

引用格式: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 JingChuan, TIAN HuiXin. 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.

基于 LSTM-DAE 的化工故障诊断方法研究

张敬川¹ 田慧欣^{1,2*}

(天津工业大学 1. 电气工程与自动化学院; 2. 电工电能新技术天津重点实验室, 天津 300387)

摘 要: 现代化工过程愈加精密化、复杂化,使得化工过程数据呈现高度非线性、强耦合等特点,传统的故障诊断模型难以学习此类数据的有效特征表示,且无法挖掘隐含的时间序列信息。针对上述问题,提出了一种长短期记忆(long short-term memory, LSTM)网络与降噪自编码器(denoising auto-encoder, DAE)结合的 LSTM-DAE 化工故障诊断方法,用基于 LSTM 的特殊编码方式代替传统 DAE 模型的全连接网络编码方式,并结合高斯噪声处理和全连接网络解码层,搭建出基于 LSTM-DAE 的特征提取模型,最后由 Softmax 分类器输出故障诊断结果。该方法结合了 DAE 与 LSTM 的优点,确保了编码特征获取的有效性。使用田纳西-伊斯曼(Tennessee-Eastman, TE)过程数据设计所提方法与其他 5 类模型的对比实验,实验结果表明:在多故障诊断效果上,基于 LSTM-DAE 的化工故障诊断方法的训练集正确率达到了 96.02%,测试集正确率达到了 97.31%,平均误报率仅为 0.65%,平均漏检率仅为 3.19%,在 6 类模型中为最优;在单故障诊断效果上,基于 LSTM-DAE 的化工故障诊断方法能够提高对故障 14 的分辨能力,并缩短对故障 18 的检测延迟时间,有效降低了漏检率,表明所提方法能够在实际化工过程中进行有效的故障诊断。

关键词: 故障诊断; 田纳西-伊斯曼过程; 降噪自编码器; 长短期记忆网络; Softmax 分类器

中图分类号: TP277 **DOI:** 10.13543/j.bhxbzr.2021.02.014

引 言

随着现代化工过程愈加精密化、复杂化,其安全问题也逐渐受到重视。与其他工业过程故障相比,化工故障易引发毒气泄漏、爆炸等更大的危险事故^[1],因此,适用于现代复杂化工过程的故障诊断方法引起广泛的关注并得到不断的发展。近年来,该领域的故障诊断技术已形成了一个庞大的体系^[2-5],但由于化工过程的精确数学模型难以建立、专家经验的可移植性差等原因,基于解析模型和经验知识的方法的发展受到了极大限制;基于数据驱动的方法只需分析化工过程的历史数据即可进行有效的故障诊断,因而逐渐成为该领域的研究重点。

主成分分析(PCA)、核主成分分析(KPCA)、独立成分分析(ICA)、Fisher 判别分析(FDA)等多元统计方法^[6-9],以及 BP 神经网络(BPNN)、支持向量机(SVM)等^[10-11]人工智能领域的浅层故障诊断方法均已在故障诊断领域取得了重要应用。此外,多元统计方法与 BP 神经网络、支持向量机相结合的故障诊断研究也取得了重要成果^[12-14]。然而,这些故障诊断方法在处理高纬度、非线性、强耦合且具有时间序列信息的现代化工过程数据时,往往无法有效提取其特征,且无法分辨特征相似的故障类别,不能满足现代化工故障诊断的要求。

自编码器(auto-encoder, AE)作为一种无监督学习算法,已在现代化工故障诊断领域展现出比多元统计方法和浅层学习方法更好的诊断性能。冯倩玉^[15]提出一种基于降噪正交自编码器(denoising orthogonal auto-encoder, DQAE)的故障诊断算法,在自编码器基础上引入正交性和降噪处理,取得了较好的诊断效果,并在所提方法基础上进一步完善,解决了多故障同时发生的问题。Zheng 等^[16]提出了一

收稿日期: 2020-06-28

基金项目: 天津市自然科学基金(18JCYBJC22000);天津市企业科技特派员项目(19JCPTJC47600)

第一作者: 男,1998 年生,本科生

* 通信联系人

E-mail: tianhuixin@tiangong.edu.cn

种基于堆栈自编码器 (stacked auto-encoder, SAE) 的故障诊断模型, 结合 t 分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 算法和 density-based spatial clustering of applications with noise (DBSCAN) 聚类, 在田纳西-伊斯曼 (Tennessee-Eastman, TE) 过程中实现了无监督故障诊断。张祥等^[17]提出了一种基于 VAE-DBN (variational auto-encoder, VAE; deep belief network, DBN) 的故障诊断方法, 针对高维数据故障特征难以提取的问题, 将变分自编码器与深度置信网络相结合, 在 TE 过程实验中展现出了较好的诊断性能。此外, 基于其他深度学习技术的故障诊断方法也在不断发展, 如基于深度置信网络及其派生网络^[18-20]、基于卷积神经网络 (convolutional neural network, CNN) 及其派生网络^[21-24], 以及基于深度残差网络 (deep residual network, DRN) 的模型在化工故障诊断领域的应用^[25]等。然而上述方法在处理现代化工过程数据时, 忽略了数据中的长时间依赖关系, 提取到的故障特征不具备时间序列信息, 整体故障诊断性能仍有待进一步提升。

