

DOI: 10.19650/j.cnki.cjsi.J1905469

样本重构多尺度孪生卷积网络的化工过程故障检测*

王 翔,柯颀挺,任 佳

(浙江理工大学自动化系 杭州 310018)

摘 要:基于数据驱动的故障检测已成为工业过程故障检测的重要手段,但在实际应用时受限于过程历史数据的规模,往往难以取得令人满意的检测精度。针对这一问题,提出了一种样本空间重构策略,该策略基于随机采样构造同类、异类样本对,在扩充数据规模的同时,将复杂的分类建模问题转化为样本间的相似度对比问题,降低了任务的复杂度。在此基础上,引入并改进孪生卷积神经网络(Siamese CNN)结构,提出了一种基于多尺度孪生卷积神经网络(Multi-scale Siamese CNN)的化工过程故障检测方法。田纳西-伊斯曼(TE)过程数据测试结果表明,所提算法的平均故障检测准确率达到 89.66%,相对于常规数据驱动的故障检测算法提高 8% 以上。

关键词:过程系统;故障检测;样本重构;多尺度;孪生卷积神经网络;田纳西-伊斯曼过程

中图分类号: TH7 **文献标识码:** A **国家标准学科分类代码:** 510.80

Chemical industrial process fault detection based on sample reconstruction multi-scale siamese CNN

Wang Xiang, Ke Liuting, Ren Jia

(Department of Automation, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: Data-driven based fault detection method has become important means for the fault detection of practical industrial processes, however, in practical application it is often limited by the size of process historical data, so that it is difficult to achieve satisfactory fault detection accuracy. In this paper, aiming at this problem a sample space reconstruction strategy is proposed, which constructs the sample pairs of the same or different categories based on random sampling. While the data size is expanded, the strategy transforms complex classification modeling problem into the comparison problem of the similarity among the samples, which effectively reduces the complexity of the task and the amount of the data needed for modeling. Based on the reconstruction strategy, the siamese CNN is introduced and improved, a chemical industrial process fault detection method based on Multi-scale Siamese Convolutional Neural Networks (Multi-scale Siamese CNN) is proposed. The test results on the Tennessee-Eastman (TE) process dataset verify the effectiveness of the proposed algorithm. The test results show that the average fault detection accuracy of the proposed algorithm reaches 89.66%, which is improved by 8% above compared with that of conventional data-driven fault detection algorithm.

Keywords: process system; fault detection; sample reconstruction; multi-scale; siamese convolutional neural network (CNN); Tennessee-Eastman(TE) process

0 引 言

随着科技的不断进步和发展,化工过程的生产规模不断扩大,其产生的经济价值也日益增加。但化工过程一旦发生事故,往往会造成较为严重的财产损失甚至人

身伤亡,故对化工过程进行故障检测便显得尤为重要^[1]。在故障早期发现过程中的错误可以有效防止发生严重的生产事故,一旦过程出现故障警报,操作人员便能及时纠正异常,使生产过程能够迅速回归正常条件。根据建模原理,故障检测方法可分为知识驱动建模、机理建模和数据驱动建模 3 大类^[2]。由于化工过程的工业系统高度集

收稿日期:2019-08-12 Received Date:2019-08-12

* 基金项目:浙江省自然科学基金(LY17F030024)、浙江省公益技术研究项目(LGG20F030007)资助、浙江理工大学基本科研业务费专项资金(2019Q032)

成且日益复杂化,基于知识和机理建模的故障检测方法较难应用于当前的化工过程中,因此数据驱动的智能故障检测方法受到越来越多的关注^[3]。数据驱动的智能故障检测方法又可进一步细分为统计方法、浅层学习方法和深度学习方法。统计方法包括主成分分析(principal component analysis, PCA)^[4-5]、独立成分分析(independent component analysis, ICA)^[6]、偏最小二乘法(partial least squares, PLS)^[7]、Fisher判别分析(fisher discriminant analysis, FDA)^[8]及其衍生方法。浅层学习方法包括支持向量机(support vector machine, SVM)^[9-11]、高斯混合模型(Gaussian mixture model, GMM)^[12]和人工神经网络(artificial neural network, ANN)^[13-14]。尽管这两类数据驱动方法在化工过程的故障检测中具有相当的优势,但其对化工过程数据具有的强非线性关系很难进行有效处理,且目前其所取得的故障检测的准确率仍未能很好地满足工业现场的要求。除此之外,化工过程训练数据的相对缺乏也一定程度上影响了模型的性能。

近年来,深度学习在许多领域中表现出更好的性能。因此,越来越多的专家学者开始尝试将深度学习应用于化工过程故障检测中。Sun等^[15]以无监督的方式建立深度置信网络并使用训练后的网络对测试数据进行重建从而实现自动检测故障。Zhao^[16]将PCA降维后特征正交这一特点引入自编码器,提出了一种神经主元分析算法并将其应用到故障检测中,取得了良好的检测效果。Yu等^[17]使用高斯受限玻尔兹曼机代替传统的受限玻尔兹曼机进行特征提取,并结合SVDD和核密度估计算法进行故障检测,进一步增强了模型的故障检测能力。

