

研究论文

DOI: 10.11949/j.issn.0438-1157.20170973

基于双层 DAE-SOM 的多指标工况识别方法

李梦遥, 杜文莉, 钱锋

(化学工程联合国家重点实验室, 华东理工大学化工过程先进控制和优化技术教育部重点实验室, 上海 200237)

摘要: 由于工业过程常常受到扰动等因素影响导致工作点发生偏移, 所以及时准确地掌握过程运行状况的变化显得尤为重要。目前的工况识别主要针对是否发生故障或者发生何种故障, 很少有文献能够从安全、经济、故障等多方面考虑过程工况。针对这一问题, 结合过程的历史数据和相关操作要求, 获取不同安全状况、经济状况等的评判标准。基于这些判断准则, 使用双层降噪自编码(denoising autoencoder, DAE)方法提取数据特征, 并用自组织映射神经网络(self-organizing map, SOM)方法对特征提取后的数据聚类, 将过程的状况可视化到二维映射图上。在该方法中, DAE 方法可以降低工业过程扰动对数据的影响, 而 SOM 方法能够更好地实现过程性能的可视化监控。通过实验可以发现, 基于 DAE-SOM 的双层映射方法可以很好地判断系统的安全级别以及发生的故障类型、当前系统的经济效益状况等。

关键词: 降噪自编码; 自组织映射神经网络; 性能指标; 可视化; 双层映射; 工况识别

中图分类号: TP 277

文献标志码: A

文章编号: 0438—1157 (2018) 02—0769—10

Performance recognition method based on multi-index and multi-layer DAE-SOM algorithm

LI Mengyao, DU Wenli, QIAN Feng

(State Key Laboratory of Chemical Engineering, Key Laboratory of Advanced Control and Optimization for Chemical Processes, East China University of Science and Technology, Shanghai 200237, China)

Abstract: As disturbances and other factors often lead to shifting of work point in industrial process, it is particularly important to timely and accurately identify process changes. Current working condition identification methods mainly focus on whether or what fault occurs, but few consider process conditions from viewpoint of safety, economy, fault and other aspects. Decision criteria at different safety and economic conditions were proposed by combination of historical process data and related operational requirements. With these criteria, data characteristics was extracted by DAE method and extracted feature data was clustered by SOM method. Then, the process state was visually projected to two-dimensional maps. In this method, the DAE method can reduce influence of industrial process disturbance on data and the SOM method can better visually monitor process performance. Experimental study showed that the DAE-SOM multi-layer mapping method can determine security level, type of failure, and current economic efficiency of the system.

Key words: DAE; SOM; performance index; visualization; multi-layer mapping; condition recognition

2017-07-25 收到初稿, 2017-12-20 收到修改稿。

联系人: 杜文莉。第一作者: 李梦遥(1993—), 女, 硕士研究生。

基金项目: 国家自然科学基金重点项目(61333010); 国家自然科学基金面上项目(21376077); 国家自然科学基金优秀青年基金项目(61422303)。

Received date: 2017-07-25.

Corresponding author: Prof. DU Wenli, wldu@ecust.edu.cn

Foundation items: supported by the National Natural Science Foundation of China (61333010, 21376077, 61422303).

引 言

由于复杂工业过程常常受参数偏移和扰动等多方面因素影响导致工作点发生偏移,所以及时掌握过程运行状况的变化对提高企业的产品质量和经济效益等方面有重大实际意义。

目前,针对过程运行状况监测的研究有很多,这些研究主要集中于故障检测和诊断^[1-4]方面,即判断生产过程是“正常”还是“故障”,或者是发生了何种故障。然而对于实际生产过程,为了保证产品质量和提高经济效益,仅仅保证过程的安全生产是远远不够的,还应该尽可能使过程运行于最优状况,并且在过程非最优工况时向操作人员提示过程非最优的原因。因此,本文提出了一种基于数据的方法,综合考虑了历史运行过程中,工业系统不同状态下的数据以及一些操作要求,获取过程的一些安全、经济、故障指标。根据这些指标,判断当前过程的工况。传统的工况识别方法主要有主元分析(principal component analysis, PCA)^[5-6],它是一种线性降维方法,将非线性问题近似看作线性问题处理,不能保证有效地保存数据非线性特性。而实际的化工过程大多为复杂的非线性过程。自编码神经网络^[7-8] (AE)是一种非线性的无监督学习算法,具有结构简单、精度高的特点,广泛应用于人脸识别、情绪识别、文字识别、图像识别等领域^[9-13]。降噪自编码(DAE)^[14-16]由 Vincent 等^[17]提出,在基础自编码上,增强了抗扰动能力。自组织神经网络(SOM)^[18-19]是一种无导师学习网络,由 Kohonen^[20]在 1990 年提出。它的目标是将高维空间的点映射到低维空间中,并且尽可能保持点间的距离和邻近关系,即拓扑结构,具有很好的分类和可视化效果,能够把数据映射到二维平面图上。

