

DOI: 10.19650/j.cnki.cjsi.J2107541

一种基于流形正则化随机配置网络的 化工过程故障识别方法

潘承燕, 徐进学, 翁永鹏

(大连海事大学船舶电气工程学院 大连 116026)

摘要:考虑到化工过程故障数据的复杂非线性特性和样本潜在的根本结构特征,提出了一种基于流形正则化随机配置网络的故障识别方法。该方法在经典随机配置网络的基础上,在嵌入流形约束的监督机制下随机选取隐含参数,逐个添加隐含节点,然后使用流形正则化最小二乘法计算隐含层的输出权值,保留了数据的重要几何特征,避免了信息冗余,有利于更好地识别出区别于不同类别的相关特征。在测试集上的实验表明,该方法对 TE 故障和半导体故障的识别准确率分别达到了 87.72% 和 84.27%,均高于随机向量函数连接网络和随机配置网络方法。而且对于大部分故障类型,该方法的精确率和召回率较高,验证了所提方法进行故障识别的有效性和所建立模型的良好泛化能力。

关键词: 随机配置网络;流形正则化;化工过程;故障识别

中图分类号: TH86 TP277 **文献标识码:** A **国家标准学科分类代码:** 510.8

A fault identification method of chemical process based on manifold regularized stochastic configuration network

Pan Chengyan, Xu Jinxue, Weng Yongpeng

(Marine Electrical Engineering College, Dalian Maritime University, Dalian 116026, China)

Abstract: Considering the complex nonlinear characteristics of chemical process faults and the underlying structural characteristics of samples, a fault identification method based on manifold regularized stochastic configuration network is proposed. Based on classical stochastic configuration network, this method randomly selects hidden parameters under the supervision mechanism of embedded manifold constraints to add hidden nodes one by one. Then, the output of hidden layer weights is calculated by manifold regularized least square method. It keeps the important geometric characteristics of data. The information redundancy is avoided and the relevant characteristics of different from different categories could be identified. Experimental results on test set show that the identification accuracy values of TE fault and semiconductor fault are 87.72% and 84.27%, respectively, which are higher than those of random vector function connection network and stochastic configuration network. In addition, for most fault types, the precision and recall rates of the proposed method are high. Results prove that the proposed method can effectively identify faults. The generalization ability of fault identification model is improved.

Keywords: stochastic configuration network; manifold regularization; chemical processes; fault identification

0 引言

随着流程工业日益规模化和复杂化,故障检测和诊断技术被用来保障工业系统的正常稳定运行^[1]。化工生产工序复杂,过程数据易受噪声和不确定性的影响,变量

间相互耦合,其过程数据本质上是高维数、强非线性的。因此,化工过程故障识别是一类复杂的多分类问题,常规的线性方法无法有效地提取非线性特征,可能不是处理该问题的最适当方法^[2]。

神经网络通过学习输入输出映射,可有效解决故障样本的分类问题^[3-5]。目前,基于梯度下降的反向传播算



法 (backpropagation, BP)^[6] 被广泛用于网络训练。但 BP 并不能实现最好最快的学习, 存在收敛慢、局部最优等问题^[7-8]。随机向量函数连接网络 (random vector functional link, RVFL) 是 Pao 等^[9] 提出的一种随机权单隐层前馈神经网络。它的输入权值和偏置在预设的分布范围内随机选取, 输出权值由最小二乘法计算得到, 结构简单, 计算效率高。但 RVFL 仍需手动设置隐含节点数目, 当随机参数范围选取不当时, 网络收敛便得不到保障。对此, Wang 等^[10] 提出了随机配置网络 (stochastic configuration network, SCN)。不同于传统随机权神经网络, SCN 依赖于训练数据自适应选取隐含参数的范围, 在监督机制下随机选取隐含参数, 用线性回归评估输出权值, 保证了所建立模型的收敛性能。文献[11]提出了带有 L2 范数正则化的 SCN, 改善了最小二乘法计算输出权值的代数属性, 避免了模型过拟合的结构风险。文献[12]考虑图像建模任务, 将 SCN 可能会破坏空间信息的一维输入扩展为矩阵输入, 实现了手写数字的旋转角度预测和数字识别。

由于化工系统结构复杂、环境噪声等问题, 过程数据不仅反映了实际的系统状态, 还存在一些冗余信息。SCN 在对故障数据建模时, 通过逐渐增加隐含节点来最小化训练误差。这样一味追求对训练数据的预测能力, 易学习到数据中的冗余信息, 使得所建立的模型虽在训练集上能够很好地实现分类任务, 但对于测试集分类效果不好, 大大降低了模型的泛化能力。

一个好的表示通常可以揭示数据潜在的根本结构, 用来减少冗余, 提高模型性能^[13]。汤一彬等^[14] 结合旋转不变表示和流形学习, 成功提取了含噪图像块中的隐含特征, 实现了降噪。流形学习是基于几何概念的数据表示方法, 它以流形假设为前提, 假设真实高维数据分布在嵌于高维输入空间中的低维流形上^[15-16]。流形学习方法通过近似该流形结构能很好地捕捉数据潜在的几何特征信息。流形正则化框架^[17] 是流形学习方法之一, 它通过构造样本邻接图挖掘数据的几何特征。这种利用邻域信息学习数据局部结构的方式使得数据的关键信息得以保留, 减少了信息冗余。

本文针对故障建模的过拟合问题, 将流形正则化和学习模型结合起来, 提出了一种基于流形正则化随机配置网络 (manifold regularized stochastic configuration network, MRSCN) 的故障识别方法, 来提高模型对新样本的识别能力。为尽可能保留样本根本的结构信息, MRSCN 在 SCN 的基础上, 利用带有流形约束的监督机制来选取有效隐含节点, 使用流形正则化最小二乘法计算输出权值。充分利用了输入空间的几何特性, 将数据中的有用信息用于故障建模, 避免信息冗余, 能提高模型的泛化能力和分类性能。