已有文献表明,基于深度学习的故障检测方法在多项应用中都取得了不错的表现,但利用深度学习方法建模通常需要大量的样本数据^[18],而在实际工业系统中,复杂的化工环境往往会导致无法获得足够的故障检测数据,这在一定程度上限制了深度学习方法在故障检测方面的应用与发展。

为解决上述样本数据不充分以及模型泛化能力不足的问题,本文提出一种基于样本对相似度的样本空间重构策略。基于原始样本,通过随机采样重新构建(正常工况、正常工况)、(正常工况、故障工况)样本对,从而使模型学习样本间的相似度并利用其加以分类。在测试阶段,本文通过将测试样本和多组正常工况下的样本做相似度对比,实现准确检测故障的目标。与普通的分类方法相比,本文所提出的样本重构策略不仅可以通过构建样本对扩充数据规模,而且能将基于特征的分类建模问题转化成样本间的相似度对比问题,从而降低任务的复杂度。在测试时通过与多组正常工况下的样本做相似度

对比,避免了随机因素对检测结果的影响,进一步增强了故障检测结果的稳定性。另一方面,针对浅层学习方法无法很好地捕捉工业化工数据之间的强非线性关系的问题,本文引入一种改进的多尺度孪生卷积网络(Multi-scale Siamese CNN)深度学习结构,该结构由两个卷积神经网络^[19]组成,两个网络共享权值。多个不同卷积核的卷积结构通过非线性降维能够有效地进行多尺度的特征提取以减少外界噪声干扰,共享结构能够自动提取相同的特征进而更好地学习样本间的相似度。最后将本文算法应用于田纳西-伊斯曼(Tennessee-Eastman, TE)化工过程中进行验证,与传统的机器学习算法相比,本文算法显著地提高了故障检测的准确率。

1 基于样本对相似度的样本空间重构

在实际化工企业生产现场,复杂的化工条件和生产安全的要求使得难以采集到足够的故障数据,而不论是浅层学习方法还是深度学习方法都需要大量的数据样本进行学习。因此,本文提出一种基于样本对相似度的样本空间重构方法,通过随机采样将重构后的样本对作为输入,令模型学习样本间的相似度并进行分类,具体表达式如下:

$$\begin{aligned} D_N &\longrightarrow \{n_1, n_2, n_3, \dots, n_k\} \\ D_F &\longrightarrow \{f_1, f_2, f_3, \dots, f_k\} \\ &\left\{ \begin{array}{l} (n^{(1)}, n^{(2)}, 1), (n^{(1)}, f^{(1)}, 0) \\ (n^{(3)}, n^{(4)}, 1), (n^{(3)}, f^{(2)}, 0) \\ \vdots \\ (n^{(2i-1)}, n^{(2i)}, 1), (n^{(2i-1)}, f^{(i)}, 0) \end{array} \right\} \end{aligned} \quad (1)$$

$$\begin{aligned} D_T &\longrightarrow \{t_1, t_2, t_3, \dots, t_k\} \\ D_N &\longrightarrow \{n_1, n_2, n_3, \dots, n_k\} \\ &\left\{ \begin{array}{l} (t_1, n^{(1)}), \dots, (t_1, n^{(i)}) \\ (t_2, n^{(i+1)}), \dots, (t_2, n^{(2i)}) \\ \vdots \\ (t_k, n^{((k-1)i+1)}), \dots, (t_k, n^{(ki)}) \end{array} \right\} \end{aligned} \quad (2)$$

式中: D_N 、 D_F 、 D_T 分别表示正常工况数据集、故障数据集以及测试数据集;下标 k 表示测试集样本数;上标 (i) 表示使用样本空间重构策略构成的样本对数。

训练集样本的重构过程如下:从正常工况数据集 D_N 中随机抽取一个样本记为 $n^{(1)}$,随后从 D_N 中再随机抽取一个样本 $n^{(2)}$ (此处为放回抽样)与 $n^{(1)}$ 构成正样本对 $(n^{(1)}, n^{(2)}, 1)$ (1为正向样本标签);接着,从某故障数据集 D_F 中随机抽取一个样本 $f^{(1)}$ 与 $n^{(1)}$ 构成负样本对 $(n^{(1)}, f^{(1)}, 0)$ (0为负样本对标签)。重复上述步骤次,构造对正负样本对放入训练集。

测试集样本的重构过程如下:针对测试数据集 D_r 中的每一个测试样本 t , 都随机从 D_N 中抽取多个样本与 t 构成样本对进行测试评估。假定当前输入为 t_1 , 则从 D_N 中随机抽取 i 个正样本 $n^{(1)}, n^{(2)}, \dots, n^{(i)}$, 分别将每一个正样本同 t_1 构成待检测样本对 $(t_1, n^{(1)}), (t_1, n^{(2)}), \dots, (t_1, n^{(i)})$ 。

