

8-19-2021

Actuator Fault Status Evaluation Based on Two-Class NMF Network

Yinsong Wang

Department of Automation, North China Electric Power University, Baoding 071003, China;

Tianshu Sun

Department of Automation, North China Electric Power University, Baoding 071003, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Actuator Fault Status Evaluation Based on Two-Class NMF Network

Abstract

Abstract: In the feedback control loop, the adjustment ability of controller covers up the performance degradation of the actuator to some degree. *A fault state evaluation algorithm based on a two-class non-negative matrix network is proposed to implement online fault state monitoring of the actuator, including fault classification and degradation assessment. The local static features of the samples are extracted, and a classifier model is established to form a network. The similarity is introduced to describe the dynamic characteristics between samples. To fulfill the actuator fault status assessment, the static distance and dynamic changes of the network output are merged to construct the fault discrimination index and degradation index.* The effectiveness of the algorithm is proved by the experiment of double-tank tank liquid level cascade control and the single loop simulation based on DAMADICS platform.

Keywords

actuator, non-negative matrix factorization, fault diagnosis, degradation assessment

Recommended Citation

Wang Yinsong, Sun Tianshu. Actuator Fault Status Evaluation Based on Two-Class NMF Network[J]. Journal of System Simulation, 2021, 33(8): 1882-1891.

基于二分类 NMF 网络的执行器故障状态评估

王印松, 孙天舒

(华北电力大学 自动化系, 河北 保定 071003)

摘要: 针对反馈控制回路中, 控制器的调节能力会在一定程度上掩盖执行器的性能下降的问题, 提出一种基于二分类非负矩阵网络的故障状态评估算法, 实现执行器的在线故障状态监控, 包括故障分类和退化评估。该方法提取样本的局部静态特征, 建立了分类器模型以形成网络; 并且引入相似度来描述样本之间的动态特征。为实现执行器故障状态评估, 融合网络输出的静态距离与动态变化, 构建了故障判别指标和退化指标。通过双容水箱液位串级控制实验和基于 DAMADICS 平台的单回路仿真实验, 证明了该算法的有效性。

关键词: 执行器; 非负矩阵分解; 故障诊断; 退化评估

中图分类号: TP215; TP277; TP391.9 文献标志码: A 文章编号: 1004-731X (2021) 08-1882-10

DOI: 10.16182/j.issn1004731x.joss.20-0319

Actuator Fault Status Evaluation Based on Two-Class NMF Network

Wang Yinsong, Sun Tianshu

(Department of Automation, North China Electric Power University, Baoding 071003, China)

Abstract: In the feedback control loop, the adjustment ability of controller covers up the performance degradation of the actuator to some degree. A fault state evaluation algorithm based on a two-class non-negative matrix network is proposed to implement online fault state monitoring of the actuator, including fault classification and degradation assessment. The local static features of the samples are extracted, and a classifier model is established to form a network. The similarity is introduced to describe the dynamic characteristics between samples. To fulfill the actuator fault status assessment, the static distance and dynamic changes of the network output are merged to construct the fault discrimination index and degradation index. The effectiveness of the algorithm is proved by the experiment of double-tank tank liquid level cascade control and the single loop simulation based on DAMADICS platform.

Keywords: actuator; non-negative matrix factorization; fault diagnosis; degradation assessment

引言

作为主要的调控部件, 执行器在电力、冶金、化工等工业生产中都有广泛的应用。在复杂的生产环境中, 它的劣化和故障不可避免地发生, 并会造成经济安全影响^[1]。然而, 在闭环系统中, 由于控制器的调节作用, 执行器的故障状态, 尤其是早期劣化往往被掩盖, 而当出现明显的故障特征时, 已

经调控失灵, 因此, 实时监控、及时诊断执行器状态具有重要的现实意义。

基于机理建模的方法具有比较大的挑战性, 难点在于模型复杂、需要先验知识、成本大。相比而言, 基于数据驱动的方法不依赖物理模型分析, 只需要提供大量有效的实验数据即可。由于自动化程度的提高, 大量现场数据通过传感器采集并存储到

收稿日期: 2020-06-08

修回日期: 2020-07-08

基金项目: 国家自然科学基金(61533013)

第一作者: 王印松(1967-), 男, 博士, 教授, 研究方向为先进控制策略和控制系统故障诊断技术。E-mail: wys@ncepu.edu.cn

计算机, 为数据分析提供实施基础^[2]。多元统计分析作为常用的数据处理技术, 能将高维的数据空间映射到低维特征空间, 从而挖掘数据内部的信息, 因此成为基于数据驱动的故障诊断领域的研究热点, 包括经典的主元分析、偏最小二乘、Fisher 判别分析等。除了这些传统的方法, 近年来, Lee 等提出乘性迭代优化的思想使非负矩阵分析 (Non-negative Matrix Factorization, NMF) 有了长足的发展^[3]。有别于传统的多元统计方法存在一定的假设条件或依赖特性, 该方法只要求测量数据和分解结果非负。这使得它天然存在一定的稀疏性并能学习数据的局部特征。为了适应现场的需要, Ding 等^[4]更进一步放宽 NMF 的非负约束, 提出 Semi-NMF, 使得该方法可以用在包含负数的数据集上, 突破了应用层面的限制。目前该算法已成功应用于数据挖掘^[5-6]、图像处理^[7-8]、文本分析^[9]、盲源信号分离^[10-11]等诸多领域, 并取得不错的效果。