长短期记忆 (long short-term memory, LSTM) 网络是一种适用于时间序列数据的深度学习模型, 最早由 Hochreiter 等^[26]提出。LSTM 借助特殊的“门”结构, 解决了传统循环神经网络 (recurrent neural network, RNN) 的长期依赖问题, 在语音识别、语言翻译等领域都取得了巨大成功。近年来, LSTM 在机械故障诊断领域也取得了一定的研究成果, 如 Yuan 等^[27]将 LSTM 用于航空发动机的剩余寿命预测, Lu 等^[28]将 LSTM 用于滚动轴承的早期故障预测, 王路瑶等^[29]将 LSTM 用于空调系统传感器故障的检测与诊断。在化工故障诊断领域, LSTM 的应用研究则相对较少。Zhao 等^[30]将 LSTM 用于连续数据的故障诊断, 并在 TE 实验中验证了该方法的有效性, 然而该方法所用的 vanilla LSTM 相对于其

他 LSTM 变体的效果并不好, 且实验结果易受随机噪声的影响, 故障诊断性能仍有待提升。

本文提出了一种基于长短期记忆网络与降噪自编码器结合的 LSTM-DAE 化工故障诊断方法, 针对传统 DAE 模型无法提取时间序列信息的缺点, 引入 LSTM 对模型结构进行优化, 并在 TE 过程仿真实验中验证了所提方法的有效性和优越性。

1 基于 LSTM-DAE 的故障诊断模型

传统的基于 DAE 的故障诊断模型以 3 层的全连接层为特征提取网络, 其输出节点数与输入节点数保持一致, 均为原始数据的维度; 隐层激活函数采用线性函数, 以保证特征表示不被限制; 以均方误差为损失函数, 并以最小化重构误差为目标, 用梯度下降算法进行训练。训练之前在原始数据中加入高斯噪声, 这样可以迫使模型学习原始数据的特征表示, 增强模型的鲁棒性。训练完成后, 提取隐层输出即为特征。

学习特征提取步骤完成后, 提取 DAE 模型的编码网络, 在隐层节点后加上 3 层的 Softmax 分类器, 利用神经网络全连接层强大的非线性处理性能来学习故障分类。Softmax 分类器的输入节点数为特征的维度, 输出节点数为故障类别数; 隐层采用 Sigmoid 激活函数, 输出层采用 Softmax 函数, 选择交叉熵损失函数并采用梯度下降法训练。训练完成后得到的 DAE 模型虽然能够克服随机噪声的影响, 并对原始数据进行有效的特征提取, 但是由于其特征提取网络为浅层模型, 特征学习能力受到限制。此外, DAE 模型的全连接层结构决定了它无法提取原始数据中的时间序列信息。

为了提高模型的特征学习能力, 并挖掘原始数据中的时间序列信息, 引入 LSTM 对 DAE 模型进行改进, LSTM 中“遗忘门”、“输入门”、“输出门”3 种门结构以特殊的方式进行交互, 构成了其独特的网络结构, 如图 1 所示, 其中, x_{t-1} 、 x_t 、 x_{t+1} 表

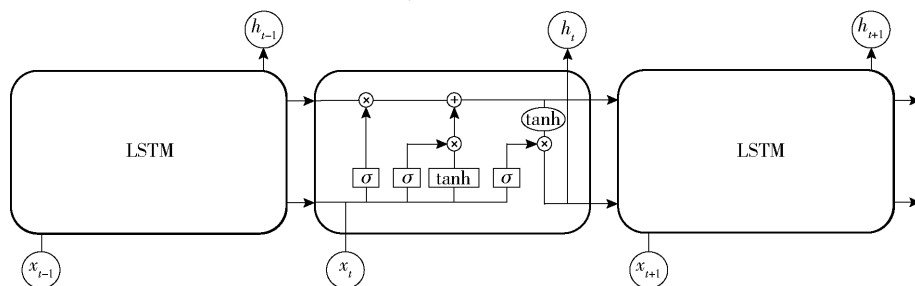


图 1 LSTM 的结构

Fig. 1 Structure of LSTM

示 LSTM 的输入, h_{t-1} 、 h_t 、 h_{t+1} 表示 LSTM 的输出; σ 和 \tanh 分别表示 Sigmoid 激活函数和 \tanh 激活函数; \times 表示向量之间按元素相乘, $+$ 表示向量之间按元素相加。