通过上述方法实现逐对训练、批量对比预测, 分类模型所处理的问题从依据特征进行分类转化成了样本间的相似度对比, 进而在数据处理阶段为整个检测过程分解、降低了检测任务的复杂度, 为检测准确率的提高提供了更多的可能性和提升空间。

2 Multi-scale Siamese CNN 算法

2.1 Siamese CNN

卷积神经网络是目前深度学习领域最流行的网络结构之一, 主要由输入层、卷积层、降采样层、全连接层和输出层组成^[19-20], 其结构如图 1 所示。卷积层通过对输入数据进行卷积运算有效地提取特征、降低噪声, 并且卷积层具有稀疏连接和权值共享的特性, 能够有效地减少权值的数量。降采样层则使用某一位置相邻输出的总体统计特征来替代网络在该位置的输出的方式降低数据的冗余、提高网络的训练效率。作为特殊的多层前馈神经网络, 卷积神经网络通过不断交替使用卷积和降采样提取更丰富的高层次特征信息, 再经由全连接层整合多次卷积和降采样所提取的高度抽象化的特征, 最后通过输出层输出最终的分类结果。




图 1 卷积神经网络模型结构

Fig.1 Convolutional neural network model structure

孪生卷积神经网络 (Siamese CNN) 在传统的卷积神经网络基础上引入一种如图 2 所示的“孪生”网络结构^[21], 该结构由两个构造相同的卷积神经网络作为子网络构成, 两个子网络共享权值, 且参数更新在两个子网络中共同进行。

Siamese CNN 的输入为一对同类或异类样本对 $\{x_1, x_2\}$, 它们分别通过 CNN 提取特征并将特征非线性投影到低维向量空间 $Net(W, x_1)$ 和 $Net(W, x_2)$ 。采用共享权值的孪生网络结构能保证两个卷积神经网络提取到相同层次的特征。最后, 使用欧氏距离计算所提取到的低维特征之间的距离并将其作为所输入的样本对之间的相似度 DW 。

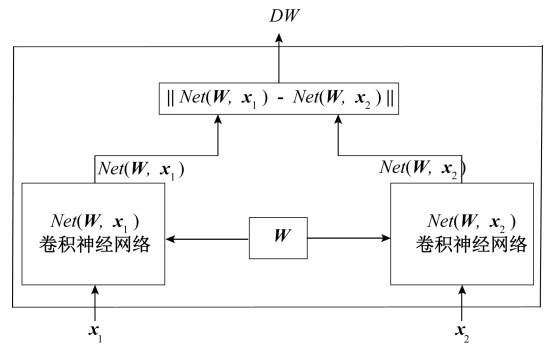


图 2 孪生网络结构

Fig.2 Siamese network structure

利用 Siamese CNN 能够有效对比输入样本之间相似度的特点, 本文基于 Siamese CNN 构造分类器模型, 使用如式 (3) 所示的交叉熵损失函数衡量网络的分类结果并通过其对整个网络的权值进行更新迭代。

$$L(W, b) = -\frac{1}{N} \sum_{v=1}^N (y_v \cdot \log p_v + (1 - y_v) \cdot \log(1 - p_v)) \quad (3)$$

式中: y_v 为第 v 个样本的期望值; p_v 为第 v 个样本预测为正样本的概率; N 为样本数。

2.2 多尺度特征提取

与图像数据不同, 化工过程数据的相邻特征之间并不一定存在很强的相关性, 即数据特征相邻与否并不影响特征之间的相关性。故若采用单个卷积核的卷积神经网络作为特征提取器, 将不可避免地受到特征排列顺序的影响, 从而导致模型难以有效完成故障检测任务。

针对上述问题, 本文使用多尺度卷积神经网络 (Multi-scale CNN) 来提取特征, 采用大小不同的卷积核进行多尺度的特征提取。通过将原始数据经由一层全连接层映射之后的数据、原始样本、与经过多尺度卷积神经网络之后的数据拼接在一起作为 $Net(W, x_i)$, 减小特征排列顺序对模型的影响。为了得到合适的模型, 本文尝试了几种不同的卷积核所构成的多尺度卷积神经网络模型, 并通过实验对比, 最终选择出如图 3 所示的模型结构。

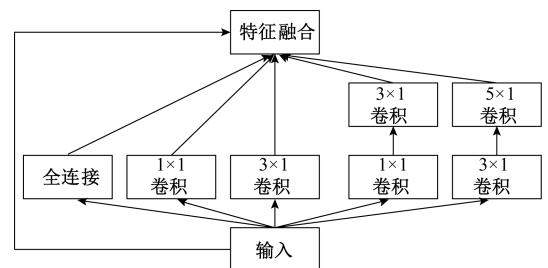


图 3 多尺度特征提取结构

Fig.3 Multi-scale feature extraction structure

2.3 批归一化

神经网络每一层参数的变化都会影响到该层输出数据的分布,这就导致通过反向传播算法训练网络时,每更新一次参数都需要考虑到输入分布的变化,无形中增加了网络训练的难度。针对此问题,尽管可以通过对网络进行合理的初始化和训练过程中仔细调整学习率来尽可能控制数据分布的变化,但依然难以完全避免该问题所带来的负面影响。