本文采用了双层 DAE-SOM 方法检测过程工况。首先通过 DAE 方法对数据进行特征提取,保存数据的非线性并达到一定抗扰动功能,然后将提取后的数据通过 SOM 分类方法映射到一个二维平面图,从映射图中判断当前过程的运行状态。此外,为了更深一步地判断过程状态,本文还使用了 DAE-SOM 的双层映射方法,不仅可以判断过程的安全级别以及发生的故障类型,还可以判断当前系统的经济效益状况等。

1 DAE-SOM 算法介绍

1.1 DAE 算法

AE 可以视为一个 3 层神经网络:输入层、隐

层、输出层,其中输入层和输出层维数相同。首先将一个输入矢量 $\mathbf{x}=[x_1, x_2, \dots, x_d], \mathbf{x} \in [0, 1]^d$ 通过 $\mathbf{y}=f_{\theta}(\mathbf{x})=s(\mathbf{W}\mathbf{x}+\mathbf{b})$ 映射到 k 维隐层 $\mathbf{y} \in [0, 1]^k$ 。其中 $\theta=\{\mathbf{W}, \mathbf{b}\}$, $\mathbf{W}$ 是一个 $k \times d$ 维矩阵, $\mathbf{b}$ 是偏差矢量。 $s(\cdot)$ 通常取 sigmoid 函数,即 $s(z)=\frac{1}{1+e^{-z}}$ 。从 $\mathbf{x}$ 到 $\mathbf{y}$ 的过程也称编码过程。然后,将隐层 $\mathbf{y}$ 映射到 d 维输出层 $\mathbf{h}=g_{\theta}(\mathbf{y})=s(\mathbf{W}'\mathbf{y}+\mathbf{b}')$, $\theta'=\{\mathbf{W}', \mathbf{b}'\}$ 。 $\mathbf{W}'$ 一般为 $\mathbf{W}$ 的转置矩阵。这个过程称为解码。编码和解码的目的,就是将每个输入矢量 $\mathbf{x}^{(i)}$ 映射到一个输出矢量 $\mathbf{h}^{(i)}$,其中 $\mathbf{h}^{(i)}$ 是 $\mathbf{x}^{(i)}$ 的一个预测,所以要使 $\mathbf{h}^{(i)}$ 和 $\mathbf{x}^{(i)}$ 尽可能接近。通过最小化平均重构误差可以最优化参数

$$\begin{aligned} \theta^*, \theta'^* = \arg \min_{\theta, \theta'} & \frac{1}{n} \sum_{i=1}^n L(\mathbf{x}^{(i)}, \mathbf{h}^{(i)}) = \\ & \arg \min_{\theta, \theta'} \frac{1}{n} \sum_{i=1}^n L(\mathbf{x}^{(i)}, g_{\theta'}(f_{\theta}(\mathbf{x}^{(i)}))) \end{aligned} \quad (1)$$

其中, n 是输入矢量的个数, $L(\cdot)$ 是重构函数,本文的重构函数为交叉熵函数,即

$$L(\mathbf{x}, \mathbf{h}) = - \sum_{j=1}^d [x_j \lg(h_j) + (1-x_j) \lg(1-h_j)] \quad (2)$$

降噪自编码在基础自编码上,要求隐层上的示对数据扰动具有一定健壮性。基本思想是:首先,破坏输入向量 $\mathbf{x}$,通过 q^D 将某些值变为 0,然后基于这个被破坏了向量 $\tilde{\mathbf{x}}$,进行上述的编码解码过程,使解码后的输出向量 $\mathbf{h}$ 尽可能接近输入向量。如果输出向量能够很好地重构出原始的输入向量,那么网络具有健壮性。流程如图 1 所示。