改进后模型的网络结构如图 2 所示, 原始 DAE 模型的全连接层编码网络被替换为 LSTM-DAE 编

码层。LSTM-DAE 编码网络的输入节点数为原始数据的维度, 其隐含层数为重要的超参数, 需经过验证集寻优; 在 LSTM-DAE 编码网络后, 加上由两个全连接层组成的解码网络, 其输出节点数与编码网络的输入节点数保持一致, 输出的激活函数采用 Sigmoid 函数。

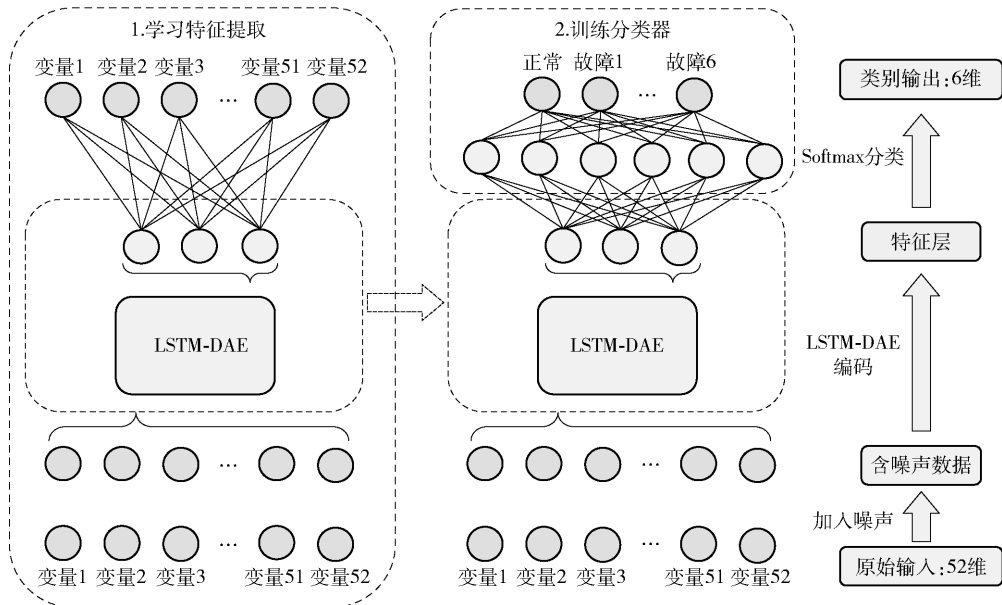


图 2 基于 LSTM-DAE 的故障诊断模型

Fig. 2 FD model based on LSTM-DAE

以最小化重构误差为目标, 用梯度下降法训练, 训练完成后提取 LSTM-DAE 编码网络的隐层输出即为原始数据的特征。此时得到的特征, 不仅由于 DAE 的强鲁棒性而不容易受到随机噪声的影响, 而且得益于 LSTM 特有的网络结构能在时间维度上存储原始数据的时间序列信息, 比改进前的 DAE 模型提取到的特征更准确、全面。

学习特征提取步骤完成后, 提取 LSTM-DAE 编码的网络部分, 在隐层节点后加上新的 Softmax 分类器并训练, 最终得到基于 LSTM-DAE 的化工故障诊断模型, 该模型由 LSTM-DAE 特征提取和 Softmax 分类器这两部分组成。完整的故障诊断流程如图 3 所示。

2 TE 过程仿真实验

2.1 数据集与评价指标

TE 过程是美国田纳西州伊斯曼化学品公司对实际化工过程进行的计算机模拟, 被普遍用于过程控制、监控和诊断方法的评价。TE 过程包括 52 个观测变量, 21 种故障类型, 样本采集间隔为 0.05 h。

训练集正常样本在 25 h 运行仿真下获得, 观测数据总数为 500, 故障样本在 24 h 运行仿真下获得, 观测数据总数为 480; 测试集数据在 48 h 运行仿真下获得, 在第 8 小时引入故障, 因此观测数据的前 160 个为正常样本, 后 800 个为故障样本。

为分析所提模型的多故障和单故障诊断性能, 选择故障 1、2、6、14、18 共 5 类故障组成所需数据集。为了使测试集的实验结果能够准确描述模型的泛化能力, 测试集不参与模型的调优过程, 因此将原始训练集按照 7:3 的比例重新划分, 得到新的训练集和验证集。最终的训练集为 $2\,030 \times 52$ 矩阵 (2030 个样本, 每个样本均为 52 维向量), 验证集为 870×52 矩阵, 测试集为 $5\,760 \times 52$ 矩阵。