为了尽可能地减少上述问题对网络训练的影响,进一步加快网络的收敛速度,本文使用批归一化算法^[22]对网络的每一层进行归一化处理,针对每一个神经元的计算如式(4)所示。

$$\hat{X}_B = \frac{X_B - E[X_B]}{\sqrt{Var[X_B] + \varepsilon}} \quad (4)$$

式中: $X_B = \{x_1, x_2, x_3, \dots, x_m\}$; m 为当前一个批次的样本数; ε 是一个极小的正数。

但若仅使用上式对网络的每一层进行归一化处理,将会使得输入的分布被限制为正态分布,从而降低网络的表征能力。因此,需要引入额外的参数 γ 和 β 对数据进行缩放和偏移,计算如式(5)所示。

$$Y_B = \gamma \hat{X}_B + \beta \quad (5)$$

综上,假设当前网络某一层输入为 $\{x_1, x_2, x_3, \dots,$

$x_m\}$,批归一化之后的数据为 $\{y_1, y_2, y_3, \dots, y_m\}$,则批归一化算法详细实现步骤总结如下:

- 1) 计算当前输入样本的均值,记为 μ ;
- 2) 计算当前输入样本的方差,记为 σ^2 ;
- 3) 针对当前输入的每一个样本数据 x_g 都使用式(6)进行归一化:

$$\hat{x}_g = \frac{x_g - \mu}{\sqrt{\sigma^2 + \varepsilon}} \quad (6)$$

- 4) 归一化后的样本数据进行缩放和偏移:

$$y_g = \gamma \hat{x}_g + \beta \quad (7)$$

批归一化算法中的 γ 和 β 值的确定,与网络的权值一样,均通过网络根据损失函数自学习得到。在训练阶段,采用 2.2 节方法提取多尺度特征之后,使用批归一化算法对每一个尺度的特征进行归一化处理,加快网络的收敛速度。在测试阶段,本文并不使用训练阶段所得到的均值和方差的移动平均,而是重新根据每次批量输入的数据计算它们的均值和方差。

2.4 基于 Multi-scale siamese CNN 的故障检测

综上,本文提出一种基于样本重构策略的 Multi-scale Siamese CNN 故障检测方法,其整体流程如图 4 所示。整个模型分为离线建模训练和在线监控两个阶段。

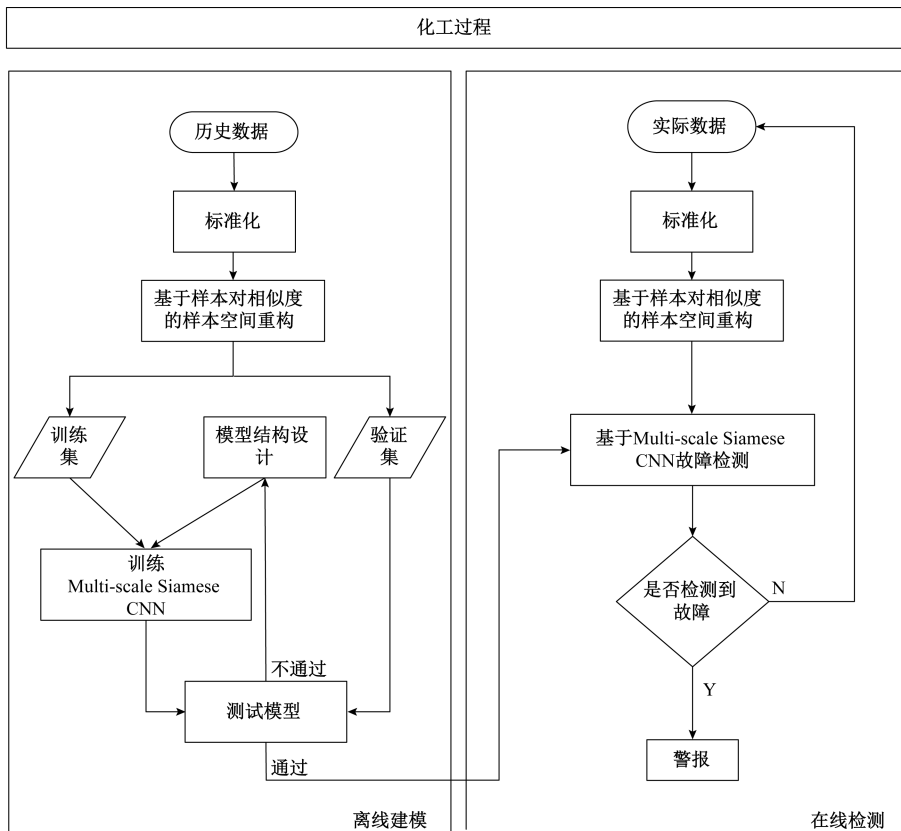


图 4 基于 Multi-scale Siamese CNN 的故障检测流程

Fig.4 The flow chart of Multi-scale Siamese CNN based fault diagnosis

在离线建模阶段,利用所收集的历史数据的变量的均值和方差对数据进行标准化处理并按第 1 节数据处理的方式重新构造成正负样本对的形式作为 Multi-scale Siamese CNN 的输入。在训练阶段对网络的优化采用 Adam 方法^[23],该优化算法可以自适应地调整各个参数的学习率,从而帮助网络更快收敛。模型训练完毕之后,通过验证集对模型的故障检测性能进行评估,若模型性能达到实际部署的要求,便将其投入实际的化工生产过程中进行在线故障检测,否则需要调整网络参数和架构重新训练。