图 1 DAE 方法流程

Fig.1 Flow chart of DAE method

DAE 一般作为一个降维技术来使用,隐层 $\mathbf{y}$ 被视为 $\mathbf{x}$ 的一种降维表示。在本文中,首先用 DAE 提取数据的特征,然后用 SOM 方法对降维后的数据聚类。为了证明用 DAE 降维后的数据,能够获得更好的聚类效果,本文首先采用几种常见的降维方法 PCA、KPCA、LDA、LLE、DAE 对 Iris 降维,图 2 显示的是 Iris 的原数据集(横纵坐标为前两维数据)以及经过不同降维方法降成 2 维后的数据集图像,从图中可以看出经过 DAE 降维后的数据,只有一小部分还重合在一起,会导致分类错误,而其




图2 降维后的 Iris 数据图像
Fig.2 Images of Iris data after dimension reduction

他降维方法产生的数据集，很难将其中蓝红两类的数据区分开，所以 DAE 方法有更好的特征提取效果。然后，使用几种降维方法对几个常见的数据集 Iris、Wine、Abalone、Glass 降维，并使用 K-means 方法对降维后的数据聚类。数据集的性质见表 1。

表 2 是几种方法和 K-means 结合后，聚类正确率、方差及聚类时间（单位为 s）的统计。可以看出，经过 DAE 降维后的数据聚类准确率相对较高，当然，在一定程度上，DAE 牺牲了运算时间。因此，可以预见用 DAE 方法对数据降维，再使用 SOM 将

表 1 聚类数据集

Table 1 Dataset for cluster

Data set	Cluster	Dimension	Sample size
Iris	3	4	150
Wine	3	13	178
Abalone	3	9	4177
Glass	6	10	214

降维数据聚类可以获得更好的可视化图像。

1.2 SOM 算法

SOM 算法的典型结构是输入层和输出层。输入层负责接收信息,并将信息向输出层传递。信息形式是一个输入矢量 $\mathbf{X} \in R^{n \times k}$, $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{ik}]$ ($i=1, 2, \dots, n$), 其中 n, k 分别是输入样本的数量和维数。输出层由一系列有序的神经元组成,一般是一些六角网格或者矩形。因为六角网格能提供更好的可视化效果,所以通常选择六角网格。输入输出层间通过与输入矢量同维的权重矢量连接

$$\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jk}] \quad j=1, 2, \dots, J \quad (3)$$

其中, J 是输出层神经元个数。因为 J 的大小影响 SOM 的精确性和泛化能力,它一般满足

$$J = 5\sqrt{n} \quad (4)$$

为了确定神经元的活化能力,一般选择“欧几里得距离”方法比较输入矢量和输出神经元的权重矢量。参考矢量偏差最小的神经元将被选为获胜神经元,选择函数定义如下

$$b_i = \arg \min_j \|\mathbf{x}_i - \mathbf{w}_j\|$$

$$i=1, 2, \dots, n; \quad j=1, 2, \dots, J \quad (5)$$

获胜神经元 b_i 选好后,获胜神经元的权重矢量会稍微朝着输入矢量方向更新。邻近神经元的权重矢量也会被更新,但是变化会更小。更新函数为

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + \alpha(t)h_{bj}(t)\|\mathbf{x}_i(t) - \mathbf{w}_j(t)\| \quad j=1, 2, \dots, J \quad (6)$$

其中, $\alpha(t)$ 是学习率参数, $h_{bj}(t)$ 是隶属函数。一般选择高斯函数作为隶属函数。定义输出层上第 j 个神经元位置为 $r_j \in R^2$, r_w 是获胜神经元位置,那么

$$h_{bj}(t) = \exp\left(-\frac{\|r_w - r_j\|^2}{2\sigma(t)^2}\right) \quad (7)$$

其中, $\sigma(t)$ 代表神经元的邻近宽度。为了达到收敛目的, $\alpha(t)$ 和 $\sigma(t)$ 初始设定一般较大,并会随时间 t 逐渐下降。当 $t \rightarrow \infty$, $\alpha(t) \rightarrow 0$, $\sigma(t)$ 趋近于一个很小的值(一般是 1)。