以正确率 (accuracy) 指标来评价模型的多故障诊断效果, 记作 A , 其定义为

$$A = \frac{N_c}{N_t} \times 100\% \quad (1)$$

式中, N_c 为正确分类的样本数, N_t 为样本总数。

对于单故障评价指标, 考虑到 TE 过程中存在的数据偏斜问题^[31], 引入误报率 R_{FA} (false alarm

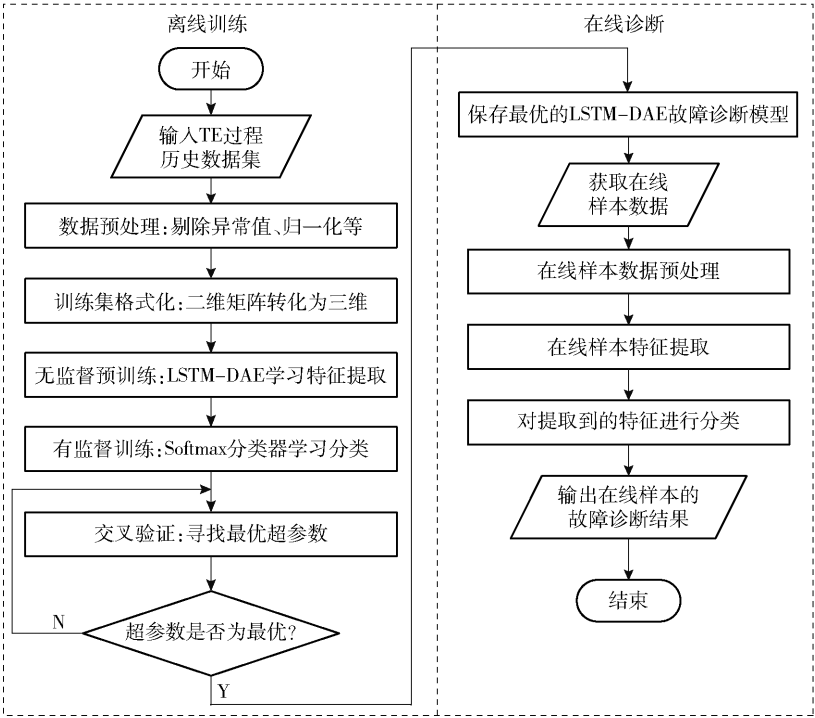


图3 LSTM-DAE 模型的故障诊断流程

Fig. 3 FD process of the LSTM-DAE model

rate, FAR)、漏检率 R_{MD} (miss detection rate, MDR) 两个指标,定义如下。

$$R_{FA} = \frac{FP}{FP + TN} \times 100\% \tag{2}$$

$$R_{MD} = \frac{FN}{TP + FN} \times 100\% \tag{3}$$

式中, FP 为假阳性数, TN 为真阴性数, FN 为假阴性数, TP 为真阳性数, 它们的定义如表 1 中的混淆矩阵所示。

表 1 单故障诊断的混淆矩阵

实际类别	定义	
	预测类别为 1	预测类别为 0
1	TP	FP
0	FN	TN

0 表示正常样本, 1 表示故障样本。

最后, 在单故障评价问题中, 引入故障检出点来表示模型实际检测到的故障发生的时间点, 其确定方法为, 在仿真实验引入故障后 (即从第 160 个样本点开始), 模型首次将样本判别为故障的时间点, 即为本次模拟的故障检出点。

2.2 模型超参数调优

本文提出的 LSTM-DAE 模型的可调参数很多,

其中 LSTM-DAE 编码网络的隐含层数、隐层节点数是两个重要的超参数, 对模型的正确率、平均误报率、平均漏检率, 以及模型整体运行时间的影响很大。

由于 LSTM 特殊的网络结构, LSTM-DAE 编码网络的隐含层数的选择受批训练大小的限制。在可选范围内选择 2、4、5、10、20 这 5 个值作为隐含层数的待选值。对每个取值重复 10 次平均实验, 得到训练集平均正确率、测试集平均正确率以及平均总运行时间随隐含层数的变化关系, 如图 4 所示。




图 4 正确率和运行时间随隐含层数的变化关系

Fig. 4 Variation in accuracy and running time as a function of the number of hidden layers

由图 4 可知, 随着隐含层数的增加, 总运行时间增加, 训练集正确率变化幅度不大, 测试集正确率整

体呈现出先升高再降低的趋势。表明随着模型结构的逐渐复杂,时间成本逐渐增加,模型的故障诊断效果不断提升。但过于复杂的模型结构不仅会使时间成本过高,而且反而会降低模型的故障诊断性能。因此,综合考虑时间成本和诊断性能,选择 10 作为隐含层数的最优取值。

采用同样的实验方法来确定 LSTM-DAE 编码网络隐层节点数的取值。训练集平均正确率、测试集平均正确率以及平均总运行时间随隐层节点数的变化关系如图 5 所示。




图 5 正确率和运行时间随隐层节点数的变化关系
Fig.5 Variation in accuracy and running time as a function of the number of hidden nodes