1 流形正则化随机配置网络

1.1 随机配置网络

SCN 结构如图 1 所示。对任意样本 $\mathbf{x} \in R^d$, 目标函数 $f: R^d \rightarrow R^m$, SCN 以点增量的方式构建学习模型。

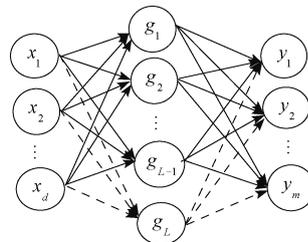


图 1 随机配置网络结构图

Fig. 1 Architecture diagram of SCN

L 表示隐含层节点数目, 采用 Sigmoid 函数作为激活函数计算第 j 个隐含节点的输出 g_j , 对于 N 个样本, 含 $L-1$ 个隐含节点的 SCN 的输出:

$$\mathbf{f}_{L-1}(\mathbf{x}) = \sum_{j=1}^{L-1} \boldsymbol{\beta}_j g_j(\mathbf{x}) \quad (1)$$

其中, $\boldsymbol{\omega}_j$, b_j 和 $\boldsymbol{\beta}_j$ 表示第 j 个隐含节点的输入权值、偏置和输出权值, 此时的网络误差:

$$\mathbf{e}_{L-1} = \mathbf{f} - \mathbf{f}_{L-1} = [\mathbf{e}_{L-1,1}, \mathbf{e}_{L-1,2}, \dots, \mathbf{e}_{L-1,m}] \quad (2)$$

SCN 从一个小型网络开始, 逐个增加隐含节点构建学习模型。其依赖于训练数据自适应选取输入权值和偏置的范围, 采用监督机制:

$$\langle \mathbf{e}_{L-1,q}, \mathbf{g}_L \rangle^2 \geq b_g^2 \delta_{L,q}, q = 1, 2, \dots, m \quad (3)$$

其中, $\delta_{L,q} = (1-r-\mu_L) \|\mathbf{e}_{L-1,q}\|^2$, $0 < \|\mathbf{g}\| < b_g$, $b_g \in R^+$, r 满足 $0 < r < 1$, μ_L 满足 $\lim_{L \rightarrow \infty} \mu_L = 0$ 和 $0 < \mu_L \leq 1-r$ 。SCN 将满足监督约束式 (3) 的隐含节点添加到网络后, 使用最小二乘法计算隐含层输出权值矩阵:

$$[\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \dots, \boldsymbol{\beta}_L] = \operatorname{argmin}_{\boldsymbol{\beta}} \|\mathbf{f} - \sum_{j=1}^L \boldsymbol{\beta}_j g_j\|^2 \quad (4)$$

1.2 流形正则化理论

流形正则化方法从图嵌入的角度入手, 用样本数据的邻接图来描述数据间的联系, 如图 2 所示。

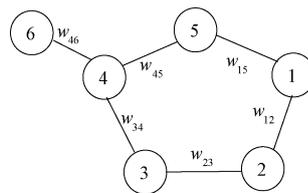


图 2 局部近邻关系示意图

Fig. 2 Schematic diagram of local neighborhood relationship



图 2 中的节点代表样本,边权值代表样本间的相似性,样本越接近,边权值越大。

本文研究有监督学习,利用有标签数据进行学习分析,流形正则约束的目标函数为:

$$\min \frac{1}{2} \sum_{i,j=1}^N w_{ij} \|y_i - y_j\|^2 \quad (5)$$

其中,输入输出样本 $(x_i, y_i) | x_i \in R^d, y_i \in R^m, i = 1, 2, \dots, N$, y_i 和 y_j 分别是输入样本 x_i 和 x_j 的输出预测向量, w_{ij} 表示样本 x_i 和 x_j 的相似度。

$$w_{ij} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{\rho}\right), & \text{同类样本 } x_i \text{ 和 } x_j \text{ 互为近邻} \\ 0, & \text{其它} \end{cases} \quad (6)$$

流形正则化通过式(5)对样本的局部近邻关系进行学习,来挖掘数据的局部几何特征,尽可能保证在相似的几何结构中彼此接近的样本拥有相似输出。若样本 x_i 和 x_j 在原始空间中距离越近, w_{ij} 越大。根据式(5), $\|y_i - y_j\|^2$ 就会越小, y_i 和 y_j 距离越近。根据图谱理论,式(5)可等价于:

$$\min \text{tr}(Y L_p Y^T) \quad (7)$$

其中, L_p 是输入样本的图拉普拉斯矩阵

$$L_p = D - W \quad (8)$$

W 是样本的相似度矩阵, D 是对角阵, 对角元素如下:

$$d_i = \sum_{j=1}^N w_{ij} \quad (9)$$

1.3 流形正则化随机配置网络

1) 理论推导

给定 N 个输入样本 $X \in R^{N \times d}, x_i \in R^d, i = 1, 2, \dots, N$, 目标函数 $f: R^d \rightarrow R^m$ 。假定 MRSCN 在建立学习模型过程中,保持已建立的隐含节点不变。建立了 $L-1$ 个隐含节点后,为了使所添加节点尽可能体现样本的局部几何结构,挖掘其重要的结构信息,MRSCN 训练第 L 个隐含节点的目标函数为:

$$\min_{\beta_L} \frac{1}{2} \|e_L\|^2 + \frac{\lambda_M}{2} \text{tr}((g_L \beta_L)^T L_p g_L \beta_L) \quad (10)$$