1.3 基于 DAE-SOM 算法的工况性能识别

为了解决非线性工业过程,结构复杂、维数高、样本多、存在扰动等问题,识别过程的经济、安全等状态,首先输入标准化后的数据集 $\mathbf{X} \in R^{n \times d}$, 采用 DAE 方法,根据式(1)、式(2)求解出 $\theta = \{\mathbf{W}, \mathbf{b}\}$ 的值,根据 θ 得到降维后的 k 维映射数据 $\mathbf{Y} = f_d(\mathbf{X}) = s(\mathbf{W}\mathbf{X} + \mathbf{b})$ 。将 $\mathbf{Y} \in R^{n \times k}$ 作为 SOM 方法的输入数据,根据式(4)确定神经元个数,根据式(3)随机初始化输入神经元权重。然后,通过式(5)选择获胜神经元,并通过式(6)、式(7)更新权重。最后,将训练结果输出到二维图上。具体步骤如下。

(1) 将输入训练数据 $\mathbf{X} = [\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(n)}]^T$ ($\mathbf{x}^{(i)}$ 为 d 维矢量)标准化为 $[0, 1]$ 的值。

(2) 通过 DAE 算法求解 $\theta = \{\mathbf{W}, \mathbf{b}\}$, 并得到降维后的数据集 $\mathbf{Y} = [\mathbf{y}^{(1)}, \mathbf{y}^{(2)}, \dots, \mathbf{y}^{(n)}]^T$, 其中 $\mathbf{y}^{(i)}$ 为 k 维矢量。

(3) 通过式(4)确定神经元个数 J , 并初始化权重 $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jk}]$, $j=1, 2, \dots, J$ 为 0 到 1 的随机值。

(4) 将数据集 $\mathbf{Y}$ 作为 SOM 方法的输入值,根据式(5)选择获胜神经元 b_i 。

(5) 根据式(6)和式(7)更新权重,直到 $\alpha(t) \rightarrow 0$, 此时神经元(权重)趋于聚类中心。

表 2 几种常见算法的降维效果比较

Table 2 Comparisons of several common algorithms for dimension reduction

Data set	K-means	PCA/K-means	KPCA/K-means	LDA/K-means	LLE/K-means	DAE/K-means
Iris	0.8070±0.0117 (2.37)	0.8337±0.0028 (2.36)	0.8467±1.34×10 ⁻¹⁵ (2.22)	0.8072±0.0188 (2.35)	0.72±6.69×10 ⁻¹⁶ (0.372)	0.9195±0.0038 (2.465)
Wine	0.7025±0.0022 (1.33)	0.966±0.00163 (1.26)	0.7661±0.0435 (1.58)	0.5939±0.0353 (2.27)	0.7806±0.0079 (5.06)	0.9663±8.9265×10 ⁻¹⁶ (5.37)
Abalone	0.4842±0.014 (2.19)	0.5121±7.19×10 ⁻⁴ (5.50)	0.4795±0 (58.9)	0.3702±0.0038 (4.35)	0.4878±1.17×10 ⁻⁴ (28.72)	0.5170±4.75×10 ⁻⁴ (43.13)
Glass	0.3576±0.0798 (2)	0.3948±0.0765 (1.54)	0.3087±0.0063 (1.52)	0.3158±0.1063 (1.77)	0.2927±0.0356 (1.52)	0.4067±0.0306 (4.59)

(6) 将聚类结果显示在二维六角网格上。

2 TE 过程工况识别

TE 过程是一个基于真实工业的过程,由 Downs 等^[21]提出。它广泛应用于不同的领域,如故障诊断、监控^[22-24]和优化^[25-26]等。在本文中,TE 过程用于生产过程的状态识别。

根据 Richer^[27-28]建立的仿真模型,改变 12 个操纵变量,获得 48 组不同状态下 TE 过程的运行数据。结合这些数据,以及文献^[21],将 TE 过程的性能范围分为 3 类,即 C1、C2、C3。其中 C1 表示过程发生了重大故障,这些故障可能导致停工,引起这些故障的原因见表 3。C2 表示那些会对产品组成产生影响的情况,产品约束条件见表 4。C3 是过程的利益指标,在确保过程能够安全稳定地产生产品之后,可以根据历史数据确定过程的经济效益范围,判断当前系统效益。由于工厂生产的主要目的是收获利益,所以应该使过程的利益最大化。根据获得的 48 组数据集,将 TE 过程的利益分为 7 个范围,见表 5 (假设产品 G、H 售价为成本的 2 倍, $\text{profit}(t)=p_G(t)+p_H(t)-c_1(t)-c_2(t)$, $p_G(t)$ 是产品 G 的收益, $p_H(t)$ 是产品 H 的收益, $c_1(t)$ 是操作价值, $c_2(t)$ 是原材料成本,忽略其他成本)。

