

引用格式:程志磊,章国宝,黄永明. 基于 CNN-LSTM-LOF 的过程故障预测模型[J]. 北京化工大学学报(自然科学版), 2024, 51(1):121-127.

CHENG ZhiLei, ZHANG GuoBao, HUANG YongMing. A prognosis model for process fault based on CNN-LSTM-LOF [J]. Journal of Beijing University of Chemical Technology (Natural Science), 2024, 51(1):121-127.

基于 CNN-LSTM-LOF 的过程故障预测模型

程志磊 章国宝* 黄永明

(东南大学 自动化学院, 南京 210018)

摘要:在现代工业过程中,故障预测可以及时预测设备的潜在故障,减少事故的发生以及降低经济损失,因此故障预测对于过程系统至关重要。由于过程系统的复杂性以及运行数据集分布不均,使用正常数据集离线预测运行状态的方法没有较好的泛用性,且不太准确。针对以上问题,将卷积神经网络(CNN)与长短期记忆网络(LSTM)相结合,用于提取设备运行数据的特征,在线预测之后的运行状态;随后将预测结果送入在离线状态下训练好的局部异常因子(LOF)模型中,计算预测出时间序列的异常值;最后将异常值与离线状态下训练出的故障阈值进行比较,大于阈值则认为存在潜在故障。将模型用于田纳西-伊斯曼(TE)时间序列进行验证,并与传统的故障预测方法进行比较,实验结果表明:本文所提模型对于多故障以及单故障预测相比传统故障预测方法均具有更好的效果,可以提前 1 个采样窗口检测到数据异常,有应用于工业故障预测的潜力。

关键词:故障预测; 田纳西-伊斯曼过程; 长短期记忆; 局部异常因子算法; 卷积神经网络

中图分类号: TP277 **DOI:** 10.13543/j.bhxbzr.2024.01.014

引 言

在工业过程中,一旦设备发生故障,将会造成巨大的经济损失,因此对于过程故障的预测尤为重要。现有的故障预测方法大体可以分为 3 类^[1]:基于模型的方法,基于数据驱动的方法以及基于专业知识的方法。由于工业设备中一旦出现故障就会造成巨大的损失,因此在工业生产环境下,当设备发生故障时,操作人员会立即停止运行及时止损。然而这同时会导致故障数据集较少,无法很准确地根据现有故障数据训练出合适的模型来预测过程系统的运行状态;另一方面,由于工业过程大多是多输入多输出系统,多个输入相互耦合,这也增加了构建模型的困难性。对于基于专业知识的方法,由于生产环境不可能完全相同,因此大部分专业模型没有很好的泛用性。

由于工业 4.0 更加注重设备自主运行,因此使用浅层和深度学习算法等基于数据驱动的方法成为主流^[2]。目前主要使用的深度学习算法包括卷积神经网络(CNN)、递归神经网络(RNN)、自动编码器(AE)和受限玻尔兹曼机(RBM)方法等^[3]。Cheng 等^[4]指出 CNN 可以提取一维传感器的特征, Jin 等^[5]提出一种基于 CNN 的故障诊断算法,具有更少的参数。同时,基于 RNN 的模型也应用于时间序列以进行故障预测^[6-7],以及基于自动编码器的故障预测方法也取得了一定的效果^[8-9]。

长短期记忆网络(LSTM)由 Hochreiter 等^[10]提出,相较于传统的递归神经网络, LSTM 网络解决了 RNN 网络不能“记忆”的缺点,广泛应用于长时间跨度序列领域,在语音识别方面取得了巨大的突破。在故障预测中,最常用的深度学习算法是 CNN、RNN 以及自编码网络^[11]。近年来, Gao 等^[12]建立了一种基于 CNN-LSTM 的神经网络模型, CNN 用于从数据中提取特征, LSTM 则用来分析来自 CNN 的特征序列。张敬川等^[13]将 LSTM 与降噪自编码器(DAE)相结合来进行故障诊断,但是只用 LSTM 来提取时间序列特征的准确度不高,因此模型有待改进。Huang 等^[14]将 CNN-LSTM 模型应用于复杂

收稿日期: 2022-12-13

基金项目: 江苏省科技计划(BE2021750); 江苏省重点研发计划(BE2022135)