其中, $g_L = 1/(1 + \exp(-X \omega_L + b_L))$, ω_L 和 b_L 随机选取, λ_M 是流形正则参数, L_p 是样本的图拉普拉斯矩阵。正则项 $\frac{\lambda_M}{2} \text{tr}((g_L \beta_L)^T L_p g_L \beta_L)$ 用来学习样本局部几何特征。

g_L 由随机参数确定,式(10)可看作是关于 β_L 的函数:

$$f(\beta_L) = \frac{1}{2} \|e_L\|^2 + \frac{\lambda_M}{2} \text{tr}((g_L \beta_L)^T L_p g_L \beta_L) \quad (11)$$

令式(11)导数为 0, 得到:

$$\beta_L = \langle e_{L-1}, g_L \rangle / (\|g_L\|^2 + \lambda_M \|\sqrt{L_p} g_L\|^2) \quad (12)$$

根据式(12),误差衰减量:

$$\begin{aligned} \Delta &= \|e_{L-1}\|^2 - \|e_L\|^2 = \|e_{L-1}\|^2 - \|f - f_L\|^2 = \\ &= \|e_{L-1}\|^2 - \|f - f_{L-1} - g_L \beta_L\|^2 = \|e_{L-1}\|^2 - \\ &= \|e_{L-1} - g_L \beta_L\|^2 = \langle e_{L-1}, e_{L-1} \rangle - \langle e_{L-1} - g_L \beta_L, e_{L-1} - \\ &= 2 \langle e_{L-1}, g_L \beta_L \rangle - \langle g_L \beta_L, g_L \beta_L \rangle = \\ &= \frac{\langle e_{L-1}, g_L \rangle^2}{(\|g_L\|^2 + \lambda_M \|\sqrt{L_p} g_L\|^2)^2 / (\|g_L\|^2 + 2\lambda_M \|\sqrt{L_p} g_L\|^2)} \end{aligned} \quad (13)$$

若已建立的隐含节点保持不变,则 $\|e_{L-1}\|^2$ 是常值,若要使 $\|e_L\|^2$ 最小,可选取合适的 g_L 使 Δ 最大。

根据文献[18]提出的定理 1,当增量式随机权神经网络的隐含节点数目足够大时,由于高维随机向量几乎两两正交,随机选取 g_L 时受限, $\|e_L\|$ 有很大可能会收敛到一个非零常数,无法达到期望精度。为保证模型的逼近能力,MRSCN 的误差收敛速度满足:

$$(\|e_{L-1}\|^2 - \|e_L\|^2) / \|e_{L-1}\|^2 \geq \varepsilon_L > 0 \quad (14)$$

其中, $\lim_{L \rightarrow \infty} \prod_{k=1}^L (1 - \varepsilon_k) = \varepsilon > 0$, 令 $1 - \varepsilon_L = r + \mu_L$, 由式(14)可推得:

$$\|e_L\|^2 - (r + \mu_L) \|e_{L-1}\|^2 \leq 0 \quad (15)$$

令 $\delta_L = (1 - r - \mu_L) \|e_{L-1}\|^2$, 结合式(12):

$$\begin{aligned} &\|e_L\|^2 - (r + \mu_L) \|e_{L-1}\|^2 = \\ &= \|e_{L-1} - g_L \beta_L\|^2 - (r + \mu_L) \|e_{L-1}\|^2 = \\ &= \langle e_{L-1} - g_L \beta_L, e_{L-1} - g_L \beta_L \rangle - (r + \mu_L) \langle e_{L-1}, e_{L-1} \rangle = \\ &= (1 - r - \mu_L) \langle e_{L-1}, e_{L-1} \rangle - 2 \langle e_{L-1}, g_L \beta_L \rangle + \langle g_L \beta_L, g_L \beta_L \rangle = \\ &= \frac{\langle e_{L-1}, g_L \rangle^2}{(\|g_L\|^2 + \lambda_M \|\sqrt{L_p} g_L\|^2)^2 / (\|g_L\|^2 + 2\lambda_M \|\sqrt{L_p} g_L\|^2)} \end{aligned} \quad (16)$$

根据式(15)可知:

$$\langle e_{L-1}, g_L \rangle^2 \geq \delta_L \frac{(\|g_L\|^2 + \lambda_M \|\sqrt{L_p} g_L\|^2)^2}{\|g_L\|^2 + 2\lambda_M \|\sqrt{L_p} g_L\|^2} \quad (17)$$

其中, r 大小可调满足 $0 < r < 1$, 用来保证存在满足式(17)的隐含节点, μ_L 满足 $\lim_{L \rightarrow \infty} \mu_L = 0$ 和 $0 < \mu_L \leq 1 - r$ 。

当模型输出为多维时,即目标函数为 $f: R^d \rightarrow R^m$, 式(17)等价于:

$$\langle e_{L-1,q}, g_L \rangle^2 \geq \delta_{L,q} \frac{(\|g_L\|^2 + \lambda_M \|\sqrt{L_p} g_L\|^2)^2}{\|g_L\|^2 + 2\lambda_M \|\sqrt{L_p} g_L\|^2},$$

$q = 1, 2, \dots, m$

此时 $\delta_{L,q} = (1 - r - \mu_L) \|e_{L-1,q}\|^2$, 第 L 个节点的输出权值:



$$\tilde{\beta}_{L,q} = \langle \mathbf{e}_{L-1,q}, \mathbf{g}_L \rangle / (\|\mathbf{g}_L\|^2 + \lambda_M \|\sqrt{\mathbf{L}_p} \mathbf{g}_L\|^2),$$

$$q = 1, 2, \dots, m \quad (19)$$

为加快网络收敛,同时更新所有输出权值来进一步减小误差。使用流形正则化来约束网络输出的几何结构,用 $\mathbf{H}_L \in R^{N \times L}$ 表示隐含层输出矩阵,输出权值为

$$[\beta_1^*, \beta_2^*, \dots, \beta_L^*] = \operatorname{argmin}_{\beta} \frac{1}{2} \left\| \mathbf{f} - \sum_{j=1}^L \mathbf{g}_j \beta_j \right\|_F^2 + \frac{\lambda_M}{2} \operatorname{tr}((\mathbf{H}_L \beta)^T \mathbf{L}_p (\mathbf{H}_L \beta)) \quad (20)$$

