

DOI:10.19651/j.cnki.emt.2314811

基于VAE-LSTM模型的无人机飞行数据异常检测^{*}王从宝¹ 张安思^{1,2} 杨磊¹ 张保¹ 李松²

(1. 贵州大学机械工程学院 贵阳 550025; 2. 贵州大学公共大数据国家重点实验室 贵阳 550025)

摘要: 无人机飞行数据是反映其自身飞行安全的重要状态参数,通过对飞行数据进行异常检测,是提高无人机整体飞行安全性的关键举措。尽管基于数据驱动方法不需专家先验知识和精确的物理模型,但缺乏参数选择且检测网络结构模型单一,使得检测模型由于参数过多导致过拟合以及无法有效捕捉数据异常模式的问题。文中结合变分自编码器和长短期记忆网络的优势,提出了一种基于VAE-LSTM的无人机飞行数据异常检测模型方法。首先,引入肯德尔相关性分析方法用于选择相关依赖的飞行数据参数集;其次,将具有相关性的参数集对所设计的VAE-LSTM深度混合模型进行训练,学习不同数据特征之间的关系映射;最后,以无监督异常检测方式在真实多维无人机飞行数据进行验证。实验结果表明,VAE-LSTM的精密度、检测率、准确率、F1分数及误检率的各项平均性能指标分别达到95.24%、98.71%、98.8%、96.82%、1.31%,相比于KNN、OC-SVM、VAE、LSTM模型,整体上展现出较好异常检测性能。

关键词: 无人机飞行数据;Kendall相关性;变分自编码器;长短期记忆网络;混合模型;异常检测

中图分类号: V241;V267;V238 **文献标识码:** A **国家标准学科分类代码:** 510.40

Anomaly detection of UAV flight data based on VAE-LSTM modeling

Wang Congbao¹ Zhang Ansi^{1,2} Yang Lei¹ Zhang Bao¹ Li Song²

(1. School of Mechanical Engineering, Guizhou University, Guiyang 550025, China;

2. State Key Laboratory of Public Big Data, Guizhou University, Guiyang 550025, China)

Abstract: UAV flight data is an important state parameter reflecting its own flight safety, and it is a key initiative to improve the overall flight safety of UAVs through abnormal detection of flight data. Although data-driven methods do not require expert a priori knowledge and accurate physical models, the lack of parameter selection and a single model for the detection network structure make the detection model overfitting due to too many parameters and failing to effectively capture data anomaly patterns. In this paper, a VAE-LSTM based UAV flight data anomaly detection modeling method is proposed by combining the advantages of Variational Auto-Encoders and Long Short-Term Memory networks. First, the Kendall correlation analysis method is introduced for selecting relevant dependent flight data parameter sets; Second, the parameter sets with correlation are trained on the designed VAE-LSTM deep hybrid model to learn the relational mapping between different data features; And lastly, the validation is performed with unsupervised anomaly detection in real multi-dimensional Unmanned Aerial Vehicle flight data. The experimental results show that the various average performance metrics of precision, detection rate, accuracy, F1 score and false detection rate of VAE-LSTM reach 95.24%, 98.71%, 98.8%, 96.82%, and 1.31%, respectively, and show overall better anomaly detection performance compared to KNN, OC-SVM, VAE, and LSTM models.

Keywords: unmanned aerial vehicle flight data; Kendall correlation; variational auto-encoders; long short-term memory; hybrid model; anomaly detection

0 引言

随着无人机(unmanned aerial vehicle, UAV)技术领

域的蓬勃发展,其在公共安全^[1]、消防急救^[2]、勘测^[3]、军事^[4]等领域广泛应用。与此同时,其面临的飞行安全问题也日益凸显。其中,传感器作为UAV感知自身飞行状态

收稿日期:2023-10-23

^{*} 基金项目:国家重点研发计划资助项目(2020YFB1713302)、国家自然科学基金(52365061)、贵州省高等学校集成攻关大平台资助项目(黔教合KY字[2020]005)、贵州省省级科技计划项目(黔科合基础-ZK[2023]一般059)资助

和与外界环境交互的重要部件^[5-6],当其发生故障,会使无人机出现不符合预期运动,从而导致 UAV 失控、坠机等飞行安全事故。及时发现传感器的故障并为后续飞行任务规划提供决策依据,是 UAV 飞行安全的重大研究课题。

UAV 传感器(如导航滤波传感器、气压高度计、GPS 传感器等)性能发生变化或者失效时,对应的飞行数据中会发生异常,即与其他数据存在较大偏差且呈现出不同机制的数据^[7]。对于无人机飞行数据异常检测,研究学者们提出各种方法^[8-9],而近年来的数据驱动方法因不需要准确的物理模型和大量先验知识备受关注^[10-14],其直接通过挖掘数据内部特征的关联关系,从而实现 UAV 的异常检测。例如, Bronz 等^[15]采用支持向量机(support vector machine, SVM)对小型固定翼无人机的正常飞行状态和故障状态行为进行分类,并通过该方法对陀螺仪和加速度计测量等参数进行异常检测,验证其方法的可行性。Liu 等^[16]针对飞行数据异常检测提出 K 近邻(K nearest neighbor search, KNNs)方法,通过构建二叉树对历史飞行数据进行索引,对每个观测数据进行 K 最近邻搜索,从而识别不同数据类型的异常。然而无人机飞行数据存在复杂时空相关性,这些方法在参数选择上仍依赖专家知识和经验,限制其自身的应用^[17]。此外,因获取带标签飞行数据难度大且成本高,而深度学习的无监督方法不需要先验异常知识即可捕捉飞行数据间复杂映射关系,非常适合无人机飞行数据异常检测任务要求。如丁建立等^[18]利用 LSTM 对广播式自相关监视时序数据进行检测,通过对数据特征进行扩展,使模型更好捕捉数据时间依赖性;Wang 等^[19]提出 LSTM 残差滤波的多元回归方法,使用 LSTM 模型捕捉多参数飞行数据的时空相关性,但其还依赖专家经验对参数的选择。钟杰等^[20]采用卷积神经网络异常检测方法,依据模型预测值和真实值的残差进行异常判定。尽管现有大多数方法在仿真数据或真实数据的人为异常注入方式取得了较好的异常检测性能,但对于真实的无人机异常情况,其方法还有待验证。其次,由于多维无人机飞行数据在时间和空间维度都具有相关性,而现有大多数方法并未考虑参数选择或仍依赖于专家知识选择参数。此外,单一类型网络模型无法较好捕捉飞行数据时空特征^[21]或是对数据样本过于敏感,容易对异常数据产生过拟合。