由图 5 可知,随着隐层节点数的增加,运行时间增加,训练集、测试集正确率均呈现出先升再降再升的趋势。当隐层节点数大于 22 时,尽管正确率较高,但由于模型结构过于复杂,时间成本剧增,因此在对各个因素权衡考虑后,选择 18 作为隐层节点数的最优取值。

LSTM-DAE 模型的其他超参数如批训练大小、迭代次数、学习率等的寻优结果如表 2 所示。在最

表 2 LSTM-DAE 模型的超参数

Table 2 Hyper-parameters of LSTM-DAE model			
超参数	符号表示	LSTM-DAE 特征提取部分	Softmax 分类器部分
隐含层数	<i>time_step</i>	10	
隐层节点数	<i>hidden_num</i>	18	40
学习率	α	0.012	0.01
正则化参数	<i>lambda</i>	0	0
Dropout 参数	<i>dropout_keep_prob</i>	1.0	1.0
迭代次数	<i>epochs</i>	1 000	1 000
批训练大小	<i>batch_size</i>	256	256
噪声系数	<i>decay_rate</i>	0.3	
学习率衰减率	μ		0.8
学习率衰减步数	<i>decay_steps</i>		100

优超参数取值下,模型的训练集正确率为 96.02%,测试集正确率为 97.31%,总运行时间为 48.366 s。

2.3 结果分析

为了验证所提 LSTM-DAE 模型中深层编码网络的有效性,引入 BP 神经网络(含 1 个隐层)、支持向量机两个浅层故障诊断模型进行对比分析;为验证 LSTM-DAE 模型相对于多元统计模型的优越性,引入 PCA、KPCA 两个故障诊断模型作对比分析;为验证 LSTM-DAE 模型引入 LSTM 后的改进效果,将其与原始 DAE 模型作对比分析。

2.3.1 多故障诊断效果

对所研究的 6 类模型均进行 5 次重复实验,实验结果如图 6 所示,记录 5 次实验的平均值如表 3 所示。由表 3 可知,LSTM-DAE 模型的训练集正确率高达 96.02%,测试集正确率高达 97.31%,平均误报率仅为 0.65%,平均漏检率仅为 3.19%。由图 6 可知 LSTM-DAE 模型 5 次实验的正确率不仅最高,而且变化幅度很小,结果更为稳定,表明 LSTM-DAE 模型不易受随机噪声影响,具有很强的鲁棒性。




图 6 6 类模型的正确率变化曲线
Fig.6 Variation in accuracy for the six models

表 3 6 类模型的各项评价指标

Table 3 Evaluation indicators of the six models				
模型	训练集 正确率/%	测试集 正确率/%	平均误报 率/%	平均漏检 率/%
BP	68.94	65.53	21.80	11.33
SVM	99.38	63.59	4.32	42.29
PCA	97.49	86.32	3.26	16.24
KPCA	97.85	90.34	3.77	9.76
DAE	93.40	95.54	1.31	7.88
LSTM-DAE	96.02	97.31	0.65	3.19

由图 7 可知,所提的 LSTM-DAE 模型与原始 DAE 模型的总运行时间较其他 4 类模型的运行时

间更长,这一方面是因为二者的模型结构更复杂,另一方面是它们的训练过程存在多次迭代过程,而 PCA 和 KPCA 模型均无此迭代过程。此外,相对于改进前的 DAE 模型,所提 LSTM-DAE 模型的总运行时间更短,且故障诊断效果更好,表明了所提方法的优越性。





图 7 6 类模型的运行时间对比

Fig. 7 Comparison of the running times of the six models

2.3.2 单故障诊断效果

通过观察单故障实时监测图(图 8),发现与原始 DAE 模型(改进前)相比,所提出的 LSTM-DAE 模型(改进后)对故障 14、故障 18 的诊断具有较好的改善效果,因此对其改善的原因作进一步



分析。

图 8(a)所示为故障 14 的实时监测图,可以看出 DAE 模型在引入故障 14 后仍会将大量故障样本误判为正常样本,而 LSTM-DAE 模型在引入故障 14 后几乎没有误判的情况。由表 4 可知,LSTM-DAE 模型将故障 14 的漏检率从 14.85% 降至 1.38%,而改进前后的故障检出点却仅仅相差 2 个样本点。以上结果表明:在故障 14 上,LSTM-DAE 模型并没有明显缩短故障的检测时间,而是在故障发生后提高了对故障的辨别能力,大大减少了误判的情况,从而改善了对故障 14 的诊断效果。