表 3 引起重大故障原因

Table 3 Reasons for hard faults

Process variable	Normal operating limits		Shut down limits	
	Low	High	Low	High
	limit	limit	limit	limit
reactor pressure/kPa	—	2895	—	3000
reactor level/m ³	11.8(50%)	21.3(100%)	2	24
reactor temperature/°C	—	150	—	175
product separator level/m ³	3.3(30%)	9.0(100%)	1	12
stripper base level/m ³	3.5(30%)	6.6(100%)	1	8

在实验过程中,首先需要判断当前 TE 过程是否发生重大故障(C1),如果发生重大故障,则需要进一步确定故障原因,如反应器压力超界(F1)、反应器液位超限(F2)、反应器温度超限(F3)、产品分离

器液位超限(F4)和剥离器液位超限(F5)。在没有重大故障的条件下,确定生产的产品是否合格(C2)。最后,在产品合格时,确定过程当前利润空间(C3),并根据利润区间确定效益范围,在实验结果中,case1~7 用 P1~P7 表示。整个流程见图 3 (文中只考虑了 P1~P7 和 F1~F5 两种情况)。




图 3 双层 DAE-SOM 方法流程

Fig.3 Flow chart of multilayer DAE-SOM method

表 5 TE 过程经济效益评级

Table 5 Profits ranges for TE process

Case	Profit/USD·h ⁻¹
1	≥5200
2	5150—5200
3	5100—5150
4	5000—5100
5	4900—5000
6	4700—4900
7	≤4700

3 实验结果与仿真

本节使用双层的 DAE-SOM 方法评估系统的当前性能状况。首先,在第 1 层,判断系统安全状况,即处于 C1、C2 还是 C3 状态。C1 表示系统有重大故障, C2 表示有一些小故障导致产品不达标, C3 表示系统没有故障处于安全生产过程。而在第 2

表 4 产品约束条件

Table 4 Constraints for products

Product variability		Feed flow variability		
Flowrate changes	Composition variability	Stream 1	Stream 2	Stream 4
less than ±5% in range 8—16 h ⁻¹	less than ±5%(mol) G in range 6—10 h ⁻¹	minimize flow variability in range 8—16 h ⁻¹	minimize flow variability in range 8—16 h ⁻¹	minimize flow variability in range 12—80 h ⁻¹

层, 根据当前状态, 可以进一步对过程进行映射, 找到引起故障的原因(C1), 影响产品的因素(C2), 以及获得利润的范围(C3)。

3.1 过程的安全性能评估

根据表 3、表 4 和表 5 可知, C1 状态有 5 种情况, C2 状态有 5 种情况, C3 状态有 7 种情况。在这 3 种状态中分别选取一种情况作为训练样本。C1 选择压力过高样本, C2 选择组成变化样本, C3 选择 base case, 即 case 3 的利润样本。

首先选用简单 SOM 方法对数据分类, 结果见图 4。图 4(a)是 U 矩阵图, 在图中, 亮的部分表示数据的分界线, 分界越明显, 表示数据越分散。图 4(b)是数据的训练图, 图上的标签 C1、C2、C3 表示数据的类别, 括号中的数表示映射到当前网格的数据个数。结合图 4(a)、(b)可以看出, 3 组数据能够很好地区分开来。但是边界部分比较靠近, 容易引起错分类。DAE 方法有抗扰动功能, 使用 DAE 方法对数据进行预处理后, 可以获得更好地训练结果。图 5(a)、(b)是使用 DAE-SOM 方法后的训练结果, 与图 4 相比, U 矩阵图的边界更明显, 数据区分度更高。图 5(c)是测试效果, 选择了反应器压力超限的数据作为测试集, 但是引起压力超限的原因发生了变化, 可以看出, 该组数据能够很好地映射到 C1 范围内。同样地, 选择其他故障数据, 如反