第一作者: 男, 1999 年生, 硕士生

* 通信联系人

E-mail: guobaozh@seu.edu.cn

系统故障检测,但是 CNN-LSTM 模型首先需要在离线状态下对模型进行训练,其次由于数据集中故障数据的不均衡,训练出的模型很难保证具有良好的效果,因此直接将其应用于过程故障预测可能达不到预期,需要对其做出改进。

局部异常因子算法(LOF)是基于密度的经典算法,由 Breunig 等^[15]提出,被广泛应用在异常值检测领域中,在数据挖掘以及深度学习领域可发挥重要作用。Ding 等^[16]通过评估观测数据与整体数据之间的偏差,应用 LOF 来检测光伏系统中的故障。Cheng 等^[17]使用基于隔离森林和局部离群因子算法的集成算法来进行数据集的异常值检测。Ortner 等^[18]将局部异常因子算法与稳健主成分分析法(ROBPCA)^[19]结合,并将其应用到高维异常值检测中。然而这些异常值检测算法都是基于当前状态的检测数据是否异常,无法对之后的状态进行预测,不能直接将其应用到时间序列,因此不能直接用于故障预测。

在设计用于故障预测的深度神经网络时,需要考虑如下问题:使用无监督方法很难准确预测到故障情况,而通过正常数据集训练模型再通过离线计算来预测故障情况是不准确的。因此本文从上述考虑出发提出了一种基于 CNN-LSTM-LOF 的故障预测方法,将 CNN-LSTM 模型用于特征提取,将 LOF 应用到对预测数据的异常值检测中,并且对提出模型在田纳西-伊斯曼(TE)过程数据集中进行验证,证明了模型的有效性和优越性。

1 基于 CNN-LSTM-LOF 的故障预测模型

1.1 CNN-LSTM 方法

本文将 CNN 与 LSTM 相结合,CNN-LSTM 的输入与输出均为多维时间序列数据,CNN 主要用于从时间序列数据中提取出数据特征,再将其送入 LSTM 网络中。LSTM 内部由 3 个门结构组成,分别是输入门、遗忘门和输出门。输入门主要是决定有多少输入可以进入模型,输出门是为控制最终输出多少数据而设计的,遗忘门则决定保留和遗忘上一个输出的哪几个部分。LSTM 将当前输入以及上一次输出一起训练,在最后加入全连接层,用于将前面层中提取的所有特征组合起来转换为特征数据。

首先,模型通过窗口对输入数据进行采样,采样

后一维时序数据为

$$X = [X_1, X_2, \dots, X_n] \quad (1)$$

其中 n 为数据序列的窗口长度。接着对数据进行标准化

$$X' = \frac{X - \mu}{\sigma} \quad (2)$$

式中, μ 表示数据的均值, σ 代表样本标准差。

在一维卷积过程中,卷积核在每个样本上滑动并进行卷积,卷积层输出维度由卷积核的数目确定,每个样本转化为特征图,公式如下。

$$F_i = \alpha(\omega^T X^{i:i+n-1} + \beta) \quad (3)$$

式中, ω^T 代表卷积核矩阵的转置, α 表示非线性激活函数, β 表示偏置变量, $X^{i:i+n-1}$ 代表从 i 到 $i+n-1$ 的输入变量。最后将多个特征图组成一维向量作为 CNN 的输出。

LSTM 中的遗忘门可以与输入门组合在一起,公式如下。

$$C_i = f_i C_{i-1} + i_i \tilde{C}_i \quad (4)$$

式中, f_i 为遗忘门的输出, C_i 为当前状态, i_i 数值为从 0 到 1,决定更新哪些值保留下来生成此时状态, \tilde{C}_i 为新的状态候选向量。输出门的作用是选取当前状态的一部分作为输出

$$h_i = o_i \tanh(C_i) \quad (5)$$

其中输出门就是将上一个状态与当前状态整合在一起作为当前状态的权重 o_i , C_i 经过一个 \tanh 激活函数与 o_i 相乘得到输出信号。

最后,在 LSTM 之后设置全连接层,将前面提取出的特征数据组合起来生成输出数据,公式如下。

$$y = \alpha(W_f h + \beta) \quad (6)$$

式中, α 是非线性激活函数, W_f 为全连接层的权重矩阵, β 为偏置向量, h 为输入向量,即 LSTM 网络的输出向量。

1.2 用于故障预测的混合网络

本文提出的 CNN-LSTM-LOF 模型完整的训练框架如图 1 所示。首先使用正常数据训练 LOF 模型,计算离线状态下异常值的大体范围,并且根据异常值的最大值进行一定的放缩,将其作为阈值来判断运行数据是否发生故障。多变量时间序列的长度由滑动窗口的大小决定,将采样后的数据帧送入 CNN 进行特征提取,模型采用 ReLU 激活函数,经过 LSTM 模型进行预测,并将结果送入离线状态下训练好的 LOF 模型中。LOF 会对 CNN-LSTM 预测的