图 8(b)所示为故障 18 的实时监测图。LSTM-DAE 模型的故障检出点显然比 DAE 模型更靠前。由表 4 可知,改进前后两者的故障检出点相差 82 个样本点,即缩短了 246 min 的检测时间,从而使故障 18 的漏检率从 16.90% 降低至 11.55%。以上结果表明:在故障 18 上,LSTM-DAE 模型有效缩短了故障的检测延迟时间,从而改善了对故障 18 的诊断效果。

经过以上分析可知,LSTM-DAE 模型不仅在多故障诊断效果上取得了比其他 5 类模型更高的正确率,而且在单故障诊断效果上也能够获得更低的漏检率,表明了所提方法的有效性和优越性。




图 8 改进前后的故障实时监测图

Fig. 8 Real-time monitoring curves of the models before and after improvement

表4 改进前后模型的单故障诊断效果对比
Table 4 Single fault diagnostic effects before and after improvement

模型	故障检 出点 ^{a)}	漏检 率 ^{a)} /%	故障检 出点 ^{b)}	漏检 率 ^{b)} /%
DAE 模型(改进前)	162	14.85	265	16.90
LSTM-DAE 模型(改进后)	164	1.38	183	11.55

a—故障 14;b—故障 18。

3 结论

(1)提出了基于 LSTM-DAE 的化工故障诊断方法,用基于 LSTM 的特殊编码方式代替了传统 DAE 模型的全连接网络编码方式,并结合高斯噪声处理和全连接网络解码层,搭建出基于 LSTM-DAE 的特征提取模型,最后由 Softmax 分类器输出故障诊断结果。所提模型不仅具备 DAE 模型的强鲁棒性,而且由于引入了 LSTM,使之能够挖掘数据中的时间序列信息,保证了编码特征获取的有效性。

(2)在多故障诊断效果上,所提 LSTM-DAE 模型的训练集正确率达到了 96.02%,测试集正确率达到了 97.31%,平均误报率仅为 0.65%,平均漏检率仅为 3.19%,整体诊断效果优于 BP 神经网络、SVM、PCA、KPCA、DAE 这 5 类故障诊断模型。

(3)在单故障诊断效果上,LSTM-DAE 模型提高了对故障 14 的辨别能力,缩短了对故障 18 的检测延迟时间,获得了比 DAE 模型更好的故障诊断效果。

所提 LSTM-DAE 模型不仅能够快速、准确地诊断故障,而且具有鲁棒性好、泛化能力强等优点。然而随着深度学习技术的不断发展,随之而来的问题也不断增加,如深度学习模型的网络结构愈加复杂,造成模型的超参数越来越多,超参数的调节也更加困难。如何结合智能优化算法(如遗传算法、蚁群算法)对超参数自动寻优,都是今后具有重要研究意义的方向。

参考文献:

[1] 胡志新. 基于深度学习的化工故障诊断方法研究[D]. 杭州: 杭州电子科技大学, 2018.
HU Z X. Research on chemical fault diagnosis methods based on deep learning[D]. Hangzhou: Hangzhou Dianzi University, 2018. (in Chinese)
[2] GE Z Q, SONG Z H, GAO F R. Review of recent re-

search on data-based process monitoring[J]. Industrial & Engineering Chemistry Research, 2013, 52(10): 3543 – 3562.
[3] VENKATASUBRAMANIAN V, RENGASWAMY R, YIN K, et al. A review of process fault detection and diagnosis Part I: quantitative model-based methods[J]. Computers and Chemical Engineering, 2003, 27(3): 293 – 311.
[4] VENKATASUBRAMANIAN V, RENGASWAMY R, KAVURI S N. A review of process fault detection and diagnosis Part II: qualitative models and search strategies[J]. Computers and Chemical Engineering, 2003, 27(3): 313 – 326.
[5] VENKATASUBRAMANIAN V, RENGASWAMY R, KAVURI S N, et al. A review of process fault detection and diagnosis Part III: process history based methods[J]. Computers and Chemical Engineering, 2003, 27(3): 327 – 346.
[6] 杜海莲, 苗诗瑜, 杜文霞, 等. 改进 PCA 方法在化工过程中的故障诊断研究[J]. 山东科技大学学报(自然科学版), 2017, 36(5): 16 – 22.
DU H L, MIAO S Y, DU W X, et al. Research on fault diagnosis of chemical process based on improved PCA method[J]. Journal of Shandong University of Science and Technology (Natural Science), 2017, 36(5): 16 – 22. (in Chinese)
[7] 韩敏, 张占奎. 基于改进核主成分分析的故障检测与诊断方法[J]. 化工学报, 2015, 66(6): 2139 – 2149.
HAN M, ZHANG Z K. Fault detection and diagnosis method based on modified kernel principal component analysis[J]. CIESC Journal, 2015, 66(6): 2139 – 2149. (in Chinese)
[8] LEE J M, QIN S J, LEE I B. Fault detection of non-linear processes using kernel independent component analysis[J]. The Canadian Journal of Chemical Engineering, 2007, 85(4): 526 – 536.
[9] 吕鹏飞, 闫云聚, 荔越. 基于马氏距离的改进核 Fisher 化工故障诊断研究[J]. 自动化学报, 2020, 46(11): 2379 – 2391.
LV P F, YAN Y J, LI Y. Research on fault diagnosis of improved kernel fisher based on Mahalanobis distance in the field of chemical industry[J]. Acta Automatica Sinica, 2020, 46(11): 2379 – 2391. (in Chinese)
[10] 陈剑雪. ACO-BP 算法在化工过程故障诊断中的应用[J]. 化工自动化及仪表, 2012, 39(7): 872 – 875.
CHEN J X. Application of ACO-BP algorithm to fault diagnosis in chemical process[J]. Control and Instruments