应器液位超限等, 也可以得到正确映射结果。

Tian 等^[29]采用 LTSA-SOM 方法诊断 PX 氧化反应中的故障, 该方法能够很好地诊断出已知故障, 但对于未知故障可能会稍显不足。为了显示本文提出的方法对于未知类别数据诊断的优越性, 采用 LTSA-SOM 方法对 C1、C2、C3 数据可视化分类。在实验中, C2 表示影响产品质量的情况, 因为影响产品组成变化的因素非常多, 所以引起这一情况的原因也非常多, 因此, C2 最容易产生分辨错误。选择同样的 3 种情况作为训练数据, 但是测试数据选择 C2 中流量变化的数据。图 6(a)是 DAE-SOM 方法的测试结果, 可以看出, 测试数据仍然映射到了 C2 范围内, 所以对于不同原因引起的相同性能状况, 仍获得了很好的结果。图 6(b)、(c)是使用 LTSA-SOM 方法的 U 矩阵图和测试结果图, C1 和 C2 的 U 矩阵分界限并不明显, 且测试数据映射到了 C1、C2 中间, 虽然更靠近 C2 区域, 但是效果不如 DAE-SOM 方法。所以 DAE-SOM 方法可以更好地区分未知情况。

3.2 过程的故障诊断与经济效益评估

在 3.1 节的基础上, 当确定了系统的安全状况之后, 需要对过程的状态进一步研究。这里主要讨论了两种情况, 即 C1 故障诊断情况以及 C3 利益评级情况。




图 4 SOM 第 1 层映射结果

Fig.4 Mapping results for first layer based on simple SOM




图5 DAE-SOM 第1层映射结果

Fig.5 Mapping results for first layer based on DAE-SOM




图6 DAE-SOM 和 LTSA-SOM 对 C2 的映射结果

Fig.6 Comparison of DAE-SOM and LTSA-SOM algorithms for C2

3.2.1 故障检测 在 TE 过程中,可能会出现各种各样的故障,这些故障直接或间接地影响表3所示5个测量变量的变化。所以通过这5个变量来区分故障类型。这5个变量分别为反应器压力、反应器

液位、反应器温度、产品分离器液位以及剥离器基准液位。在 TE 仿真模型中^[27-28],改变操纵变量的值,可以发现反应器温度一般很难超过约束范围,所以这里只对其余4种情况讨论。根据4种不同故




图 7 DAE-SOM 第 2 层(故障检测)映射结果

Fig.7 Mapping results for second layer (fault diagnosis) based on DAE-SOM




图 8 FDA-SOM 第 2 层(故障检测)映射结果

Fig.8 Mapping results for second layer (fault diagnosis) based on FDA-SOM

障的数据,如表 3 所示,使用 DAE-SOM 方法建立 U 矩阵图[图 7(a)]和训练图[图 7(b)]。图中 F1 表示反应器压力超限, F2 表示反应器液位超限, F4 表示产品分离器液位超限, F5 表示剥离器基准液位超限。根据 3.1 节的实验结果,测试数据映射到 C1 区域,所以可以判断测试数据属于故障数据。在此基础上,将测试数据映射到新建的映射图 7(c)中,可以发现数据属于 F1 区域,即反应器压力超限。

由此看出,通过使用 DAE-SOM 方法对过程数据二次映射的方法,可以判断过程的故障类型。

Chen 等^[30]使用 FDA-SOM 方法,诊断 TE 过程的故障,该方法可以区分易于错分类的故障 4 和故障 5^[21]。图 8 是使用 FDA-SOM 方法区分上述 F1、F2、F4 和 F5 故障的 U 矩阵图和训练图。虽然 4 个故障可以区分开来,但是 U 矩阵图的界限并不如 DAE-SOM 方法的清晰,所以 DAE-SOM 可以更好




图9 DAE-SOM第2层(效益评估)映射结果

Fig.9 Mapping results for second layer (profit assessment) based on DAE-SOM

地区分故障类别。

3.2.2 利润评估 在本文中,TE 过程的利润被分为了7个区域范围,见表5。因为有些利润范围内数据出现频率高,有些范围内数据出现频率低,所以数据区间不是等距离的。同样地,选用7组属于不同区间的训练数据,使用 DAE-SOM 方法建立 U 矩阵图[图 9(a)]和映射图[图 9(b)]。P1~P7 分别代表 case1~case7。选择一组在一层映射中映射到 C3 的测试数据,对该数据进行进一步预测,如图 9(c)所示。可以发现该组测试数据映射到了 P1 范围内,即利润大于 5200 USD·h⁻¹,所以可以判定,当前过程的运行效果很好,利润空间大。因此,通过 DAE-SOM 的二次映射方法,可以判断过程的效益。