基于上述问题和挑战,本文在考虑无人机飞行数据时空相关性的基础上,提出了一种基于 VAE-LSTM 的无人机飞行数据异常检测方法。首先,利用相关性分析方法挖掘无人机飞行数据之间的相关性,从而得到具有相关性的飞行数据参数集,以减少参数选择对先验知识的依赖,防止过多数据输入导致检测模型过拟合或高维诅咒等问题;其次,结合变分自编码器的表示学习和空间建模能力以及长短期记忆网络在时序特征建模方面优势,设计了能够充分提取无人机飞行数据时空相关性特征的 VAE-LSTM 深度混合网络模型,实现不同数据特征的关系映射;最后,在真

实无人机飞行数据进行了异常检测,验证该方法的有效性。

1 基础网络架构

1.1 变分自编码器

变分自编码器(variational auto-encoders, VAE)作为自编码器的一种特殊变体,其一经提出就快速成为深度生成模型领域中备受关注的网络模型之一^[22]。VAE 作为深度隐藏空间生成模型的一种形式,在数据生成方面展现出巨大的应用价值^[23-24]。近年来 VAE 模型不断改善,衍生出多种变体,其表现性能得到显著提高,能根据需求定向生成不同形式的数据。如图 1 所示,VAE 结构是由神经网络搭建的两个概率密度分布模型:一个用于原始数据输入的变分推断,从而生成隐藏变量的变分概率分布的编码器网络 $q_{\phi}(z|x)$,另一个则是根据生成的隐变量变分为概率分布,进而还原生成原始数据的近似概率分布的解码器网络 $p_{\theta}(x|z)$ 。其中, x 为输入样本, z 为不可观测的隐藏层变量。原始数据被编码器网络压缩到低维度空间,进而使输入样本 x 映射到隐藏层变量 z 中,解码器网络通过隐藏层变量 z 来进行数据生成,利用隐藏层变量 z 重构原始数据 x ,从而拟合隐藏层变量 z 到重构样本的似然函数。

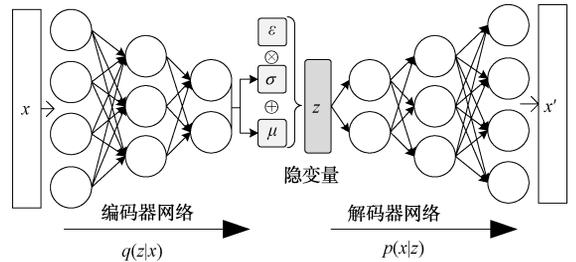


图 1 VAE 结构图

VAE 的‘编码器’和‘解码器’的输出都受到约束变量的概率分布影响,而不是某种特定的编码。依据先验分布假设,隐藏层变量 z 被约束为高斯分布,以便模型学习输入数据的概率分布。然而分布的边际似然函数求解困难,对此引进建议分布 $q(z|x)$ 和近似后验分布 $q_{\phi}(z|x)$, 边际似然函数的变分下界作为目标函数,并用极大似然法优化目标函数,从而得到对数似然函数,如式(1)所示。

$$\log p(x) = D_{KL}(q_{\phi}(z|x) \parallel p_{\theta}(z|x)) + L(x) \quad (1)$$

式中: D_{KL} 为隐藏层变量 z 的近似后验 $q_{\phi}(z|x)$ 和先验分布之间的 KL 散度,由于 KL 散度的非负性,从而得 $\log p(x) \geq L(x)$, 故此称 $L(x)$ 为似然函数的变分下界。因:

$$D_{KL}(q_{\phi}(z|x) \parallel p_{\theta}(z|x)) = E_{q_{\phi}(z|x)}(\log q_{\phi}(z|x) - \log p_{\theta}(z|x)) = E_{q_{\phi}(z|x)}((\log q_{\phi}(z|x) - \log p(z,x)) + \log p(x)) \quad (2)$$

其次,根据马尔可夫蒙特卡洛方法所假设真实后验概率是由隐藏层组成的均匀分布^[25],由此可推导出变分自编码器网络的损失函数,即变分下界的最终形式,如式(3)

所示。

$$L(x) = E_{q_{\phi}(z|x)}[\log p_{\theta}(x|z)] - E_{q_{\phi}(z|x)}[\log q_{\phi}(z|x) + \log p_{\theta}(z)] = E_{q_{\phi}(z|x)}[\log p_{\theta}(x|z)] - D_{KL}(q_{\phi}(z|x) \parallel p_{\theta}(z)) \quad (3)$$

式中: $E_{q_{\phi}(z|x)}$ 表示在后验分布 $q_{\phi}(z|x)$ 下所求的期望。

为确保网络训练误差的传回特性,使用重参数化方法将抽样得到的不确定性样本转化为确定性样本,先从标准正态分布中采样得到一个辅助参数 ε , 即 $\varepsilon \sim N(0,1)$, 进而计算隐藏层变量特征 z , 如式(4)所示。

$$z = \mu + \varepsilon \times \sigma \quad (4)$$

以此直接模拟从分布 $N(\mu, \sigma^2)$ 采样 z 。由此又可得到 VAE 的 KL 散度计算表达式如式(5)所示。

$$D_{KL} = \frac{1}{2}(1 + \log(\sigma^2) - \mu^2 - \sigma^2) \quad (5)$$

具体来说,VAE 的结构可分为 3 个步骤:第 1 步是编码过程,数据样本通过神经网络分别获取正态分布的均值和方差;第 2 步是重参数化,其目的是为了能够用从近似后验分布中进行采样和使用反向传播来训练模型参数。第 3 步是解码,将重参数化的变量通过生成模型生成新样本^[25]。

1.2 长短期记忆网络

长短期记忆网络(long short-term memory, LSTM)是一种特殊类型的循环神经网络(recurrent neural network, RNN),其提出目的就是为了改善 RNN 出现梯度爆炸和梯度消失的问题,且善于处理长期依赖性序列 ADVANCE^[26]。LSTM 模型通常包含输入门、遗忘门、输出门以及存储单元。如图 2 所示,展示了 LSTM 模块结构。