- in Chemical Industry, 2012, 39(7): 872 – 875. (in Chinese)
- [11] 张鑫, 胡瑾秋, 张来斌, 等. 基于 RS 和 SVM 的化工过程高精度故障诊断方法[J]. 石油学报(石油加工), 2017, 33(4): 777 – 784.
- ZHANG X, HU J Q, ZHANG L B, et al. High-accuracy fault diagnosis of chemical processes based on RS and SVM[J]. Acta Petrolei Sinica (Petroleum Processing Section), 2017, 33(4): 777 – 784. (in Chinese)
- [12] 冀丰偲, 余云松, 张早校. LDA_SVM 方法在化工过程故障诊断中的应用[J]. 高校化学工程学报, 2020, 34(2): 487 – 494.
- Ji F C, YU Y S, ZHANG Z X. Application of LDA and SVM method in fault diagnosis of chemical process[J]. Journal of Chemical Engineering of Chinese Universities, 2020, 34(2): 487 – 494. (in Chinese)
- [13] 谭莉, 于春梅. 基于 PCA-LVQ 神经网络的化工过程故障诊断[J]. 工业控制计算机, 2016, 29(11): 86 – 87.
- TAN L, YU C M. Chemical process fault diagnosis based on PCA – LVQ neural network[J]. Industrial Control Computer, 2016, 29(11): 86 – 87. (in Chinese)
- [14] 薄翠梅, 乔旭, 张广明, 等. 基于 ICA-SVM 的复杂化工过程集成故障诊断方法[J]. 化工学报, 2009, 60(9): 2259 – 2264.
- BO C M, QIAO X, ZHANG G M, et al. ICA – SVM based fault diagnosis method for complex chemical process[J]. CIESC Journal, 2009, 60(9): 2259 – 2264. (in Chinese)
- [15] 冯倩玉. 基于降噪正交自编码器的 TE 过程故障诊断[D]. 上海: 上海交通大学, 2018.
- FENG Q Y. Fault diagnosis based on denoising orthogonal auto-encoder in TE process[D]. Shanghai: Shanghai Jiao Tong University, 2018. (in Chinese)
- [16] ZHENG S D, ZHAO J S. A new unsupervised data mining method based on the stacked autoencoder for chemical process fault diagnosis[J]. Computers and Chemical Engineering, 2020, 135: 106755.
- [17] 张祥, 崔哲, 董玉玺, 等. 基于 VAE-DBN 的故障分类方法在化工过程中的应用[J]. 过程工程学报, 2018, 18(3): 590 – 594.
- ZHANG X, CUI Z, DONG Y X, et al. Application of fault classification method based on VAE-DBN in chemical process[J]. The Chinese Journal of Process Engineering, 2018, 18(3): 590 – 594. (in Chinese)
- [18] WANG Y L, PAN Z F, YUAN X F, et al. A novel deep learning based fault diagnosis approach for chemical process with extended deep belief network[J]. ISA Transactions, 2020, 96: 457 – 467.
- [19] 程焕新, 王建庆. 改进深度置信网络对 TE 过程故障诊断研究[J]. 电子测量技术, 2019, 42(9): 117 – 120.
- CHENG H X, WANG J Q. Improved DBN for TE process fault diagnosis[J]. Electronic Measurement Technology, 2019, 42(9): 117 – 120. (in Chinese)
- [20] 黄家华, 钱龙, 易军, 等. 基于参数优化的深度信念网络 TE 过程故障诊断[C]//第 30 届中国过程控制会议(CPCC 2019). 昆明, 2019: 15.
- HUANG J H, QIAN L, YI J, et al. Fault diagnosis in deep belief network based on parameter optimization for TE process[C]//Chinese Process Control Conference 2019. Kunming, 2019: 15. (in Chinese)
- [21] 衷路生, 吴春磊. 基于 AC-CNN 模型的过程故障识别[J]. 计算机工程与设计, 2020, 41(2): 542 – 549.
- ZHONG L S, WU C L. Fault recognition based on AC-CNN model[J]. Computer Engineering and Design, 2020, 41(2): 542 – 549. (in Chinese)
- [22] 程诚, 任佳. 基于自适应卷积核的改进 CNN 数值型数据分类算法[J]. 浙江理工大学学报, 2019, 41(5): 657 – 664.
- CHENG C, REN J. Improved CNN classification algorithm based on adaptive convolution kernel for numerical data[J]. Journal of Zhejiang Sci-Tech University, 2019, 41(5): 657 – 664. (in Chinese)
- [23] 王翔, 柯颀挺, 任佳. 样本重构多尺度孪生卷积网络的化工过程故障检测[J]. 仪器仪表学报, 2019, 40(11): 181 – 188.
- WANG X, KE L T, REN J. Chemical industrial process fault detection based on sample reconstruction multi-scale siamese CNN[J]. Chinese Journal of Scientific Instrument, 2019, 40(11): 181 – 188. (in Chinese)
- [24] 程诚, 任佳. 一种基于雷达图表示的数值型数据的 CNN 分类方法[J]. 信息与控制, 2019, 48(4): 429 – 436.
- CHENG C, REN J. A classification method of CNN for numerical data based on radar chart representation[J]. Information and Control, 2019, 48(4): 429 – 436. (in Chinese)
- [25] 衷路生, 夏相明. 基于深度残差网络的化工过程故障诊断[J]. 过程工程学报, 2020, 20(12): 1483 – 1490.
- ZHONG L S, XIA X M. Fault diagnosis for chemical processes based on deep residual network[J]. The Chinese Journal of Process Engineering, 2020, 20(12): 1483 – 1490. (in Chinese)

