, 2015.
- [7] 印寅,聂宏,魏小辉,等. 多因素影响下的起落架收放系统性能分析[J]. 北京航空航天大学学报,2015,41(5):953-960.
- [8] 胡晓青,马存宝,和麟,等. 飞机起落架收放系统建模与故障仿真[J]. 计算机工程与科学,2016,38(6):1286-1293.
- [9] SATEESH BABU G, ZHAO P L, LI X L. Deep convolutional neural network based regression approach for estimation of remaining useful life [C]//Database Systems for Advanced Applications, 2016:214-228.
- [10] ZHENG S, RISTOVSKI K, FARAHAT A, et al. Long short-term memory network for remaining useful life estimation[C]//2017 IEEE International Conference on Prognostics and Health Management(ICPHM). Dallas, TX, USA:IEEE,2017:88-95.

收稿日期:2020-11-05