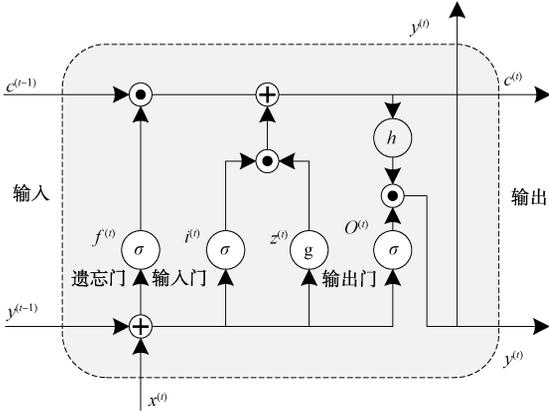


图 2 LSTM 模块结构

假设时刻 t , d 维数据 $x^{(t)} \in \mathbf{R}^{d \times 1}$ 输进 LSTM 单元时,新的信息会通过记忆单元状态更新进行记忆。 $t-1$ 时刻的记忆单元的隐藏状态和存储状态表示为 $y^{(t-1)} \in \mathbf{R}^{k \times 1}$ 与 $c^{(t-1)} \in \mathbf{R}^{k \times 1}$, k 表示 LSTM 网络隐藏节点的数量。LSTM 单元中,遗忘门是决定那些信息应该从先前的记忆单元 $c^{(t-1)}$ 中删除,其计算表达式如下:

$$f^{(t)} = \sigma(W_f x^{(t)} + R_f y^{(t-1)} + b_f) \quad (6)$$

输入门的功能是更新当前的输入数据,并确定那些数据被输入记忆单元中,其表达式如下:

$$i^{(t)} = \sigma(W_i x^{(t)} + R_i y^{(t-1)} + b_i) \quad (7)$$

下一步是计算记忆单元值,其确定当前记忆并流向下层的信息,其表达式如下:

$$z^{(t)} = g(W_z x^{(t)} + R_z y^{(t-1)} + b_z) \quad (8)$$

$$c^{(t)} = f^{(t)} \odot c^{(t-1)} + z^{(t)} \odot i^{(t)} \quad (9)$$

输出门是控制模型的数据输出和从当前 LSTM 记忆单元流向下一个隐藏层,其表达式如下:

$$o^{(t)} = \sigma(W_o x^{(t)} + R_o y^{(t-1)} + b_o) \quad (10)$$

$$y^{(t)} = o^{(t)} \odot g(c^{(t)}) \quad (11)$$

式中: $W_f, R_f \in \mathbf{R}^{k \times (d+k)}$ 分别是遗忘门的关联权重; $W_i, R_i \in \mathbf{R}^{k \times (d+k)}$ 分别是输入门的关联权重; $W_z, R_z \in \mathbf{R}^{k \times (d+k)}$ 分别是记忆单元的关联权重; $W_o, R_o \in \mathbf{R}^{k \times (d+k)}$ 分别是输出门的关联权重。 b_f, b_i, b_z 和 b_o 分别是各分量相关的偏置权重。 σ, g 和 h 表示非线性激活函数,其中 $\sigma(x) = 1/(1 + e^{-x})$, $g(x) = h(x) = \tanh(x)$ 。

2 检测模型整体框图

基于 VAE-LSTM 混合模型的无人机飞行数据异常检测总体架构如图 3 所示。具体详情如下,首先,对原始多维飞行数据进行预处理,即数据进行标准化,目的是为了消除参数间不同量纲对实验结果的影响;其次,利用 Kendall 相关性分析方法对飞行数据相关性分析,获取相关依赖的飞行数据参数集;然后,将正常且具有相关性的飞行数据特征分为训练集与验证集,将带有异常的飞行数据作为测试集,训练集与验证集对搭建好的 VAE-LSTM 模型进行训练和调整,测试集用作测试和评估混合模型的有效性;最后,由 VAE-LSTM 模型对输入窗口进行重构输出,通过输入输出之间残差同阈值进行比较,从而实现对飞行数据的异常检测。

2.1 飞行数据预处理与相关性分析

1) 飞行数据预处理

由于无人机飞行数据具有不同衡量单位,为消除飞行数据之间特征尺度不同对模型性能的影响,使用如式(12)的 z -score 归一化方法对飞行数据预处理。

$$X_{z-score} = \frac{X - \mu}{\sigma} \quad (12)$$

式中: X 为原始数据, μ 为原始数据 X 的平均值, σ 为原始数据 X 的标准差。

2) 飞行数据相关性分析

无人机是一个包括大量传感器的复杂系统,其飞行数据在时间维度和空间维度上具有相关性,通过相关性分析方法,对多参数飞行数据相关性进行挖掘,从而建立飞行数据参数集。文中采用肯德尔(Kendall)方法^[27]对飞行数据进行相关性分析,该方法广泛用于量化不同变量的相关程