定理 1 对于样本 $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, $\mathbf{x} \in R^d$, 目标函数 $f: R^d \rightarrow R^m$, MRSCN 从小型网络开始,在式(18)下随

$$\|\mathbf{e}_L\|^2 - \|\mathbf{e}_{L-1}\|^2 \leq \|\tilde{\mathbf{e}}_L\|^2 - \|\mathbf{e}_{L-1}\|^2 = \|\mathbf{f} - \tilde{\mathbf{f}}_L\|^2 - \|\mathbf{f} - \mathbf{f}_{L-1}\|^2 = \|\mathbf{e}_{L-1} - \tilde{\beta}_L \mathbf{g}_L\|^2 - \|\mathbf{e}_{L-1}\|^2 =$$

$$\sum_{q=1}^m (\langle \mathbf{e}_{L-1,q} - \mathbf{g}_L \tilde{\beta}_{L,q}, \mathbf{e}_{L-1,q} - \mathbf{g}_L \tilde{\beta}_{L,q} \rangle - \langle \mathbf{e}_{L-1,q}, \mathbf{e}_{L-1,q} \rangle) =$$

$$\sum_{q=1}^m \left(- \frac{\langle \mathbf{e}_{L-1,q}, \mathbf{g}_L \rangle^2}{(\|\mathbf{g}_L\|^2 + \lambda_M \|\sqrt{\mathbf{L}_p} \mathbf{g}_L\|^2)^2 / (\|\mathbf{g}_L\|^2 + 2\lambda_M \|\sqrt{\mathbf{L}_p} \mathbf{g}_L\|^2)} \right) \quad (21)$$

根据式(21)可知, $\|\mathbf{e}_L\|^2 \leq \|\mathbf{e}_{L-1}\|^2$ 且 $\|\mathbf{e}_L\| \geq 0$, 序列 $\{\|\mathbf{e}_i\|\}_{i=1}^L$ 是单调递减且收敛。与式(21)缩放不等式同理,

$$\|\mathbf{e}_L\|^2 - (r + \mu_L) \|\mathbf{e}_{L-1}\|^2 =$$

$$= \sum_{q=1}^m \left(\delta_{L,q} - \frac{\langle \mathbf{e}_{L-1,q}, \mathbf{g}_L \rangle^2}{(\|\mathbf{g}_L\|^2 + \lambda_M \|\sqrt{\mathbf{L}_p} \mathbf{g}_L\|^2)^2 / (\|\mathbf{g}_L\|^2 + 2\lambda_M \|\sqrt{\mathbf{L}_p} \mathbf{g}_L\|^2)} \right) \quad (22)$$

根据式(18)和(22),

$$\|\mathbf{e}_L\|^2 \leq (r + \mu_L) \|\mathbf{e}_{L-1}\|^2 = r \|\mathbf{e}_{L-1}\|^2 + \mu_L \|\mathbf{e}_{L-1}\|^2 \quad (23)$$

对式(23)两边取极限,由于 $\lim_{L \rightarrow \infty} \mu_L = 0$, 所以 $\lim_{L \rightarrow \infty} \mu_L \|\mathbf{e}_{L-1}\|^2 = 0$, 又因 $r \neq 0$, 所以 $\lim_{L \rightarrow \infty} \|\mathbf{e}_L\|^2 = 0$ 得证。

2) 算法描述

MRSCN 模型输入 $\mathbf{X} \in R^{N \times d}$, 输出 $\mathbf{T} \in R^{N \times m}$ 。建立 $L-1$ 个隐含节点后的网络误差 $\mathbf{e}_{L-1} \in R^{N \times m}$, 隐含层输出 $\mathbf{H}_{L-1} \in R^{N \times (L-1)}$ 。现增第 L 个隐含节点,其输出为 $\mathbf{h}_L \in R^N$, 隐含层输出 $\mathbf{H}_L \in R^{N \times L}$ 。为实现方便,根据 $\delta_{L,q} = (1 - r - \mu_L) \|\mathbf{e}_{L-1,q}\|^2$, $q = 1, 2, \dots, m$ 定义一组变量 $\xi_{L,q}$,

$$\xi_{L,q} = \frac{(\mathbf{e}_{L-1,q}^T \mathbf{h}_L)^2}{(\mathbf{h}_L^T \mathbf{h}_L + \lambda_M \mathbf{h}_L^T \mathbf{L}_p \mathbf{h}_L)^2 / (\mathbf{h}_L^T \mathbf{h}_L + 2\lambda_M \mathbf{h}_L^T \mathbf{L}_p \mathbf{h}_L)} - (1 - r - \mu_L) \mathbf{e}_{L-1,q}^T \mathbf{e}_{L-1,q} \quad (24)$$

由式(20)整理得隐含层的输出权值矩阵:

$$\beta = (\mathbf{H}_L^T \mathbf{H}_L + \lambda_M \mathbf{H}_L^T \mathbf{L}_p \mathbf{H}_L)^{-1} \mathbf{H}_L^T \mathbf{T} \quad (25)$$