进行在线故障检测时,从实际化工过程中采集待检测样本并进行标准化处理,对每个待检测样本都使用 Multi-scale Siamese CNN 算法将其与多组随机选取的正常样本进行对比得到检测结果,选取检测结果的中位数作为最终的检测结果。若最终检测结果显示存在故障,那么将触发警报系统,否则表示化工过程处于正常运行

状态。

3 算法测试与验证

3.1 TE 过程

TE 过程是基于伊斯曼化学品公司真实的工业化工过程所建立的仿真系统。作为工业化工领域的公开数据,TE 过程生成的数据具有非线性、强耦合和较强的动态特性,因而被广泛应用于各类故障检测和诊断算法测试中。TE 过程主要有 5 个操作单元:化学反应器、冷凝器、汽/液分离器、循环压缩机和汽提塔。过程中包含 A、B、C、D 和 E 5 种进料以及 F、G 和 H 3 种产物,更详尽的信息可参考文献^[24]。为了模拟真实的工业化工情况,TE 过程采用图 5 所示的控制结构进行仿真^[24],其 MATLAB 仿真程序可在网址 <http://depts.washington.edu/control/LARRY/TE/download.html> 获取。

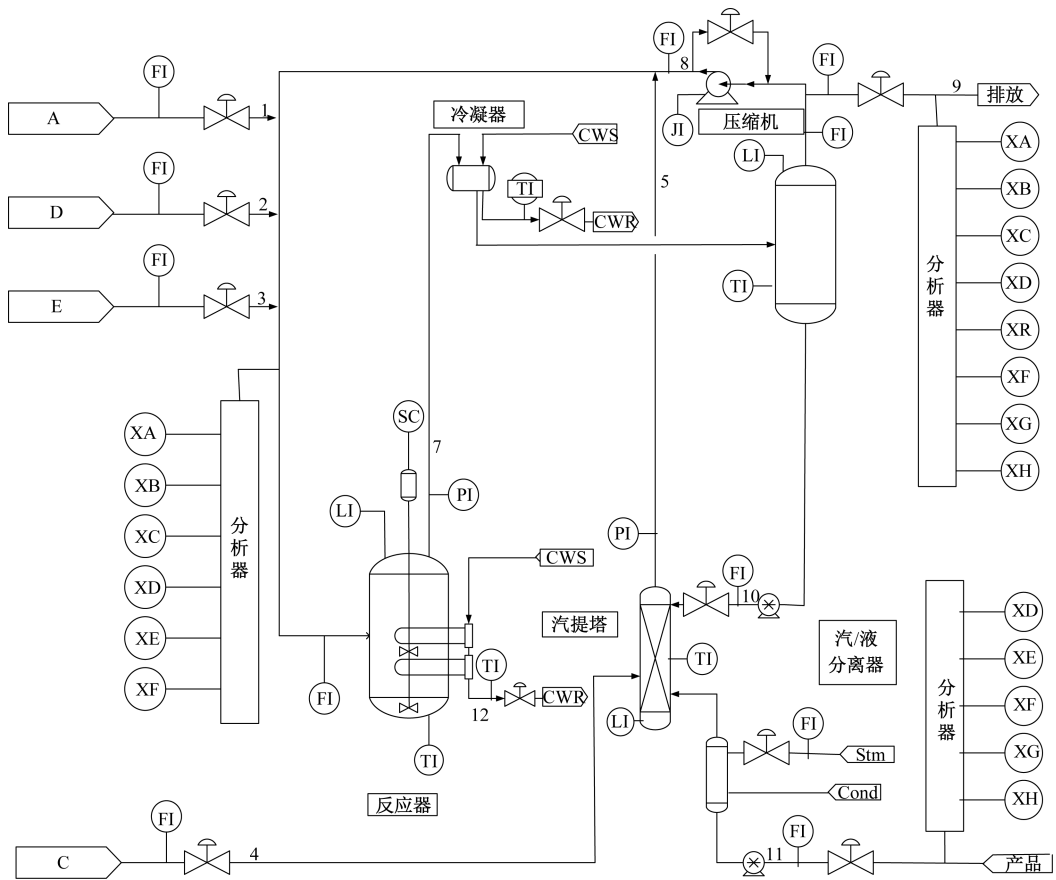


图 5 TE 过程工业流程

Fig.5 The flow chart of TE process industry

TE 过程中包含操作变量和测量变量两类变量,其中测量变量 41 个,操作变量 12 个(其中一个操作变量未进行控制),每 3 min 采集一次数据。本文所使用的 TE 过