3.3 过程的在线效果监控

基于 DAE-SOM 的方法不仅能够适用于离线数据监控,对于在线实时数据也有很好的监控效果。图 10 展示了该方法的在线监控效果。图 10(a)、(b)分别为 10 个和 20 个样本点的测试效果图,从图 10(a)到图 10(b)的轨迹变化展示了过程数据从 C3 状态变为 C2 状态的路径,即安全生产及产品合格状态变化为安全生产产品不合格状态的过程。通过图中红点的变化轨迹,可以很好地实现过程的在线监控。同样地,通过第 2 层的映射,可以进一步分析过程性能变化的原因。

4 结 论

针对以往化工过程性能评估模型建立困难和评估准则较为单一的缺点,本文提出了一种基于数




图10 DAE-SOM方法在线效果监控

Fig.10 Mapping results for online process based on DAE-SOM

据,并结合多种因素,如安全、经济、故障等的方法来判断化工过程的运行状况。通过对运行数据的特征提取以及可视化分析,可以判断当前系统是否发生故障,生产产品是否合格,以及经济效益是否最大化。为了验证该方法的有效性,本文将基于 DAE-SOM 的双层可视化映射方法用于 TE 过程中。TE 过程的性能被分成 3 个级别,分别是有重大故障(C1)、对产品质量影响(C2)以及经济状况(C3)。使用 DAE-SOM 方法,对这 3 个等级的训练数据建立一

层映射图。使用测试数据可以判断出系统当前处于哪个级别。判断出系统所属等级后,可以通过二次映射图判断系统当前运行状况。如当测试数据映射到 C1 级别时,可以对测试数据进行再一次映射,判断系统发生了何种重大故障,从而帮助操作员做出决策。通过仿真研究,可以发现,该方法能够很好地判断系统的运行状况,并能够找出故障原因以及评估当前系统效益。