- [26] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735 – 1780.
- [27] YUAN M, WU Y T, LIN L. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network[C]// *IEEE/CSAA International Conference on Aircraft Utility Systems (AUS)*. Beijing, 2016: 135 – 140.
- [28] LU W N, LI Y P, CHENG Y, et al. Early fault detection approach with deep architectures[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(7): 1679 – 1689.
- [29] 王路瑶, 吴斌, 杜志敏, 等. 基于长短期记忆神经网络的数据中心空调系统传感器故障诊断[J]. *化工学报*, 2018, 69(S2): 252 – 259.
- WANG L Y, WU B, DU Z M, et al. Sensor fault detection and diagnosis for data center air conditioning system based on LSTM neural network [J]. *CIESC Journal*, 2018, 69(S2): 252 – 259. (in Chinese)
- [30] ZHAO H T, SUN S Y, JIN B. Sequential fault diagnosis based on LSTM neural network[J]. *IEEE Access*, 2018, 6: 12929 – 12939.
- [31] GONG J, KIM H. RHSBoost: improving classification performance in imbalance data[J]. *Computational Statistics and Data Analysis*, 2017, 111: 1 – 13.

Fault diagnosis of chemical process based on long short-term memory (LSTM) –denoising auto-encoder (DAE)

ZHANG JingChuan¹ TIAN HuiXin^{1, 2*}

(1. School of Electrical Engineering and Automation; 2. Tianjin Key Laboratory of Advanced Electrical Engineering and Energy Technology, Tiangong University, Tianjin 300387, China)

Abstract: Modern chemical processes are becoming increasingly precise and complicated. It is difficult for traditional fault diagnosis (FD) models to learn the feature representation of raw data for high dimensional, nonlinear, and tightly coupled data. Furthermore, traditional FD models cannot extract the hidden time series information inside the raw data. Therefore, a novel FD model of chemical processes called LSTM-DAE based on long short-term memory (LSTM) and a denoising auto-encoder (DAE) has been proposed. By changing the full-connected encoding network of the traditional DAE model to a novel LSTM-DAE encoding network, and combining the Gaussian noise and fully-connected decoding network, a feature-extracting LSTM-DAE model has been established, with the final FD results given by a Softmax classifier. The proposed model combines the advantages of both DAE and LSTM, which ensures high efficacy in feature extraction. The experimental results for the Tennessee-Eastman (TE) process showed that in terms of multi-fault FD performance, the accuracy of the training set was 96.02%, the accuracy of the test set was 97.31%, the mean false alarm rate (FAR) was only 0.65%, and the mean miss detection rate (MDR) was only 3.19%, which is the best among all the six FD models. In terms of single-fault FD performance, the LSTM-DAE model can improve the resolution capability of fault 14 and reduce the delay time of fault 18, which reduces the MDR. The above analysis indicates that the proposed LSTM-DAE model can efficiently detect faults in actual chemical processes.

Key words: fault diagnosis; Tennessee-Eastman process; denoising auto-encoder; long short-term memory network; Softmax classifier

(责任编辑:吴万玲)