程数据总共有 21 种故障类型,每种故障的数据集都包括 480 组训练数据和 960 组测试数据,其中测试数据中前 160 组为正常数据。此外,该数据集还包含了 500 组正

常条件下的数据作为训练集的一部分。

3.2 结果对比及分析

实验平台为配置 Intel i5-6500 3.20 GHz, 16 GB DDR4 RAM, 三星 750 EVO SSD, NVIDIA GTX 1060 的 PC 机。所有代码均基于 Python 语言在 Sklearn 和 Pytorch 框架下完成。利用 CUDA 和 cudnn 提供的并行加速能力实现快速的训练和检测任务。

为了验证本文提出的 Multi-scale Siamese CNN 算法的性能, 分别将 PCA、1-NN^[25]、线性核 SVM (linear-SVM)、径向基核 SVM (RBF-SVM)、以及基于样本空间重构策略的线性核 SVM (Siamese-SVM) 与 Multi-scale Siamese CNN 共 6 种算法应用到 TE 过程中进行测试。其中, Multi-scale Siamese CNN 训练和测试单次输入模型的批量数皆为 256, 学习率选择区间为 [0.000 1, 0.001], 优化算法采用 Adam 算法。

本实验采用第 1 节所介绍的样本对重构策略对 TE 过程数据集进行处理并生成实验所需的训练集和测试集, 从而对 Multi-scale Siamese CNN 和 Siamese-SVM 进行训练和测试, 且两者每次训练和测试所使用的数据量均相同。对常规的数据驱动故障检测算法 PCA、1-NN、linear-SVM 和 RBF-SVM 则采用未经处理的原始训练集和测试集, 即将正常工况下的数据分别和每种故障的训练集组合作为训练集, 测试集则采用 TE 过程所提供的每种故障采样得到的测试数据。6 种方法在 TE 过程故障数据集上的检测准确率如表 1 所示。

在表 1 中, 针对每类故障情况 IDV 1~IDV 21, 黑色粗体表示分类结果最好, 斜粗体表示分类结果最差。从表 1 中可以看出, 使用本文基于样本对相似度的样本空间重构策略进行训练的 Siamese-SVM 的平均故障检测准确率达到 86.27%, 远远超过在相同条件下的 linear-SVM 所能取得的平均故障检测准确率, 且即使同使用了高斯核函数来捕捉数据特征之间非线性关系的 RBF-SVM 相比, Siamese-SVM 同样优势明显, 尤其在对 IDV11、IDV 13、IDV 14、IDV 17、IDV 19 和 IDV 21 进行故障检测时, 其所取得的故障检测准确率相较于 RBF-SVM 提高了约 10%。上述实验结果表明, 在类似 TE 过程这类数据规模较小、特征间非线性关系强的化工过程数据中, 使用本文所提出的数据预处理方法将常规分类问题转化成样本间相似度对比问题可以有效地降低任务的复杂度, 进而即便采用较为简单的分类算法亦可取得较好的检测效果。

尽管 Siamese-SVM 算法可以较为准确地对化工过程进行故障检测, 但由于 Siamese-SVM 使用的核函数是线性核, 所以 Siamese-SVM 难以充分利用化工过程数据特征间的强非线性关系, 故本文在 Siamese-SVM 的基础上提出了 multi-scale Siamese CNN 算法。观察表 1 可知, 在

表 1 6 种方法在 TE 过程故障数据集上的检测准确率

Table 1 Detection accuracy of six different methods on

故障类型	TE process fault dataset (%)					
	方法					
	Multi-scale Siamese CNN	Siamese-SVM	RBF-SVM	Linear-SVM	1-NN	PCA
IDV1	99.38	99.69	99.38	99.90	87.88	99.88
IDV2	97.40	98.02	97.71	97.40	97.63	98.75
IDV3	74.90	68.13	61.67	45.10	44.50	12.88
IDV4	100.0	100.0	99.89	99.89	69.63	100.0
IDV5	87.40	77.81	99.79	99.90	59.88	33.63
IDV6	100.0	93.75	99.69	99.90	98.75	100.0
IDV7	100.0	100.0	99.90	99.90	80.13	100.0
IDV8	97.40	97.40	89.48	54.06	77.88	98.00
IDV9	58.54	53.96	58.44	50.73	44.50	8.38
IDV10	86.35	78.65	73.02	43.54	51.75	60.50
IDV11	86.46	83.75	69.38	45.83	39.38	78.88
IDV12	98.96	98.85	93.44	70.21	74.63	99.13
IDV13	95.83	95.10	82.60	47.29	64.75	95.38
IDV14	99.90	99.90	79.38	48.65	48.38	100.0
IDV15	68.75	60.73	63.36	55.73	47.00	14.13
IDV16	84.06	77.40	79.17	61.88	40.75	55.25
IDV17	93.02	95.10	82.50	94.17	54.75	95.25
IDV18	91.77	91.04	90.52	90.21	90.50	90.50
IDV19	84.17	82.81	71.35	50.21	64.50	41.13
IDV20	85.13	76.56	76.98	83.85	54.38	63.38
IDV21	93.39	83.13	26.88	25.00	46.00	52.13
平均	89.66	86.27	80.69	69.68	63.69	71.29
最优个数	15	3	0	2	0	5