References

- [1] 马立玲, 徐发富, 王军政. 一种基于改进核 Fisher 的故障诊断方法[J]. 化工学报, 2017, **68**(3): 1041-1048.
MA L L, XU F F, WANG J Z. A fault diagnosis method based on improved kernel Fisher[J]. CIESC Journal, 2017, **68**(3): 1041-1048.
- [2] 江伟, 王振雷, 王昕. 基于混合分块 DMICA-PCA 的全流程过程监控方法[J]. 化工学报, 2017, **68**(2): 759-766.
JIANG W, WANG Z L, WANG X. Plant-wide process monitoring based on mixed multiblock DMICA-PCA[J]. CIESC Journal, 2017, **68**(2): 759-766.
- [3] 王坤, 杜文莉, 钱锋. 基于小波核聚类的非高斯过程故障检测方法[J]. 化工学报, 2011, **62**(2): 427-432.
WANG K, DU W L, QIAN F. Non-Gaussian process fault detection based on wavelet kernel clustering[J]. CIESC Journal, 2011, **62**(2): 427-432.
- [4] 齐咏生, 王普, 高学金, 等. 一种基于改进 MPCA 的间歇过程监控与故障诊断方法[J]. 化工学报, 2009, **60**(11): 2838-2846.
QI Y S, WANG P, GAO X J, *et al.* Batch process monitoring and fault diagnosis based on improved multi-way principal component analysis[J]. CIESC Journal, 2009, **60**(11): 2838-2846.
- [5] BALDI P, HORNIK K. Neural networks and principal component analysis: learning from examples without local minima[J]. Neural Networks, 1989, **2**(1): 53-58.
- [6] ROWEIS S. EM algorithms for PCA and SPCA[J]. Advances in Neural Information Processing Systems, 1998, **10**: 626-632.
- [7] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, **323**: 533-536.
- [8] CHANDAR A P S, LAULY S, LAROCHELLE H, *et al.* An autoencoder approach to learning bilingual word representations[J]. Advances in Neural Information Processing Systems, 2014, **3**: 1853-1861.
- [9] LORE K G, AKINTAYO A, SARKAR S. LLNet: a deep autoencoder approach to natural low-light image enhancement[J]. Pattern Recognition, 2017, **61**: 650-662.
- [10] MEHTA J, MAJUMDAR A. RODEO: robust DE-aliasing autoencoder for real-time medical image reconstruction[J]. Pattern Recognition, 2017, **63**: 499-510.
- [11] DENG J, ZHANG Z, EYBEN F, *et al.* Autoencoder-based unsupervised domain adaptation for speech emotion recognition[J]. IEEE Signal Processing Letters, 2014, **21**(9): 1068-1072.
- [12] DENG J, ZHANG Z, MARCHI E, *et al.* Sparse autoencoder-based feature transfer learning for speech emotion recognition[C]// Affective Computing and Intelligent Interaction. IEEE, 2013: 511-516.
- [13] BETECHUOH B L, MARWALA T, TETTEY T. Autoencoder networks for HIV classification[J]. Current Science, 2006, **91**(11): 1467-1473.
- [14] LI J, STRUZIK Z, ZHANG L, *et al.* Feature learning from incomplete EEG with denoising autoencoder[J]. Neurocomputing, 2015, **165**: 23-31.
- [15] XIA R, DENG J, SCHULLER B, *et al.* Modeling gender information for emotion recognition using denoising autoencoder[C]// IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2014: 990-994.
- [16] MARCHI E, VESPERINI F, EYBEN F, *et al.* A novel approach for automatic acoustic novelty detection using a denoising autoencoder with bidirectional LSTM neural networks[C]// IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2015: 1996-2000.
- [17] VINCENT P, LAROCHELLE H, BENGIO Y, *et al.* Extracting and composing robust features with denoising autoencoders[C]// International Conference on Machine Learning. ACM, 2008: 1096-1103.
- [18] PRINCIPE J C, WANG L. Non-linear time series modeling with self-organization feature maps[C]// Neural Networks for Signal Processing. IEEE, 1995: 11-20.
- [19] FORNELLS A, GOLOBARDES E, MARTORELL J M, *et al.* Measuring the applicability of self-organization maps in a case-based reasoning system[C]// Iberian Conference on Pattern Recognition and Image Analysis. Springer-Verlag, 2007: 532-539.
- [20] KOHONEN T. The self-organizing map[J]. Neurocomputing, 1990, **21**(1/2/3): 1-6.
- [21] DOWNS J J, VOGEL E F. A plant-wide industrial process control problem[J]. Computers & Chemical Engineering, 1993, **17**(3): 245-255.
- [22] GAO X, HOU J. An Improved SVM Integrated GS-PCA Fault Diagnosis Approach of Tennessee Eastman Process[M]. Amsterdam: Elsevier Science Publishers B. V., 2016.
- [23] CHEN H, TIÑO P, YAO X. Cognitive fault diagnosis in Tennessee Eastman process using learning in the model space[J]. Computers & Chemical Engineering, 2014, **67**(3): 33-42.
- [24] WANG A, SHA M, LIU L, *et al.* Fault diagnosis of TE process based on ensemble improved binary-tree SVM[C]// IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications. IEEE, 2010: 908-912.
- [25] GOLSHAN M, PISHVAIE M R, BOOZARJOMEHRY R B. Stochastic and global real time optimization of Tennessee Eastman challenge problem[J]. Engineering Applications of Artificial Intelligence, 2008, **21**(2): 215-228.
- [26] GOLSHAN M, BOOZARJOMEHRY R B, PISHVAIE M R. A new approach to real time optimization of the Tennessee Eastman challenge problem[J]. Chemical Engineering Journal, 2005, **112**(1): 33-44.
- [27] RICKER N L. Optimal steady-state operation of the Tennessee Eastman challenge process[J]. Computers & Chemical Engineering, 1995, **19**(9): 949-959.
- [28] RICKER N L. Decentralized control of the Tennessee Eastman challenge process[J]. Journal of Process Control, 1996, **6**(4): 205-221.
- [29] TIAN Y, DU W L, QIAN F. High dimension feature extraction based visualized SOM fault diagnosis method and its application in *p*-xylene oxidation process [J]. Chinese Journal of Chemical Engineering, 2015, **23**(9): 1509-1517.
- [30] CHEN X Y, YAN X F. Using improved self-organizing map for fault diagnosis in chemical industry process[J]. Chemical Engineering Research & Design, 2012, **90**(12): 2262-2277.