MRSCN 算法伪代码表 1 所示。

2 结果与讨论

2.1 实验对象及模型评估指标

为验证 MRSCN 的有效性,本研究在两个数据集上进

机配置隐含节点,用式(20)计算输出权值,当网络输出

$$\mathbf{f}_L = \sum_{j=1}^L \mathbf{g}_j \beta_j \text{ 时, 有 } \lim_{L \rightarrow \infty} \|\mathbf{e}_L\| = 0.$$

证明:

MRSCN 可分为输入训练和输出训练两部分。前者选取合适的隐含节点并使用式(19)计算输出权值;后者通过式(20)更新隐含层输出权值。输入训练的输出权值作为中间值记作 $\tilde{\beta}$, 模型输出和误差记为 $\tilde{\mathbf{f}}_L$ 和 $\tilde{\mathbf{e}}_L$; 输出训练的输出权值记作 β , 模型输出和误差记作 \mathbf{f}_L 和 \mathbf{e}_L , 显然 $\|\mathbf{e}_L\|^2 \leq \|\tilde{\mathbf{e}}_L\|^2$, 由式(19),

行了实验验证。一是来自田纳西-伊斯曼过程(Tennessee Eastman process, TEP)^[19]中的 TE 故障数据集,共 21 类故障,故障样本由 52 个变量描述。随机选取其中的 10 类故障进行建模分析。每类故障取 800 个样本,按比例 2:1:1 分为训练、验证和测试集。使用验证集调节超参数 λ_M 、 ρ 和 K 。

二是来自德克萨斯仪器公司的半导体蚀刻过程的数据集。该数据集包含 108 个正常晶片和 21 个故障晶片,故障样本可由 17 个变量描述^[20]。随机选取 5 个故障晶片进行建模分析。由于部分晶片数据不足,每个故障晶片选取 90 个样本,其中 60 个作为训练样本,30 个作为测试样本,采用交叉验证法^[21]选取合适的超参数。

本文将均方根误差(root mean squared error, RMSE)、准确率(accuracy)、各类故障的分类精确率(precision)和召回率(recall)^[22]作为模型评估指标。

2.2 仿真结果分析

对于 n 类故障的 MRSCN 识别模型,各故障的标签向量分别对应 n 维单位矩阵的行向量。

TE 故障识别模型实验参数设置: $L_{\max} = 1\ 000$, $r = [0.9, 0.99, 0.999, 0.999\ 9, 0.999\ 99, 0.999\ 999]$, $T_{\max} = 100$, $I = \{0.5, 1, 5, 10, 30, 50, 100\}$, $\varepsilon = 0.01$ 。MRSCN 模型中超参数 $\lambda_M = 0.5$, $\rho = 10\ 000$, $K = 5$ 。对于半导体数据集, ε 、 L_{\max} 、 r 、 T_{\max} 、 I 的设置同 TE 故障识别模型一样,不



算法 1 流形正则化随机配置网络算法伪代码

参数: 隐含参数范围 $I = \{\lambda_{\min}; \Delta\lambda; \lambda_{\max}\}$; 最大隐含节点数目 L_{\max} ; 期望误差 ε ; $R = \{r | 0 < r < 1\}$, 最大随机配置次数 T_{\max} ; 流形正则化参数 λ_M ; 近邻数 K ; 相似度参数 ρ 。

1. 根据式(6)和式(8)~(9)计算 X 对应的 L_p , 令 $e_0 = T, \omega^* = []$, $b^* = []$
2. While $\|e_0\|_F > \varepsilon$ AND $L \leq L_{\max}$, Do
3. For $\lambda \in I$, Do
4. 随机配置 T_{\max} 组隐含参数, 计算所有样本在候选节点的输出 $\{h_L^{(1)}, h_L^{(2)}, \dots, h_L^{(T_{\max})}\}$;
5. 计算 $\mu_L = (1-r)/(L+1)$;
6. For $i = 1; T_{\max}$, Do
7. 令 $h_L = h_L^{(i)}$, 根据式(24) 计算 $\xi_{L,q}$
8. If $\min\{\xi_{L,1}, \xi_{L,2}, \dots, \xi_{L,m}\} > 0$
9. 计算 $\xi_L = \sum_{q=1}^m \xi_{L,q}$ 并将 ξ_L 存至矩阵 Ω 中, 将对应的输入权值和偏置分别保存至 W 和 B
10. End If
11. End For (对应于步骤 6)
12. If W 不为空
13. Ω 中 ξ_L 取最大值时对应的输入权值和偏置分别存至 ω^* 和 b^* , Break (到步骤 16)
13. Else 选取 $\tau \in R$, 令 $r = \tau$, 返回步骤 5;
14. End If
15. End For (对应于步骤 3)
16. 根据式(25) 计算 β^* , 计算 $e_L = T - H_L \beta^*$, 更新 $e_0 = e_L, L = L + 1$
17. End While(对应于步骤 2)
18. 返回 β^*, ω^*, b^* 。

同的是参数 $\lambda_M = 0.5, K = 12$ 和 $\rho = 20\ 000$ 。

采用标准差标准化方法对样本进行预处理, 来消除变量间的影响, 实现数据的无量纲化。为消除随机性干扰, 以下实验均在同条件下独立运行 10 次, 将各算法分类结果的平均值作为各算法的最终结果。

为了从结构上了解 MRSCN 模型的泛化能力, 图 3 记录了 MRSCN 和 SCN 故障识别模型中的网络输出权值的大小情况。对于训练误差越小的前馈神经网络, 权值范数越小, 模型越简单, 泛化性能越好。其中, MRSCN 模型和 SCN 模型的输出权值的范围分别为 0.036 1~0.393 3 和为 0.055 8~0.767 0, 平均值分别为 0.233 7 和 0.153 1。由此看来, MRSCN 拥有比 SCN 更小且更加紧凑的输出权值分布, 为模型的泛化能力提供了保障。