总计 21 种不同类型的故障的检测中, 本文的 Multi-scale Siamese CNN 算法在其中 15 类故障的检测上皆取得了最佳的检测效果, 远优于其他算法。同时, multi-scale Siamese CNN 算法的平均故障检测准确率达到 89.66%, 高于 RBF-SVM、PCA 和 1-NN 等常规数据驱动的故障检测算法的准确率。此外, 针对传统故障检测算法难以检测的 IDV10、IDV19 和 IDV21, 采用 Multi-scale Siamese CNN 算法对其进行故障检测仍能达到较高的准确率。尽管 Multi-scale Siamese CNN 算法在其中 6 种故障 (IDV1、IDV2、IDV5、IDV12、IDV14 和 IDV17) 上的检测准确率不是最优, 但仍然取得了较好的结果, 进一步分析发现: 针对 IDV1、IDV2、IDV12 和 IDV14, 本文算法的准确率均达到了 97% 以上, 与最优算法的差距仅有 1% 左右。

对于 IDV17, 由于其训练数据存在噪声, 故复杂度较高的算法在该数据集上容易产生过拟合。虽然本文算法在 IDV17 上仅取得 93.02% 的准确率, 较最优算法低 2.25%, 但相对于 1-NN (54.75%) 和 RBF-SVM (82.50%) 的检测结果, 本文算法仍具有比较明显的优势。此外, 因 IDV5 存在较多冗余及非敏感特征, 故对神经网络的学习会产生较大的影响, 常规的神经网络模型在该数据集上的检测准确率为 59.88%, 本文算法尽管也受其影响, 但算法的检测准确率依然达到 87.40%。

上述实验结果进一步表明, 在使用基于样本对相似度的样本空间重构策略的基础上, 使用 Multi-scale Siamese CNN 对重构后的样本对进行多尺度特征提取, 可以有效地融合具有强非线性关系的化工过程特征, 增强模型对于非线性关系的处理能力, 从而进一步增强其故障检测效果, 是一种解决此类数据规模较小、变量间关系复杂的化工过程故障检测问题的可行方案。此外, 化工过程的故障检测强调实时性, Multi-scale Siamese CNN 的平均离线建模时间为 5.25 min, 在线预测时间为 1.5 ms, 其在线预测时间可以满足化工过程的故障检测实时性要求。

4 结 论

本文提出一种基于样本对相似度的样本空间重构策略, 通过将复杂的分类建模问题转化成样本特征间相似度对比问题, 有效地降低了问题的复杂度, 减少了模型对于数据量的需求。另一方面, 该策略使用逐对训练的方式巧妙地扩充了数据规模, 从而帮助模型取得更高的检测准确率。实验结果表明, 利用本文所提出的训练策略可以使得模型在同等条件下的故障检测准确率得到大幅提升。此外, 基于对模型非线性表征能力的考虑, 本文使用卷积神经网络对数据进行特征提取, 并对其进行改进, 提出 Multi-scale Siamese CNN 的复杂化工过程故障检测算法。该故障检测算法具有较高的故障检测准确率, 是较为前沿的工业故障检测方法。同时, 该算法为解决此类数据规模有限的复杂化工过程故障检测提供了新的思路。未来, 进一步研究考虑与数据增广技术相结合, 从数据源上解决化工过程故障数据不足的问题。

参考文献

[1] 齐咏生, 张海利, 高学金, 等. 基于 KECA 的化工过程故障监测新方法[J]. 化工学报, 2016, 67(3): 1063-1069.
 QI Y SH, ZHANG H L, GAO X J, et al. Novel fault monitoring strategy for chemical process based on KECA[J]. CIESC Journal, 2016, 67(3): 1063-1069.
 [2] VENKATASUBRAMANIAN V, CHAN K. A neural