时间序列进行异常值检测,并且标记每个数据,其中 +1 代表正常运行状态, -1 代表数据异常即发生故障。本算法计算每个窗口输出值中 -1 的个数,并与离线状态下计算好的阈值作比较。当异常值的数量大于阈值时,即代表预测窗口处于故障状态,从而实现故障预测的效果。由于在模型中应用了多个神经网络,带来了较多的超参数,这些超参数的选取均通过测试结果的优劣来设定。本文模型的预测时间主要由 CNN-LSTM 模型的计算时间以及滑动窗口采集数据的时间来决定。

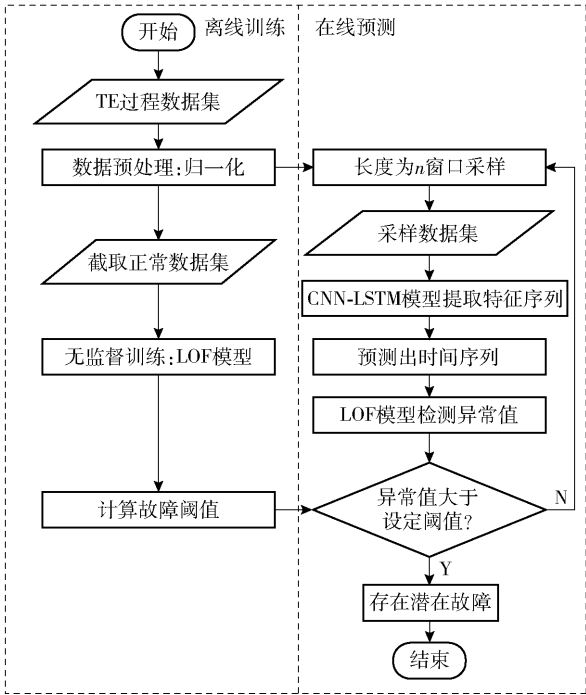


图 1 CNN-LSTM-LOF 模型故障预测框架
Fig. 1 Framework of the CNN-LSTM-LOF fault prognosis model

在所提模型中,首先使用 CNN-LSTM 来提取输入时间序列的特征,同时预测下一个状态的时间序列,然后使用 LOF 即基于密度的异常值检测算法进行检测,将检测结果与预处理的故障阈值进行比较,从而预测机器是否发生故障。完整的模型如图 2 所示。该模型首先通过窗口从数据集中截取一部分,将输入的数据进行标准化处理。本文中输入数据为 TE 数据集连续的时间变量,维度为 21 维。一维卷积神经网络卷积核的数目为 8,即卷积输出维度为 8,卷积窗口的长度为 13。在此之后为两层 LSTM 网络,其中第一层隐藏神经元的数量为 12,第二层神经元的数量为 6,输出结果为连续的时间序列,输出维度与神经元的数量一致。之后有两层全连接

层,第一层有 4 个神经元,第二层有 n 个神经元, n 的大小由输入维度唯一确定,在本文采用的模型中 n 的大小为 21,与输入时间序列相同。最后使用 LOF 算法对于预测数据进行异常值检测,将其与设定的故障阈值作比较。