图 4 和 5 描述了 SCN 和 MRSCN 在对 TE 故障数据和半导体数据建模过程中, RMSE 和 Accuracy 的变化情况。两次实验均表现出 SCN 的训练性能高于 MRSCN, 而 MRSCN 对新样本的识别能力要高于 SCN, 泛化性能强。

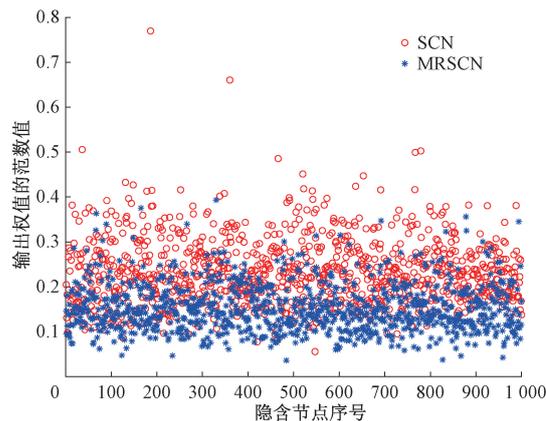
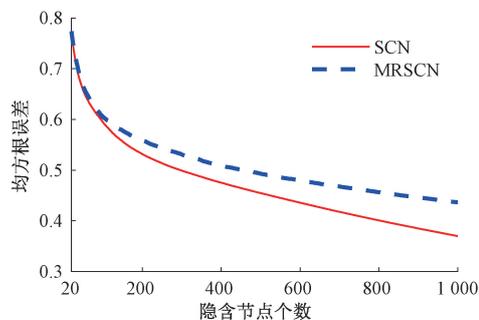


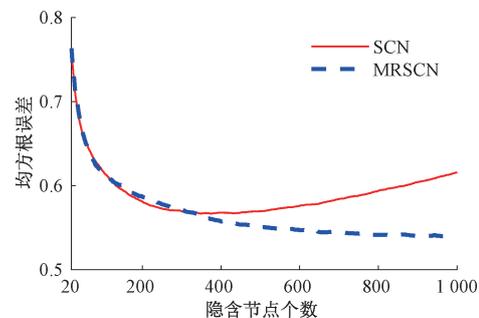
图 3 TE 故障识别模型隐含节点输出权值的范数

Fig. 3 Norm of output weights of hidden nodes in TE fault identification model

SCN 在学习模型时, 从全局信息出发, 而 MRSCN 在训练时用流形正则化来学习训练样本的局部关键特征, 忽略了部分冗余信息。因此, MRSCN 需要更多的隐含节点来达到同 SCN 一样的训练精度。随着 L 的增大, SCN 过度拟合了训练数据, 测试 RMSE 先减小后增大, 引起过拟合。而 MRSCN 因为在训练时忽略了冗余信息, 保留了样本的根本的结构信息, 更能识别出区别于不同类的相关特征, 对新样本的识别性能更好。相比于 SCN, MRSCN 故障识别模型, 避免了对经验风险的过度依赖, 有着较强的泛化能力和更高的分类性能。



(a) 训练均方根误差
(a) Training RMSE



(b) 测试均方根误差
(b) Testing RMSE

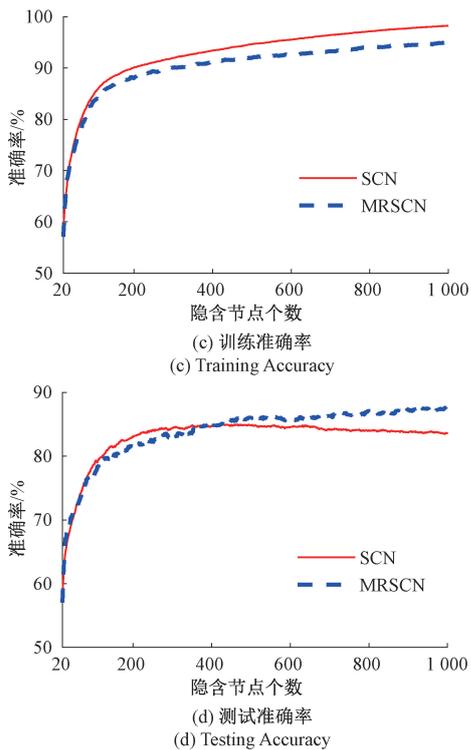


图4 SCN与MRSCN在TE故障数据集上的实验结果比较

Fig. 4 Comparison of experimental results of SCN and MRSCN on TE fault data set

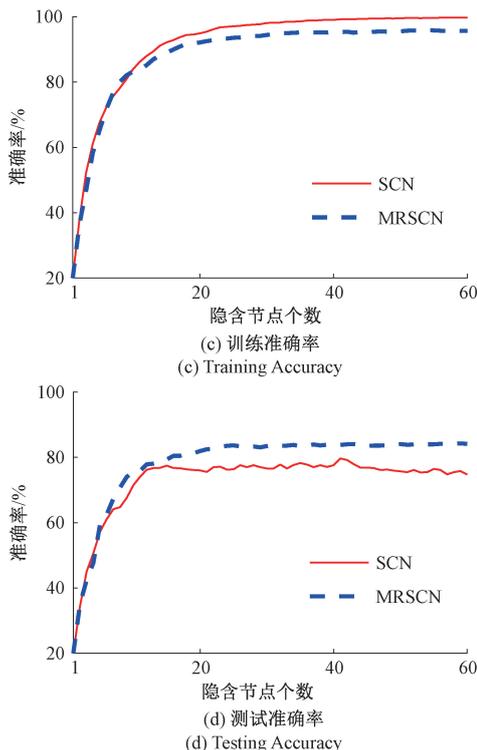


图5 SCN与MRSCN在半导体数据集上的实验结果比较

Fig. 5 Comparison of experimental results of SCN and MRSCN on semiconductor data set