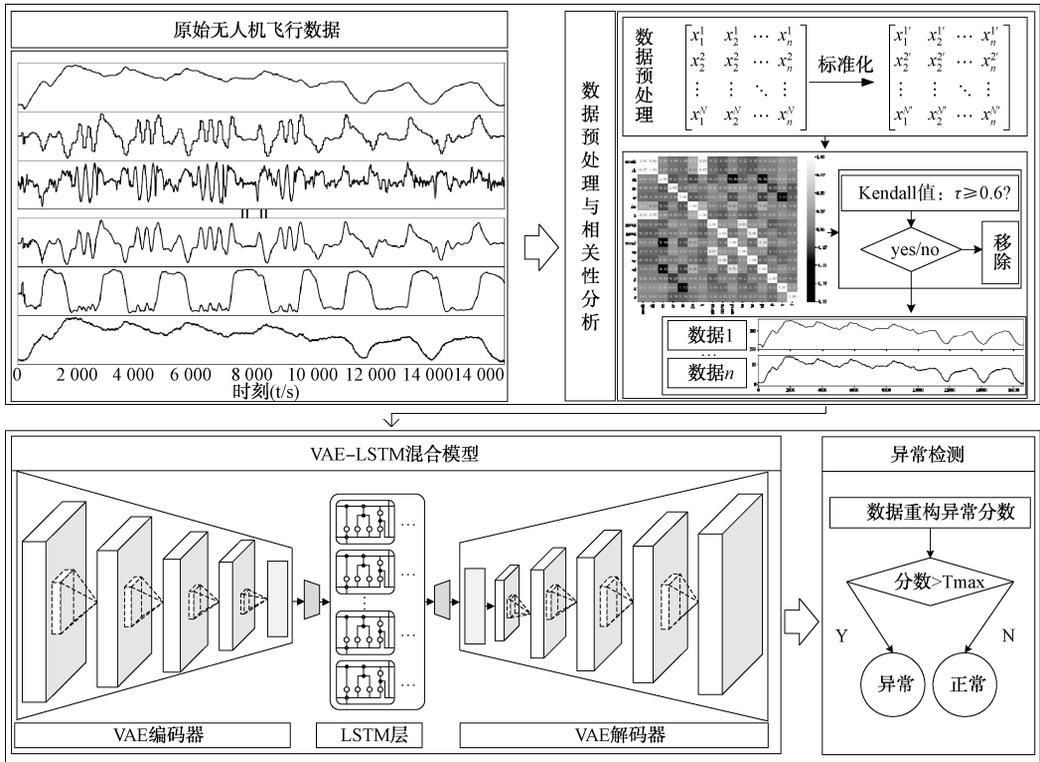


图 3 异常检测整体框架

度,其作为一种无参数假设检验,不要求数据满足高斯分布、线性约束及同方差等严格的假设条件,具有广泛的适用性。Kendall 秩相关分析法用于计算相关系数,其输出取值范围为 $[-1,1]$,相关系数值越接近 1 时,两个变量间的正线性关系就越强,相关系数接近 0 时,两个变量越趋于独立。相关系数值越接近 -1 时,负相关性就越强。计算表达式如式(13):

$$\tau = \frac{\sum_{i < j} \text{sgn}(x_i - x_j) \text{sgn}(y_i - y_j)}{\sqrt{(T_0 - \sum \frac{t_i(t_i - 1)}{2})(T_0 - \sum \frac{u_i(u_i - 1)}{2})}} \quad (13)$$

式中: τ 为变量 x 与 y 的 Kendall 相关系数, t_i (或 u_i) 是 x (或 y) 的第 i 组结点值的数量, $T_0 = n(n-2)/2$, n 为观测数量。

对如表 1 所示的 16 个定高和定速的飞行数据特征进行 Kendall 相关性分析。根据如图 4 所示相关性分析结果,其中导航高度传感数据、GPS 高度传感数据及压力高度传感数据 3 个数据相关度较高,所以选取这 3 个数据作为网络模型输入。其中 Kendall 相关系数 τ 被设置为 0.6, 作为判定相关性的阈值。

2.2 VAE-LSTM 模型无人机飞行数据异常检测

依据 VAE 网络的表示学习和空间建模能力与 LSTM 时空建模优势进行结合,设计一个用于无人机飞机数据的 VAE-LSTM 混合异常检测模型。在 VAE 模块中,其编码

表 1 Kendall 参考分析的飞行参数

字段名	说明	单位
navalt	NAV-altitude 导航高度	m
alt	GPS-GPS 高度	m
ax	X 轴加速度	m/s^2
ay	Y 轴加速度	m/s^2
az	Z 轴加速度	m/s^2
ias	指示空速	m/s
h	地面压力高度计	m
navvn	导航北向速度	m/s
navve	导航东向速度	m/s
navvd	导航下降速度	m/s
vn	GPS 向北速度	m/s
ve	GPS 向东速度	m/s
vd	GPS 下降速度	m/s
p	X 轴角速度	rad/s
q	Y 轴角速度	rad/s
r	Z 轴角速度	rad/s

器和解码器应用卷积神经网络层进行搭建,一方面,VAE 模块可以学习飞行数据特征表示,另一方面,VAE 模块可利用卷积操作捕捉多维飞行数据窗口的时空相关性;在 LSTM 模块中,其通过使用门控机制控制信息流动,从而捕捉数据间的长期依赖关系和时空相关性。具体来说,所

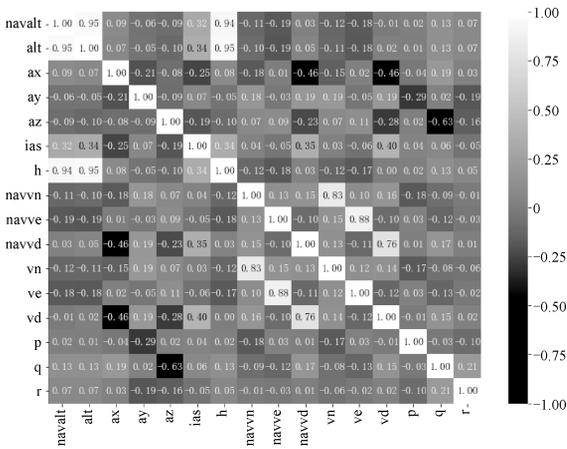


图4 飞行数据 Kendall 相关性分析

设计模型的结构包含 VAE 编码器、LSTM 层、VAE 解码器,如图 5 所示。表 2 展示了 VAE-LSTM 各个网络层结构,包括网络层类型,卷积层的输入张量、滤波器数、滤波器大小、卷积步长、填充样式、激活函数以及 LSTM 网络单元情况等。

1)VAE-LSTM 模型训练

将不包含异常的多维相关飞行数据作为训练数据,把带有异常的多维飞行数据作为测试数据进行评估。VAE 模型以重构数据窗口 X 作为输入,然后通过编码器估计低维嵌入,并通过解码器重构原始窗口。LSTM 对窗口序列 W 的 VAE 嵌入进行操作。对于长 L 的训练数据,可生成用于训练 VAE 模型的 $L-D$ 个滚动窗口和用于训练 LSTM 模型的 $L-D$ 个滚动序列,如下:

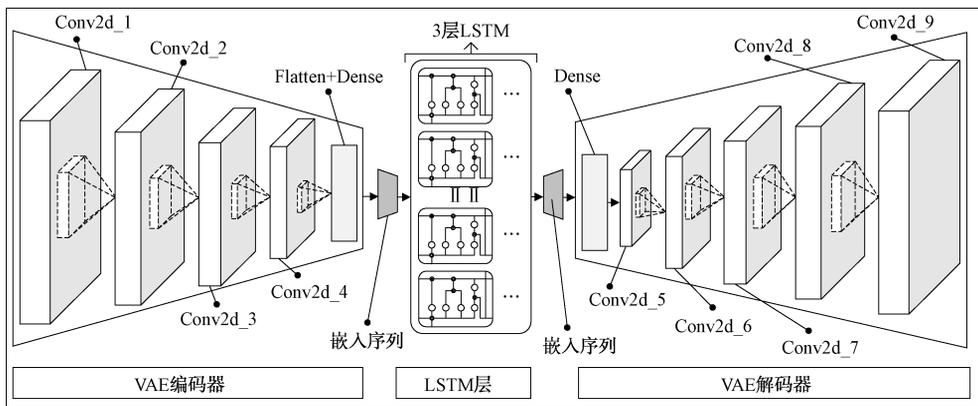


图5 VAE-LSTM 结构框架图

表2 VAE-LSTM 网络层结构

网络结构层	类型	详情
VAE 编码器	Conv2d_1	(None,48,3,1);32;3×3;21;same;leaky_relu
	Conv2d_2	(None,24,3,32);64;3×3;2×1;same;leaky_relu
	Conv2d_3	(None,12,3,64);128;3×3;2×1;same;leaky_relu
	Conv2d_4	(None,6,3,128);512;6×3;1×1;valid;leaky_relu
	Flatten+Dence	(None,512);leaky_relu
LSTM 层	Input_Layer	嵌入序列;隐藏空间;(None,10)
	LSTM1	(None,1,10)
	LSTM2	(None,1,64)
	LSTM3	(None,1,64)
VAE 解码器	Dense	(None,512);leaky_relu
	Conv2d_5	(None,1,1,768);768;1×1;1×1;same;leaky_relu
	Conv2d_6	(None,3,1,256);256;3×1;1×1;same;leaky_relu
	Conv2d_7	(None,6,1,128);128;3×1;1×1;same;leaky_relu
	Conv2d_8	(None,24,1,32);32;3×1;1×1;same;leaky_relu
	Conv2d_9	(None,48,1,16);1;5×3;1×1;same;leaky_relu

$$\mathbf{X} = \begin{bmatrix} x_1^1, x_2^1, \dots, x_{L-D}^1 \\ x_1^2, x_2^2, \dots, x_{L-D}^2 \\ \vdots \\ x_1^n, x_2^n, \dots, x_{L-D}^n \end{bmatrix} \quad (14)$$

$$\mathbf{W} = [\mathbf{X}] = \begin{bmatrix} [x_1^1, x_2^1, \dots, x_{L-D}^1] \\ [x_1^2, x_2^2, \dots, x_{L-D}^2] \\ \vdots \\ [x_1^n, x_2^n, \dots, x_{L-D}^n] \end{bmatrix} \quad (15)$$

其次,随机抽取比例为 10%的正常训练数据集作为验证集,验证集的窗口和序列全部被排除在外。除去验证集的其他窗口数据都用于训练优化 VAE 模型中 ELBO 损失,使其最大化,即最大化式(5)的最大变分下界函数。然后使用优化后 VAE 模型中的编码器对训练集全部嵌入序列 $\mathbf{E}(t) = [e_1^k, \dots, e_t^k]$ 进行估计,并通过 k 个嵌入序列以无监督方式学习自身序列(k 等于窗口总数,即 $k = D - L$),即:

$$[\hat{e}_1^k, \dots, \hat{e}_t^k] = \text{LSTM}([e_1^k, \dots, e_t^k]) \quad (16)$$

式中: e_i^k 表示低维嵌入序列, \hat{e}_i^k 表示经 LSTM 重构序列, $i = 1, \dots, k$ 。通过最小化最终嵌入的重构误差对 LSTM 模型参数进行优化,即 $\min \| \hat{e}_i^k - e_i^k \|$ 。

2) VAE-LSTM 异常检测

首先,将带有异常的测试数据 $X_{test}(t)$ 输入已训练好的 VAE-LSTM 模型,模型通过 VAE 编码器估计测试数据 $X_{test}(t)$ 的嵌入序列 $E(t)$;然后,嵌入序列输入 LSTM 模型进行自监督学习并输出重构嵌入序列;最后,在通过模型的 VAE 解码器重建 LSTM 输出的嵌入序列,从而得到重构的结果 $X'_{test}(t)$ 值。通过输入 $X_{test}(t)$ 与重构 $X'_{test}(t)$ 输出计算其残差 $R(t)$,表达式如下:

$$R(t) = | X_{test}(t) - X'_{test}(t) | \quad (17)$$

文中通过箱型图原理确定异常检测的阈值^[28],由于残

差取平均绝对误差值,残差值全是正值,所以只取上边缘 T_{max} ,其计算表达式如下:

$$T_{max} = Q_3 + 1.5 * (Q_3 - Q_1) \quad (18)$$

式中: Q_1 表示下四分位数据, Q_3 表示上四分位数。模型测试的重构残差大于阈值 T_{max} 时,就标记该数据点为异常,其于则为正常,即可通过以下定义式实现异常检测:

$$\begin{cases} 1, & R(t) > T_{max} \\ 0, & R(t) \leq T_{max} \end{cases} \quad (19)$$

式中:1 表示异常数据点,0 表示正常数据点。

3 实验与分析

3.1 实验设置

所用实验平台为 Lenovo TM ThinkStation P920 30DB, GPU 为 NVIDIA GeForce RTX 2080 Ti 510.108.03,系统配置为 Windows 系统,开发环境为 Anaconda、TensorFlow 2.3 以及 Keras 2.4.3,采用 Python 编程语言。VAE-LSTM 模型中,VAE 学习率为 0.00018, LSTM 学习率为 0.00014。

3.2 实验数据

为了证明文中的 VAE-LSTM 模型异常检测的可行性和有效性,选用明尼苏达无人机实验室 Thor 型无人机(小型固定无人机)真实飞行数据进行验证,实验总共选取了 6 个架次飞行数据集,三架次正常数据集^[29](flight 97、flight 98、flight 104)和三架次带有异常样本的数据集^[29](flight 111、flight 112、flight 121),数据采样频率为 50 Hz。其中,训练数据集为 flight 97、98、104 三架次正常数据,并将训练数据集中的 10%作为验证集,测试集则为带有异常的 flight 111、112、121 三架次飞行数据。并以检测导航高度数据为例,其数据变化曲线如图 6 所示,通过其验证 VAE-LSTM 混合检测模型的有效性,数据相关信息如表 3 所示。