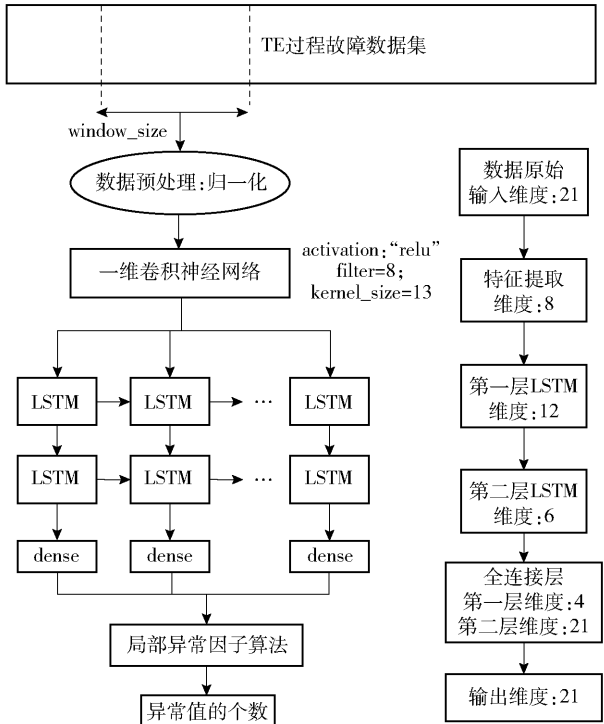


图 2 CNN-LSTM-LOF 故障预测模型
Fig. 2 Fault prognosis model based on CNN-LSTM-LOF

2 TE 过程验证

2.1 故障数据集

采用 TE 过程数据集对所提出的故障预测模型进行验证。TE 过程数据集模拟工业生产过程中的数据检测过程,同时模拟了 21 种不同故障条件下数据的变化情况,因此被广泛应用于故障诊断以及故障预测的模型验证中^[20]。如表 1 所示,数据集中一共包括 21 种故障类型。在每一种故障数据集中共有 52 个观测变量,其中 21 个变量是连续过程的观测变量,19 个变量是成分变量,12 个是操纵变量。由于故障预测依靠连续的时间序列来预测之后的状态,因此这里选择 21 个连续变量作为验证数据集,即作为模型的输入。故障 IDV1 ~ 7 与被观测变量的阶跃变化有关,故障 IDV8 ~ 12 的发生是由于观测变量的随机变化,故障 IDV14、15 和 21 与阀门有关,故障 IDV16 ~ 20 是没有被定义的故障,即故障原因不明。为了验证本文所提模型可以有效地进行

故障预测,即对于多故障及单故障有良好的预测效果,选择故障 IDV1、4 和 5 测试模型对于阶跃故障的准确性,选择故障 IDV11 和 12 来测试随机故障的发生情况,选择故障 IDV14 和 15 来测试模型对于黏性故障的预测效果。每一种故障数据集均包含 1 500 组数据,其中 1 000 个样本数据是正常操作下的,其余 500 组数据是故障情况下的数据。根据 1.2 节的网络训练模型,本文从正常样本中提取 500 组数据用于训练 LOF 模型,得到故障阈值,其余数据作为测试集对故障进行预测。

表 1 TE 故障过程

Table 1 Tennessee-Eastman process faults

故障编号	故障描述	故障类型
IDV1~3	物料含量改变	阶跃
IDV4	反应器冷却温度改变	阶跃
IDV5	冷凝器冷却温度改变	阶跃
IDV6	物料缺失	阶跃
IDV7	物料压力损失	阶跃
IDV8	物料组成比例改变	随机
IDV9、10	进料温度改变	随机
IDV11	反应器冷却温度改变	随机
IDV12	冷凝器冷却温度改变	随机
IDV13	动力学参数改变	漂移
IDV14、15、21	阀门粘住	黏性
IDV16~20	未知	未知

2.2 模型超参数调优


本文所提出的 CNN-LSTM-LOF 模型涉及较多的超参数,其中适应性矩估计(Adam)优化器中的学习率和迭代次数是两个重要的超参数,它们对于 CNN-LSTM 网络的运行时间以及故障预测的准确性有很大的影响。

为了确定 Adam 优化器中学习率的大小以及学习迭代次数,本文选择均方误差(mean square error, MSE)用于评估模型的性能。均方差为预测值与真实值之间差值的平方和的均值,利用均方差处处可导便于使用梯度下降法。MSE 可用于评价数据的变化程度,其值越小,说明模型的精准度越高。


$$E_{\text{MSE}} = \frac{1}{m} \sum_{i=1}^m (y_i - y'_i)^2 \quad (7)$$

式中, m 代表一次采样的样本数量, y_i 和 y'_i 分别为真实值与预测值。

图 3 显示了不同学习率下 CNN-LSTM 及 LSTM 方法的均方误差的变化情况。由图可知,学习率过大或过小都会导致均方误差收敛较慢,从而致使模型达到局部最优时间或运行时间过长。同时可以看出,使用 CNN-LSTM 方法明显比 LSTM 方法得到的均方误差更小,这主要是因为 CNN 对输入时间序列进行特征提取,使得 LSTM 预测的准确度更高。综合考虑 MSE 的收敛速度和所花费时间,本文选择模型的学习率为 0.01,迭代次数为 300。