network methodology for process fault diagnosis [J]. AIChE Journal, 1989, 35(12): 1993-2002.
 [3] 任佳, 马仕强. 时序局部加权自适应核 PLS 软测量建模及其应用[J]. 仪器仪表学报, 2018, 39(1): 1-7.
 REN J, MA SH Q. Locally weighted adaptive kernel PLS soft sensor modeling and its application for time-series data[J]. Chinese Journal of Scientific Instrument, 2018, 39(1): 1-7.
 [4] KRESTA J V, MACGREGOR J F, MARLIN T E. Multivariate statistical monitoring of process operating performance [J]. The Canadian Journal of Chemical Engineering, 1991, 69(1): 35-47.
 [5] 周卫庆, 司凤琪, 徐治皋, 等. 基于 KPCA 残差方向梯度的故障检测方法及应用[J]. 仪器仪表学报, 2017, 38(10): 2518-2524.
 ZHOU W Q, SI F Q, XU ZH G, et al. Fault detection method based on KPCA residual direction gradient and its application[J]. Chinese Journal of Scientific Instrument, 2017, 38(10): 2518-2524.
 [6] FAN J C, WANG Y Q. Fault detection and diagnosis of non-linear non-Gaussian dynamic processes using kernel dynamic independent component analysis[J]. Information Sciences, 2014, 259(20): 369-379.
 [7] ZHANG Y, HU Z. Multivariate process monitoring and analysis based on multi-scale KPLS [J]. Chemical Engineering Research and Design, 2011, 89(12): 2667-2678.
 [8] ZHU Z B, SONG ZH H. A novel fault diagnosis system using pattern classification on kernel FDA subspace[J]. Expert Systems with Applications, 2011, 38(6): 6895-6905.
 [9] KULKARNI A, JAYARAMAN V K, KULLKARNI B D. Knowledge incorporated support vector machines to detect faults in Tennessee Eastman process [J]. Computers & Chemical Engineering, 2005, 29(10): 2128-2133.
 [10] MAHADEVAN S, SHAH S L. Fault detection and diagnosis in process data using one-class support vector machines [J]. Journal of Process Control, 2009, 19(10): 1627-1639.
 [11] XIAO Y C, WANG H G, XU W L, et al. Robust one-class SVM for fault detection [J]. Chemometrics and Intelligent Laboratory Systems, 2016, 151(15): 15-25.
 [12] YU J, QIN SH J. Multimode process monitoring with Bayesian inference - based finite Gaussian mixture models[J]. AIChE Journal, 2008, 54(7): 1811-1829.
 [13] 陈科, 顾森茂, 郑红梅. 滚动轴承实时智能故障诊断算法研究[J]. 电子测量与仪器学报, 2018, 32(1): 66-72.

- CHEN K, GU S M, ZHENG H M. Research on real-time intelligent fault diagnosis algorithm for rolling bearing[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(1): 66-72.
- [14] AYUBI RAD M A, YAZDANPANA M J. Designing supervised local neural network classifiers based on EM clustering for fault diagnosis of Tennessee Eastman process [J]. Chemometrics and Intelligent Laboratory Systems, 2016, 151(15): 15-25.
- [15] SUN J, WYSS R, STEINECKER A, et al. Automated fault detection using deep belief networks for the quality inspection of electromotors [J]. Technisches Messe, 2014, 81(5): 255-263.
- [16] ZHAO H T. Neural component analysis for fault detection [J]. Chemometrics and Intelligent Laboratory Systems, 2018, 176(15): 11-21.
- [17] YU J B, YAN X F. Layer-by-layer enhancement strategy of favorable features of the deep belief network for industrial process monitoring [J]. Industrial & Engineering Chemistry Research, 2018, 57(45): 15479-15490.
- [18] 包萍, 刘运节. 不均衡数据集下基于生成对抗网络的改进深度模型故障识别研究[J]. 电子测量与仪器学报, 2019, 33(03): 176-183.
- BAO P, LIU Y J. Research on fault identification based on improved deep model in combination of generative adversarial networks under unbalanced data sets [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(03): 176-183.
- [19] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [20] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7): 134-143.
- QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 134-143.
- [21] CHOPRA S, HADSELL R, LECUN Y. Learning a similarity metric discriminatively, with application to face verification[C]. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2015: 539-546.
- [22] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. Proceedings of the 32nd International Conference on Machine Learning, 2015: 448-456.
- [23] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [24] DOWNS J J, VOGEL E F. A plant-wide industrial process control problem [J]. Computers & Chemical Engineering, 1993, 17(3): 245-255.
- [25] ASSIS B F, RAUBER T W, VAREJÃO F M. Evaluation of the extreme learning machine for automatic fault diagnosis of the Tennessee Eastman chemical process[C]. Conference of the IEEE Industrial Electronics Society, 2014: 2551-2557.

作者简介



王翔, 2017 年于浙江理工大学获得学士学位, 现为浙江理工大学硕士研究生, 主要研究方向为机器学习、深度学习及其在化工过程故障检测与诊断中的应用。

E-mail: wx15857152367@163.com

Wang Xiang received his B. Sc. degree from Zhejiang Sci-Tech University in 2017. Now, he is a M. Sc. candidate at Zhejiang Sci-Tech University. His main research interests include machine learning, deep learning and its application in fault detection and diagnosis of chemical industrial processes.



任佳(通信作者), 1999 年于华北电力大学获得学士学位, 2002 年于沈阳工业大学获得硕士学位, 2006 年于浙江大学获得博士学位, 现为浙江理工大学副教授, 主要研究方向为机器学习、智能优化算法及其在复杂工业中的应用。

E-mail: jren@zstu.edu.cn

Ren Jia (Corresponding author) received her B. Sc. degree in 1999 from North China Electric Power University, M. Sc. degree in 2002 from Shenyang University of Technology and Ph. D. degree in 2006 from Zhejiang University. Now, she is an associate professor in Zhejiang Sci-Tech University. Her main research interests include machine learning, intelligent optimization algorithm and its application in complex industrial process.