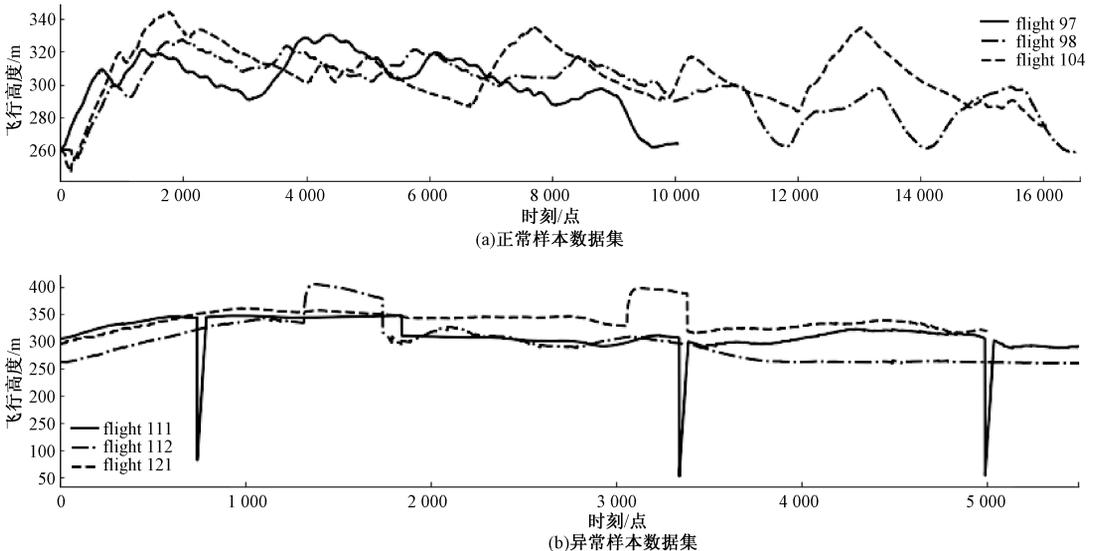


图 6 导航高度数据变化曲线

表3 实验数据相关信息

数据类型	数据集名称	原始数据长度	实验索引范围	实验长度	异常区间
正常数据	flight97	14 794	[3 751,13 800]	10 050	无
	flight98	21 015	[3 201,19 800]	16 600	无
	flight104	25 836	[6 701,22 800]	16 100	无
异常数据	flight111	13 327	[5 000,10 500]	5 500	[740,1 842],[3 340,3 387],[4 967,5 035]
	flight112	10 646	[5 000,10 000]	5 000	[1 316,1 740]
	flight121	27 097	[7 100,10 500]	5 000	[3 058,3 381]

3.3 实验评估指标

为评估实验中检测模型异常检测的性能,实验中采用异常检测领域常用的检测率(TPR)、误检率(FPR)以及准确率(accuracy, Acc)、精确度(precision, Pre)、F1分数5种指标进行评估。其计算表达式分别如式(20)~(24)所示。

$$TPR = \frac{TP}{TP + FN} \quad (20)$$

$$FPR = \frac{FP}{FP + TN} \quad (21)$$

$$Acc = \frac{TN + TP}{TN + TP + FN + FP} \quad (22)$$

$$Pre = \frac{TP}{TP + FP} \quad (23)$$

$$F_1 = \frac{2 \times Pre \times TPR}{Pre + TPR} \quad (24)$$

式中:TN为真反例数,TP为真正例数,FN为假反例数,FP为假正例数。其中,TPR是评估算法模型检测正类样本全体的能力指标,其值越大,模型性能越好;FPR是评估算法模型检测正类样本的纯度能力指标,其值越小,模型性能越好;Acc是评估算法模型对整体样本检测正确的能力指标,其值越大,算法模型检测效果越好,但会受到正类样本和负类样本数据分布不均的影响;Pre是评估算法模型检测正样本精度的能力指标,其值越大模型性能越好,但该指标同检测率相互制约,精确率高而召回率就会低;特引入综合指标F1分数进行评估,其值越大,模算法型的性能就越好。

3.4 实验结果与分析

将VAE-LSTM与KNN、OC-SVM、VAE、LSTM四种检测算法进行比较,以进一步验证VAE-LSTM混合模型检测方法的可行性和有效性。其中,KNN通过统计数据点间的距离作为不同群体数据的相似度量,并通过对K个邻近数据下一时刻样本点进行加权平均计算异常的得分,最后依据阈值对异常样本进行判定。OC-SVM作为SVM的一种分类模型,其通过在数据样本的特征空间中求解最大间隔超平面,进而学习分类的边界。VAE与LSTM都是具有时空相关的异常检测方法,他们先是对样本数据重构或预测,再通过与实际值之间的差值来判定是否异常。

对飞行数据Thor flight 111异常检测结果如图7所示。KNN与OC-SVM虽然有着较高的Pre分别为95.4%和99.1%,但它们的TPR与Acc分别相对较低,分别为82%和70.71%,这是因为KNN和OC-SVM对训练数据容错性较差,许多正常样本被检测为异常。尽管VAE-LSTM的Pre为85.71%,低于KNN和OC-SVM,但其TPR、Acc及综合指标F1分数的性能都是最优,分别高达98.58%、96.56%、91.7%。从FPR指标来看,VAE-LSTM为3.92%,比VAE和LSTM低5%~7%,略比KNN和OC-SVM高,符合异常检测的要求。总体来看,VAE-LSTM有某各指标低于其他方法,从整体表现更平均,具有较好异常检测性能。

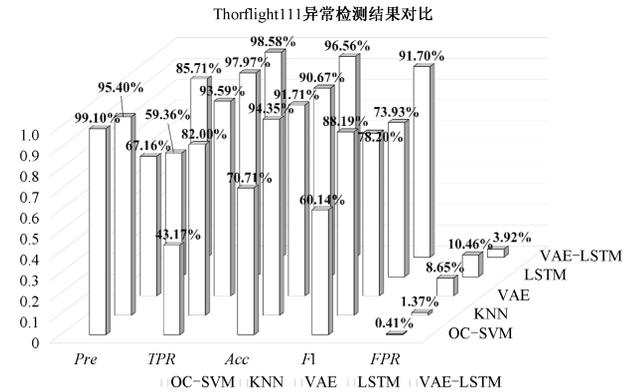


图7 Thor flight 111数据异常检测对比图

对飞行数据Thor flight 112异常检测的结果如图8所示,对于数据flight 112导航高度异常,每种方法都表现出较好Pre和较低的FPR,都高达到99%以上和低于1%。同时,VAE、LSTM、KNN、VAE-LSTM也达到较高的Acc,都达到97%以上,以VAE-LSTM为最高,达到了99.93%。然而VAE、LSTM、KNN的TPR表现较差,仅为78.92%、83.63%及86.86%,从而使得他们各自综合指标F1分数低于VAE-LSTM的F1分数,分别为91.11%、82.4%、93.18%。相比之下,VAE-LSTM在保证较高的Pre(100%)同时,也保证较好的TPR(99.07%),从而保证了其F1上表现出很好性能(99.53%)。而OC-SVM在TPR、Acc、F1的性能上都表现较差,分别为10.63%、36.29%、19.21%。