(a) CNN-LSTM模型



(b) LSTM模型

图 3 学习率对于 Adam 优化器的影响

Fig. 3 The effect of learning rate on the Adam optimizer

另一方面,对本文所提模型有较大影响的是训练出的 LOF 模型的准确率。由图 2 可知,模型在离线状态下通过训练正常样本数据得到故障阈值,以确定在线状态下采样窗口的数据是否超过阈值,从而判断是否存在潜在的故障。阈值的计算方式如式(8)所示,阈值权值为根据不同的训练样本通过实验产生的经验值。

$$\text{Threshold} = \alpha * \max(\text{anomaly_cnt}) \quad (8)$$

式中, α 为设置故障阈值的权重, anomaly_cnt 为异常值的个数。经实验确定,异常值的比例为 0.000 06。

CNN-LSTM 模型的其他超参数如表 2 所示。

2.3 实验结果分析

将所提模型对于每一种故障数据集均进行了验

表 2 CNN-LSTM 模型的超参数

超参数	符号表示	数值
卷积核数目	filters	8
卷积窗口长度	kernel_size	13
Adam 优化学习率	learning_rate	0.01
迭代次数	epoch	300
批训练大小	batch_size	25

证。以 IDV12 故障为例,图 4 展示了模型预测值与实际值的对比情况,图中虚线代表 LOF 在离线状态下正常样本中训练出的故障阈值。由图可知,此时故障阈值为 25,当大于此阈值时即认为发生故障。从图 4 可以看出,在第 11 个采样窗口时模型认为发生了故障,比故障实际发生的时间提前了 1 个窗口采样时间。

将所提模型应用于其他故障数据集中,结果如图 5 所示。可以看出本文所提出的模型可以在故障发生前提前检测到故障,起到故障预测的效果。对于故障 IDV1、11、12 基本上可以提前 1 个采样窗口捕获到故障发生的征兆。模型的运行时间取决于模型迭代次数及窗口数据的大小,使用配备 Core i7、3.0 GHz 处理器以及 16 G 内存的计算机运行模型,对于迭代次数为 300 次、窗口大小为 100 的模型而言,模型运行时间大概在 100 s。近年来,尽管基于




图 4 基于 IDV12 的故障预测结果

Fig. 4 Fault prediction results based on IDV12

深度神经网络的数据预测方法已经广泛应用于故障预测领域,但是很少在 TE 数据集上进行验证比较。因此本文将所提模型与隐马尔可夫模型 (HMM)^[21]、CNN-LSTM-OCSVM (一类支持向量机) 模型^[22]进行比较,结果如表 3 所示。由表 3 可知,本文模型仅对故障 IDV5 没有及时检测到,对于其他故障本文提出的模型基本上可以在 1 个采样窗口内提前预知到故障情况,由于设置 TE 过程的采样周期为每 2 min 采集一次数据,因此平均下来可以提前 3 h 预知故障发生。与 HMM 相比,所提模型可以提前预测到故障发生;与 CNN-LSTM-OCSVM 相比,该模型同时又不会太早预测到故障,造成不必要的损失。