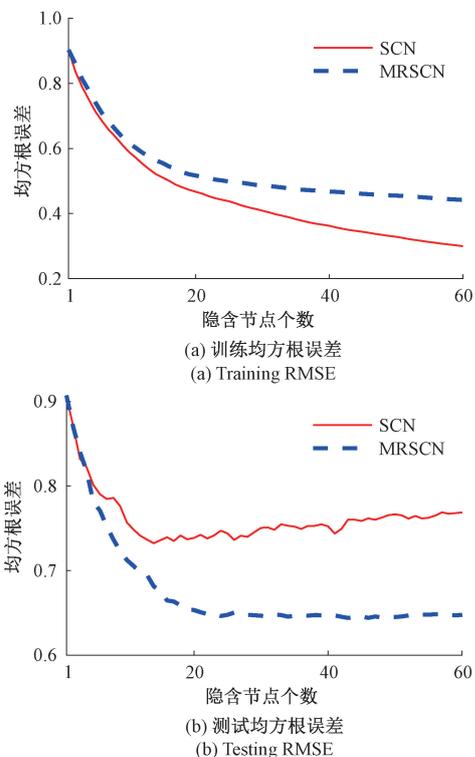


表1~4是RVFL、SCN和MRSCN在不同数据集下,分类准确率最好时的各性能指标估计。对于TE故障数据,RVFL、SCN和MRSCN分别取900、428、996个隐含节点时,分类准确率最高。对于半导体数据,RVFL、SCN和MRSCN分别取85、41、59个隐含节点时,分类准确率最高。3种算法在TE故障数据上的训练RMSE均在0.43~0.47范围内,训练Accuracy均高于90%。但从测试数据看,MRSCN模型的RMSE最小,准确率最高。表2可以了解到,MRSCN对故障01、02、04、05和07的识别精确率和召回率相较于RVFL和SCN差别不大,对故障12、14、15、17和20的识别精确率和召回率要比RVFL和SCN高。对于半导体数据,MRSCN的分类准确率比RVFL和SCN高。表4表明,MRSCN对故障‘TCP+50’识别效果不好,但对于其他4类故障,识别率是高于SCN和RVFL的。而且,MRSCN在两个数据集上的故障识别精确率和召回率的平均值,均高于SCN和RVFL。对于大部分故障类型,MRSCN的精确率和召回率比其他两种算法要高,样本漏报、误报情况少。



表 1 3 种算法在 TE 故障数据集上的性能

Table 1 Performance of three algorithms on TE fault data set

	训练		测试	
	均方根误差	准确率/%	均方根误差	准确率/%
RVFL	0.435 0	96.35	0.607 7	83.57
SCN	0.469 5	93.72	0.567 5	85.23
MRSCN	0.436 9	94.93	0.540 9	87.72

表 2 3 种算法在 TE 故障数据集的测试精确率和召回率

Table 2 Test precision and recall of three algorithms on TE fault data set

故障类型	精确率/%			召回率/%		
	RVFL	SCN	MRSCN	RVFL	SCN	MRSCN
01	1.00	99.80	1.00	1.00	1.00	1.00
02	1.00	1.00	1.00	1.00	1.00	1.00
04	85.19	85.64	84.30	99.30	99.80	1.00
05	82.40	85.60	89.81	1.00	1.00	1.00
07	99.41	99.51	1.00	1.00	1.00	1.00
12	76.68	77.68	87.03	59.60	67.70	82.50
14	76.72	87.66	90.77	65.60	67.70	71.60
15	55.13	55.38	57.29	63.10	68.00	74.50
17	82.37	83.20	89.02	78.10	78.10	78.60
20	79.87	84.25	90.25	70.00	71.00	70.00
平均值	83.78	85.87	88.85	83.75	85.23	87.72

表 3 3 种算法在半导体数据集上的性能

Table 3 Performance of three algorithms on semiconductor data set

	训练		测试	
	均方根误差	准确率/%	均方根误差	准确率/%
RVFL	0.330 9	99.37	0.7843	77.07
SCN	0.357 5	99.23	0.7438	79.67
MRSCN	0.441 3	95.70	0.6471	84.27

表 4 3 种算法在半导体数据集上的测试精确率和召回率

Table 4 Test precision and recall of three algorithms on semiconductor data set

故障类型	精确率/%			召回率/%		
	RVFL	SCN	MRSCN	RVFL	SCN	MRSCN
TCP+50	88.62	91.40	63.51	92.67	94.33	84.00
Pr+3	96.69	91.09	97.81	61.00	51.67	99.67
TCP-20	98.07	99.20	1.00	73.67	77.67	99.33
Pr-2	78.36	89.42	90.19	98.33	98.67	1.00
RF+10	47.62	51.56	71.50	59.67	76.00	38.33
平均值	81.87	84.53	84.60	77.05	79.67	84.72

3 结 论

本文针对化工过程中具有高维非线性、多变量强耦合等特点的故障数据进行建模时存在的过拟合问题,提出了使用 MRSCN 进行化工过程故障识别的方法,并在理论上进行了推导。SCN 和 MRSCN 的 TE 故障建模实验结果表明 MRSCN 模型的输出权值更为紧凑、更小,模型更加简单,泛化能力得到了提高。MRSCN 模型对于测试样本的识别能力高于 SCN 和 RVFL,这在 TE 故障数据集和半导体数据集上均得到了有效验证。MRSCN 在训练学习模型时,考虑了样本的根本结构特征,利用流形正则化来挖掘样本的潜在的几何特征,抑制了过拟合现象,提高了故障识别的准确率。