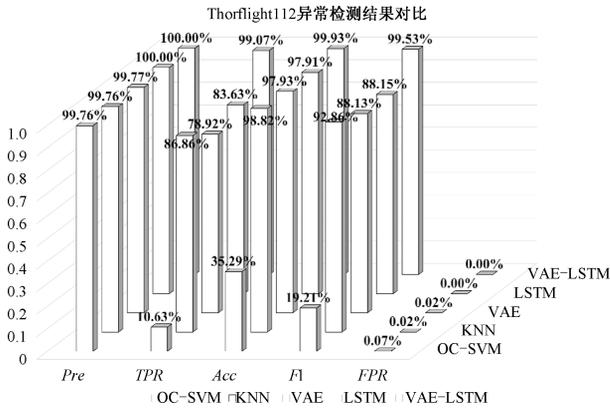


图 8 Thor flight 112 数据异常检测对比图

对飞行数据 Thor flight 121 异常检测的结果如图 9 所示。各种算法模型都表现较高得到 *Pre*，都达到了 99% 以上，其中 LSTM 和 VAE-LSTM 达到 100%，表明它们检测出所有的异常。从 *TPR* 指标来看，VAE-LSTM 以 98.84% 为最优，而 VAE 与 LSTM 的 *TPR* 分别为 83.68% 和 70.07%，这是由于 VAE 在捕捉数据时间依赖关系性能较弱，而 LSTM 在数据空间建模性能上欠佳，使得 *TPR* 相对较差，在检测上述的 flight 111 和 flight 112 也出现类似情形，OC-SVM 表现最差，*TPR* 才达到 10.63%。相比于其他方法，VAE-LSTM 在保持较高的 *Pre* (100%) 和 *TPR* (98.84%) 的同时，其 *F1* 分数同样达到较高的性能 (99.23%)。VAE-LSTM、LSTM、VAE 及 KNN 都达到较高的 *Acc* (97% 以上)，以 VAE-LSTM 的 *Acc* 到达 99.9% 最高，同时，它们都具有极低的 *FPR* 值，都低于 0.05%。

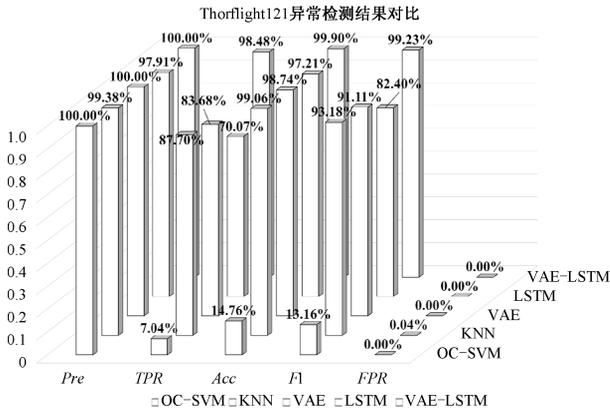


图 9 Thor flight 121 数据异常检测对比图

图 10 显示了 OC-SVM, KNN, VAE, LSTM 及 VAE-LSTM 模型的性能指标平均值。可以看出 OC-SVM 除 *Pre* 和 *FPR* 表现较好外，分别为 99.62% 和 0.16%，其他各个指标都较差，分别为 *TPR* = 20.28%，*Acc* = 40.25%，*F1* = 30.84%。相比之下，VAE-LSTM 在 *TPR* 上比 KNN, VAE 和 LSTM 高出 13.19%，13.31%，14.82%；在 *Acc* 上比 KNN, VAE, LSTM 高出 1.39%，2.67%，

3.54%；在 *F1* 上比 KNN, VAE, LSTM 高出 5.41%，11.01%，15.33%。在 *FPR* 上比 VAE, LSTM 高出 1.58%，2.18%。尽管 VAE-LSTM 的 *Pre* 和 *FPR* 值分别为 95.24% 和 1.31%，相对于 OC-SVM 和 KNN 较差，但是 VAE-LSTM 模型能够在保持较高 *Pre* 和较低 *FPR* 情况下，同时保持最优的 *TPR*, *Acc* 以及 *F1*，分别为 98.71%，98.8%，96.82%。因此，VAE-LSTM 整体表现出更好的异常检测性能。

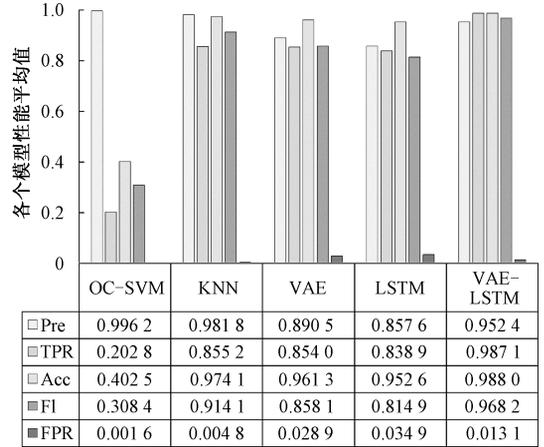


图 10 各个模型性能平均值

4 结 论

为提高无人机飞行数据的异常检测能力，针对参数选取依赖先验知识和单一网络模型存在捕捉数据模式单一或对数据容易过拟合的难题。本文结合 VAE 的表示学习和空间建模及 LSTM 时空建模优势，引入 Kendall 相关性分析方法，提出了一种考虑时空相关性的 VAE-LSTM 混合模型，用于无人机飞行数据异常检测。首先，通过 Kendall 相关性分析方法实现飞行数据特征的提取，并将其作为混合检测模型输入，降低了参数选取对先验知识的依赖；其次，将相关性参数集训练 VAE-LSTM 深度混合模型，学习飞行数据特征关系映射；最后，在在明尼苏达无人机实验室的 3 个带异常的飞行数据集 (Thor flight 111、Thor flight 112、Thor flight 121) 上进行了实验。实验结果表明，VAE-LSTM 混合模型平均异常检测结果分别为 *Pre* = 0.952 4，*TPR* = 0.987 1，*Acc* = 0.988，*F1* = 0.968 2 和 *FPR* = 0.013 1。尽管，VAE-LSTM 混合模型的 *Pre* 和 *FPR* 分别低于 OC-SVM 和 KNN，但是其在 *Acc* 上比 KNN, VAE, LSTM 高出 1.39%，2.67%，3.54%、*F1* 上比 KNN, VAE, LSTM 高出 5.41%，11.01%，15.33%、*FPR* 上比 VAE, LSTM 高出 1.58%，2.18%。实验综合表明，VAE-LSTM 混合模型能够有效地挖掘飞行数据之间相互依赖关系，整体上表现较好的检测性能。