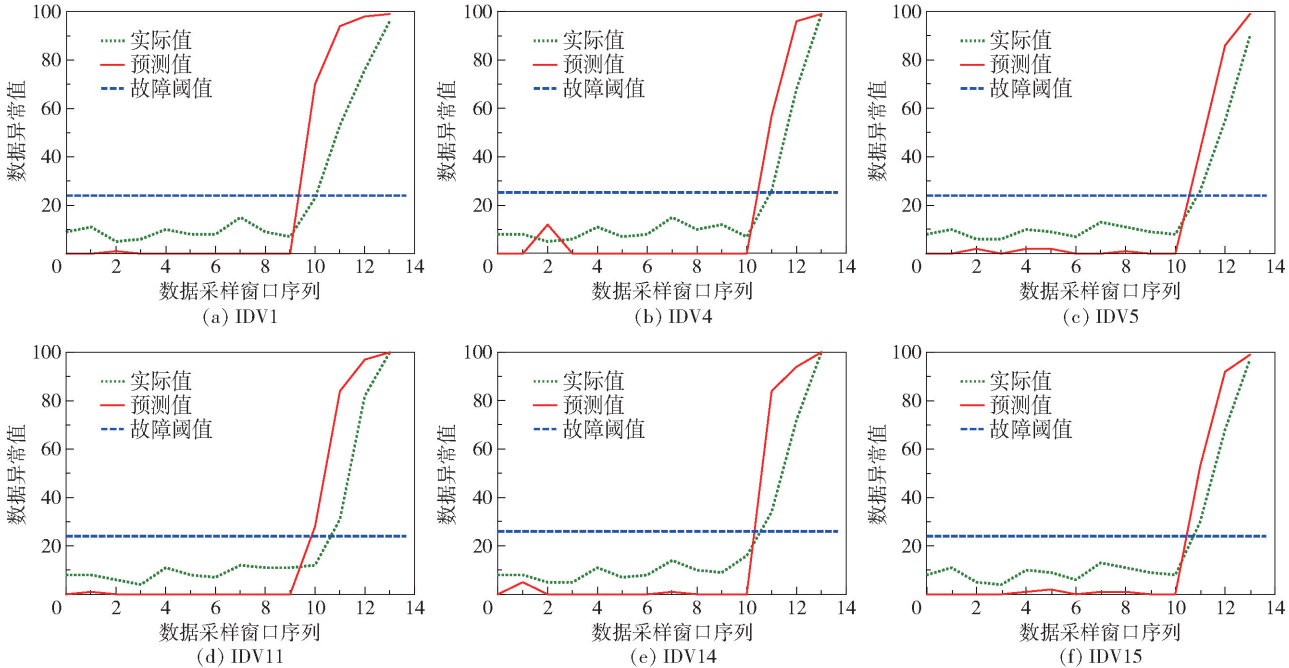


图 5 TE 过程故障预测结果

Fig. 5 Tennessee-Eastman process fault prediction test results

表3 故障预测模型比较
Table 3 Fault prognosis model comparison

故障类型	预测故障发生时间			实际故障 发生时间
	HMM ^[21]	CNN-LSTM- OCSVM ^[22]	CNN- LSTM-LOF	
IDV1	1020	850	955	1001
IDV4	1005	950	1050	1101
IDV5	1005	980	1030	1001
IDV11	1005	1000	1000	1101
IDV12	1250	1100	1100	1201
IDV14	1105	1100	1050	1101
IDV15	1150	1000	1100	1201

加粗数字代表未能及时预测出故障发生。

3 结论

本文提出了基于 CNN-LSTM-LOF 的故障预测方法,通过 CNN-LSTM 提取故障数据集特征,再使用训练好的 LOF 模型对预测出的数据进行异常值检测,从而实现故障预测的效果。将所提模型在 TE 过程数据集中进行验证,结果表明若故障是可观测的,则该模型可以尽早地预测故障状态。此外,还将该模型与 HMM、CNN-LSTM-OCSVM 等其他方法进行了对比,结果表明本文模型可以提前预测到故障发生,同时又不会过早报警,造成不必要的损失。然而随着网络的复杂程度加深,必然会带来模型超参数的增加,如何自适应地确定模型的超参数,是模型今后改善的一个方向。

参考文献:

[1] DJEZIRI M A, BENMOUSSA S, BENBOUZID M E H. Data-driven approach augmented in simulation for robust fault prognosis[J]. Engineering Applications of Artificial Intelligence, 2019, 86: 154 – 164.

[2] ARUNTHAVANATHAN R, KHAN F, AHMED S, et al. An analysis of process fault diagnosis methods from safety perspectives[J]. Computers and Chemical Engineering, 2021, 145: 107197.

[3] FERNANDES M, CORCHADO J M, MARREIROS G. Machine learning techniques applied to mechanical fault diagnosis and fault prognosis in the context of real industrial manufacturing use-cases: a systematic literature review[J]. Applied Intelligence, 2022, 52(12): 14246 – 14280.

[4] CHENG Y W, ZHU H P, WU J, et al. Machine health

monitoring using adaptive kernel spectral clustering and deep long short-term memory recurrent neural networks [J]. IEEE Transactions on Industrial Informatics, 2019, 15(2): 987 – 997.

[5] JIN T T, YAN C L, CHEN C H, et al. Light neural network with fewer parameters based on CNN for fault diagnosis of rotating machinery [J]. Measurement, 2021, 181: 109639.

[6] LIU C D, YAO R, ZHANG L X, et al. Attention based echo state network: a novel approach for fault prognosis [C]//Proceedings of the 2019 11th International Conference on Machine Learning and Computing. Zhuhai, 2019: 489 – 493.