参考文献

- [1] NANDI S, TOLIYAT H A, LI X. Condition monitoring and fault diagnosis of electrical motors-a review [J]. IEEE Transactions on Energy Conversion, 2005, 20(4): 719-729.
- [2] JIA F, MARTIN E B, MORRIS A J. Non-linear principal components analysis with application to process fault detection [J]. International Journal of Systems Science, 2000, 31(11): 1473-1487.
- [3] SIMANI S, FANTUZZI C. Fault diagnosis in power plant using neural networks [J]. Information Sciences, 2000, 127: 125-136.
- [4] 孙健, 胡国兵, 王成华. 基于随机投影和 NB 网络的模拟电路故障诊断 [J]. 仪器仪表学报, 2019, 40(2): 105-112.
SUN J, HU G B, WANG CH H. Analog circuit fault diagnosis based on random projection and NB network [J]. Chinese Journal of Scientific Instrument, 2019, 40(2): 105-112.
- [5] 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 P, Y L, Y 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.
- [6] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning internal representation by back-propagation errors [J]. Nature, 1986, 323: 533-536.
- [7] CURRY B, MORGAN P. Neural networks: A need for caution [J]. Omega, International Journal of Management Sciences, 1997, 25(1): 123-133.
- [8] VOGL T P, MANGIS J K, RIGLER A K, et al.



- Accelerating the convergence of the back-propagation method [J]. *Biological Cybernetics*, 1988, 59(4/5): 257-263.
- [9] PAO Y H, TAKEFUJI Y. Functional-link net computing: Theory, system architecture, and functionalities [J]. *Computer*, 1992, 25: 76-79.
- [10] WANG D H, LI M. Stochastic configuration networks: Fundamentals and algorithms [J]. *IEEE Transactions on Cybernetics*, 2017, 47(10): 3466-3479.
- [11] 赵立杰, 邹世达, 郭烁, 等. 基于正则化随机配置网络的球磨机工况识别[J]. *控制工程*, 2020, 27(1): 1-7.
- ZHAO L J, ZOU SH D, GUO SH, et al. Ball mill load condition recognition model based on regularized stochastic configuration networks [J]. *Control Engineering of China*, 2020, 27(1): 1-7.
- [12] LI M, WANG D H. 2D stochastic configuration networks for image data analytics [J]. *IEEE Transactions on Cybernetics*, 2019, 99: 1-14.
- [13] GUAN N Y, TAO D C, LUO Z G, et al. Manifold regularized discriminative nonnegative matrix factorization with fast gradient descent [J]. *IEEE Transactions on Image Processing*, 2011, 20(7): 2030-2048.
- [14] 汤一彬, 徐宁, 姚澄, 等. 基于旋转不变稀疏表示和流形学习的图像降噪[J]. *仪器仪表学报*, 2014, 35(5): 1101-1108.
- TANG Y B, XU N, Y CH, et al. Image denoising via rotation invariant sparse representation and manifold learning[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(5): 1101-1108.
- [15] BENGIO Y, COURVILLE A, VINCENT P. Representation learning: A review and new perspectives [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1798-1828.
- [16] LIU Y, LIU K, YANG J, et al. Spatial-neighborhood manifold learning for nondestructive testing of defects in polymer composites[J]. *IEEE Transactions on Industrial Informatics*, 2019, 16(7): 4639-4649.
- [17] BELKIN M, NIYOGI P, SINDHWANI V. Manifold regularization: A geometric framework for learning from labeled and unlabeled examples [J]. *Journal of Machine Learning Research*, 2006, 7: 2399-2434.
- [18] LI M, WANG D H. Insights into randomized algorithms for neural networks: Practical issues and common pitfalls [J]. *Information Sciences*, 2017, 382/383: 170-178.
- [19] CHIANG L, RUSSELL E, BRAATZ R. Fault detection and diagnosis in industrial systems [M]. London: Springer-Verlag, 2001.
- [20] ZHANG S, ZHAO C, GAO F. Incipient fault detection for multiphase batch processes with limited batches [J]. *IEEE Transactions on Control Systems Technology*, 2017, 27(1): 103-117.
- [21] CHEN J, LIU J. Mixture principal component analysis models for process monitoring [J]. *Industrial & Engineering Chemistry Research*, 1999, 38(4): 1478-1488.
- [22] BUCKLAND M, GEY F C. The relationship between recall and precision [J]. *Journal of the Association for Information Science & Technology*, 2010, 45(1): 12-19.

作者简介



潘承燕, 2018 年于青岛科技大学获得学士学位, 现为大连海事大学船舶电气工程学院硕士研究生, 主要研究方向为故障检测与诊断。

E-mail: 1647667348@qq.com

Pan Chengyan received her B. Sc. degree from Qingdao University of Science and Technology in 2018. She is currently pursuing her M. Sc. degree in Marine Electrical Engineering College at Dalian Maritime University. Her main research interests are fault detection and diagnosis.



徐进学(通信作者), 1986 年于沈阳化工学院获得学士学位, 分别在 1995 年和 2005 年于东北大学获得硕士学位和博士学位, 现为大连海事大学教授, 主要研究方向为智能控制、过程控制、故障检测与诊断等。

E-mail: xujx@dlmu.edu.cn

Xu Jinxue (Corresponding author) received his B. Sc. degree from Shenyang University of Chemical Technology in 1986, and received his M. Sc. degree and Ph. D. degree both from Northeastern University in 1995 and 2005, respectively. He is currently a professor at Dalian Maritime University. His main research interests include intelligent control, process control and fault detection and diagnosis.