在未来的工作中，将会进一步优化该模型的性能，使模型轻量化，降低检测所需时间，并将其部署到可以实时

异常检测平台。

参考文献

- [1] STAMPA M, SUTORMA A, JAHN U, et al. Maturity levels of public safety applications using unmanned aerial systems: A review[J]. *Journal of Intelligent & Robotic Systems*, 2021, 103: 1-15.
- [2] DENG L, HE Y, LIU Q. Research on application of fire unmanned aerial vehicles in emergency rescue[C]. 2019 9th International Conference on Fire Science and Fire Protection Engineering(ICFSFPE), 2019: 1-5.
- [3] TAN X, ZHANG G. Research on surface defect detection technology of wind turbine blade based on UAV image[J]. *Instrumentation*, 2022, 9(1): 41-48.
- [4] XIAONING Z. Analysis of military application of UAV swarm technology[C]. 2020 3rd International Conference on Unmanned Systems (ICUS), 2020: 1200-1204.
- [5] BALESTRIERI E, DAPONTE P, DE VITO L, et al. Sensors and measurements for UAV safety: An overview[J]. *Sensors*, 2021, 21(24):8253.
- [6] FOURLAS G K, KARRAS G C. A survey on fault diagnosis methods for UAVs[C]. 2021 International Conference on Unmanned Aircraft Systems(ICUAS), 2021: 394-403.
- [7] PANG G, SHEN C, CAO L, et al. Deep learning for anomaly detection: A review[J]. *ACM Computing Surveys(CSUR)*, 2021, 54(2): 1-38.
- [8] SCHMIDT T, HAUER F, PRETSCHNER A. Automated anomaly detection in CPS Log Files: A time series clustering approach[C]. *Computer Safety, Reliability, and Security: 39th International Conference*, 2020: 179-194.
- [9] BU J, SUN R, BAI H, et al. Integrated method for the UAV navigation sensor anomaly detection[J]. *IET Radar Sonar and Navigation*, 2017, 11(5): 847-853.
- [10] ZHONG J, ZHANG Y, WANG J, et al. Unmanned aerial vehicle flight data anomaly detection and recovery prediction based on spatio-temporal correlation[J]. *IEEE Transactions on Reliability*, 2021, 71(1): 457-468.
- [11] YANG L, LI S, LI C, et al. A survey of unmanned aerial vehicle flight data anomaly detection: Technologies, applications, and future directions[J]. *Science China Technological Sciences*, 2023, 66(4): 901-919.
- [12] YANG L, LI S, LI C, et al. Data-driven unsupervised anomaly detection and recovery of unmanned aerial vehicle flight data based on spatiotemporal correlation[J]. *Science China Technological Sciences*, 2023: 1-13.
- [13] LIN S, CLARK R, BIRKE R, et al. Anomaly detection for time series using vae-lstm hybrid model[C]. *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 2020: 4322-4326.
- [14] 祁超帅, 何文思, 焦毅, 等. 无人机飞行数据异常检测算法综述[J]. *计算机应用*, 2023, 43(6): 1833.
- [15] BRONZ M, BASKAYA E, DELAHAYE D, et al. Real-time fault detection on small fixed-wing UAVs using machine learning[C]. 2020 AIAA/IEEE 39th Digital Avionics Systems Conference(DASC), IEEE, 2020: 1-10.
- [16] LIU Y, DING W. A KNNs based anomaly detection method applied for UAV flight data stream[C]. 2015 Prognostics and System Health Management Conference(PHM), 2015: 1-8.
- [17] WHELAN J, SANGARAPILLAI T, MINAWI O, et al. Novelty-based intrusion detection of sensor attacks on unmanned aerial vehicles[C]. *Proceedings of the 16th ACM Symposium on QoS and Security for Wireless and Mobile Networks*, 2020: 23-28.
- [18] 丁建立, 邹云开, 王静, 等. 基于深度学习的 ADS-B 异常数据检测模型[J]. *航空学报*, 2019, 40(12): 167-177.
- [19] WANG B, LIU D, PENG Y, et al. Multivariate regression-based fault detection and recovery of UAV flight data[J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 69(6): 3527-3537.
- [20] 钟杰, 罗冲, 张恒, 等. 基于相关性参数选择的飞行数据异常检测[J/OL]. *北京航空航天大学学报*, 1-11 [2024-02-28].
- [21] AHN H. Deep learning based anomaly detection for a vehicle in swarm drone system[C]. 2020 International Conference on Unmanned Aircraft Systems(ICUAS), IEEE, 2020: 557-561.
- [22] KINGMA D P, WELING M. An introduction to variational autoencoders[J]. *Foundations and Trends[®] in Machine Learning*, 2019, 12(4): 307-392.
- [23] GRØNBECH C H, VORDING M F, TIMSHEL P N, et al. scVAE: Variational auto-encoders for single-cell gene expression data[J]. *Bioinformatics*, 2020, 36(16): 4415-4422.
- [24] BAI W, QUAN C, LUO Z W. Data-driven dimensional expression generation via encapsulated variational auto-encoders[J]. *Cognitive Computation*, 2022: 1-13.
- [25] 胡铭菲, 左信, 刘建伟. 深度生成模型综述[J]. *自动化学报*, 2022, 48(1): 40-74.

- [26] ZHU H, ZHU Y, WU D, et al. Correlation coefficient based cluster data preprocessing and LSTM prediction model for time series data in large aircraft test flights[C]. Smart Computing and Communication: Third International Conference, 2018: 376-385.
- [27] VAN DOORN J, LY A, MARSMAN M, et al. Bayesian inference for Kendall's rank correlation coefficient [J]. The American Statistician, 2018, 72(4): 303-308.
- [28] NUZZO R L. The box plots alternative for visualizing quantitative data[J]. PM&R, 2016, 8(3): 268-272.
- [29] Uninhabited Aerial Vehicle (UAV) Laboratories.

Flight data[EB/OL]. Retrieved from University of Minnesota Digital Conservancy, 2023.

作者简介

王从宝, 硕士研究生, 主要研究方向为无人机、深度学习、数据挖掘、异常检测。

张安思(通信作者), 博士, 副教授, 主要研究方向为制造大数据、智能制造、人工智能、故障诊断与健康管埋。

杨磊, 博士研究生, 主要研究方向为深度学习、无人机、故障诊断、异常检测。

张保, 硕士研究生, 主要研究方向为室内定位、人工智能。

李松, 硕士研究生, 主要研究方向为深度学习算法、点云分类。