[7] HOANG D T, KANG H J. A survey on deep learning based bearing fault diagnosis [J]. Neurocomputing, 2019, 335: 327 – 335.

[8] ZHANG C, LIM P, QIN A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2306 – 2318.

[9] VERSTRAETE D, DROGUETT E, MODARRES M. A deep adversarial approach based on multi-sensor fusion for semi-supervised remaining useful life prognostics [J]. Sensors, 2019, 20: 176.

[10] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735 – 1780.

[11] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks [J]. Reliability Engineering and System Safety, 2018, 172: 1 – 11.

[12] GAO Y, GONG P, LI L X. An end-to-end model based on CNN-LSTM for industrial fault diagnosis and prognosis[C]//2018 International Conference on Network Infrastructure and Digital Content (IC – NIDC). Guiyang, 2018: 274 – 278.

[13] 张敬川, 田慧欣. 基于 LSTM-DAE 的化工故障诊断方法研究[J]. 北京化工大学学报(自然科学版), 2021, 48(2): 108 – 116.

ZHANG J C, TIAN H X. Fault diagnosis of chemical process based on long short-term memory (LSTM)-denoising auto-encoder (DAE) [J]. Journal of Beijing University of Chemical Technology (Natural Science), 2021, 48(2): 108 – 116. (in Chinese)

[14] HUANG T, ZHANG Q, TANG X A, et al. A novel fault diagnosis method based on CNN and LSTM and its appli-

- cation in fault diagnosis for complex systems[J]. Artificial Intelligence Review, 2022, 55: 1289 – 1315.
- [15] BREUNIG M M, KRIEGEL H P, NG R T, et al. LOF: identifying density-based local outliers[C] // Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data. Dallas, 2000: 93 – 104.
- [16] DING H X, DING K, ZHANG J W, et al. Local outlier factor-based fault detection and evaluation of photovoltaic system[J]. Solar Energy, 2018, 164: 139 – 148.
- [17] CHENG Z Y, ZOU C M, DONG J W. Outlier detection using isolation forest and local outlier factor[C] // Proceedings of the Conference on Research in Adaptive and Convergent Systems. Chongqing, 2019: 161 – 168.
- [18] ORTNER T, FILZMOSER P, ROHM M, et al. Local projections for high-dimensional outlier detection [J]. Metron-International Journal of Statistics, 2021, 79: 189 – 206.
- [19] HUBERT M, ROUSSEUW P J, BRANDEN K V. ROB-PCA: a new approach to robust principal component analysis[J]. Technometrics, 2005, 47(1): 64 – 79.
- [20] DOWNS J J, VOGEL E F. A plant-wide industrial process control problem[J]. Computers & Chemical Engineering, 1993, 17(3): 245 – 255.
- [21] DON M G, KHAN F. Process fault prognosis using hidden Markov model-Bayesian networks hybrid model[J]. Industrial & Engineering Chemistry Research, 2019, 58(27): 12041 – 12053.
- [22] ARUNTHAVANATHAN R, KHAN F, AHMED S, et al. A deep learning model for process fault prognosis[J]. Process Safety and Environmental Protection, 2021, 154: 467 – 479.

A prognosis model for process fault based on CNN-LSTM-LOF

CHENG ZhiLei ZHANG GuoBao* HUANG YongMing

(School of Automation, Southeast University, Nanjing 210018, China)

Abstract: Fault prognosis is important in process systems since it can predict potential faults in industrial equipment in a timely manner and hence reduce the occurrence of accidents and economic losses. Due to the complexity of process systems and the uneven distribution of data sets, the conventional method of using the normal data set to predict the operating state offline is not versatile and inaccurate. In response to the above problems, this paper combines a convolutional neural network (CNN) with a long-short term memory network (LSTM) to extract the characteristics of boiler operating data and predict the operating state after online prediction. In the local outlier factor (LOF) model, the outliers of the time series are calculated and predicted. The results are compared with the fault threshold trained in the offline state, and if it is greater than the threshold, it is considered that there is a potential risk. The model was used in the Tennessee-Eastman (TE) process, and compared with traditional fault prognosis methods. The results show that the model performs well in multi-fault and single-fault prognosis, and outliers could be detected earlier by one sampling window. The results indicate the model has potential applications in fault prognosis in industrial process systems.

Key words: fault prognosis; Tennessee-Eastman process; long-short term memory; local outlier factor; convolutional neural network

(责任编辑:吴万玲)