非负矩阵分析在故障检测与诊断领域引起重视并得到广泛的研究。例如朱晓洁利用 NMF 提取滚动轴承双谱时频图中的故障信息, 作为支持向量数据描述算法的特征输入进行训练分类^[12]; 牛玉广等^[13]提出一种新的基于稀疏约束非负矩阵分解的复杂工业过程故障检测算法, 并成功应用于某 1 000 MW 机组; 成洁等^[14]综合利用递归图和局部非负矩阵分解提取轴承振动信号蕴含的特征信息, 通过分类器确定故障类型; Rai 等^[15]针对轴承的缓变故障, 利用 Semi-NMF 对数据的特征矩阵进行分解并通过贝叶斯推理得到正常与故障的指标结论, 检测故障的发生。但是以上研究要么是利用 NMF 提取故障特征, 要么进行故障检测, 并不能对故障类型进行分类处理, 且缺乏对故障程度的评价。而 Jia Q 等^[2]提出了一种新的矩阵分解方法——TSNMF, 可以学习不同故障数据的标签信息和几何结构, 根据学习到的模型检测并隔离故障。但是该模型混杂了多种故障特征, 对检测矩阵产生影响, 干扰故障判断。此外不适用于大样本多变化的数据集, 模型训练效率不高。

针对以上问题, 本文提出一种基于二分类非负矩阵网络的执行器故障状态评估算法。该算法的核心在于提取静态特征训练模型并实现模型库的更新, 提取动态特征融合相似度变化。最终综合样本的静态距离和动态变化, 构建故障判别指标和退化指标, 实现故障检测、分类与性能劣化评估。该算法具有以下优势: ①框架简单, 可解释性强, 没有超参数、黑箱系统等复杂结构; ②在实现故障检测的同时, 更进一步, 利用设计的指标诊断故障类型, 独立的故障模型规避了相互之间的干扰; ③基于故障诊断结果, 再深层次挖掘故障随着时间的恶化程度信息, 予以定量评价。

1 基于二分类 NMF 网络的执行器故障状态评估

1.1 算法框架

本小节从宏观层面阐述二分类 NMF 网络的基本框架。它包含模型训练和在线故障状态评估 2 个部分, 如图 1 所示。

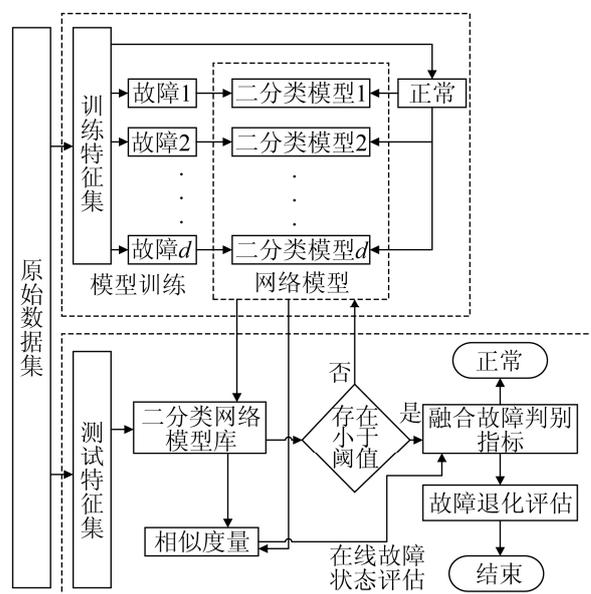


图 1 二分类 NMF 网络框架

Fig. 1 Two-class NMF network framework

从现场采集的原始数据经 Semi-NMF 算法提取特征, 划分为 2 个特征集, 一个用于训练不同故

障对应的模型，组建模型库；另一个作为测试集，检验故障的发生并诊断其具体类别。针对不同类别的故障，利用指标量化其随时间的劣化程度。

在整个框架中，无论特征集的构建还是二分类模型的训练，以及两大指标的设计都离不开非负矩阵算法的应用。而且，在实际的测试过程中，二分类 NMF 网络具有结构简洁、可解释性强的特点。与传统的多元统计方法以及其他的 NMF 诊断方法相比，本文方法主要存在以下优点：①框架简单，不存在超参数、黑箱等复杂结构，便于理解。得益于 NMF 算法的稀疏性和局部特征提取能力，可以将数据分解为表现一段时间内固有特性的静态基矩阵和该段时间内变化波动的动态表示矩阵。利用静态矩阵构建模型库，阐释不同故障模式的内在特征；利用动态矩阵建立指标诊断与评价体系，反映不同故障类型的外在变化。因此，具有很强的可解释性。②在检测故障发生的基础上，诊断故障类型。大多数的研究将 NMF 算法用于故障检测的前置数据分析，只有如 TSNMF 的少部分研究拓宽该算法在诊断分类上的功能应用，本文框架更在此基础上，利用独立的模型、特定的初始化条件、融合的指标，克服 TSNMF 中多种故障相互干扰的缺陷，提升了诊断的正确率。③定量评价故障性能劣化程度。NMF 很少有用于故障性能评价的研究。本文在判别故障类型之后，利用指标定量分析指定故障随时间的恶化趋势，对现场调控和维修具有指导意义。

1.2 特征提取

Semi-NMF 是 Chris Ding 在传统的非负矩阵分解要求样本数据非负的基础上，对该限制进一步放宽，使之可以应用于存在负数的数据集上的改进，即允许数据集 $X \in \mathbf{R}^{m \times n}$ 和基矩阵 U 有负值，而 V 依旧保持非负^[4]，即：

$$X_{\pm} = U_{\pm} V_{+} \quad (1)$$

式中：下标“+”表示正值，“±”表示既可以是正值也可以是负值； U 为 $m \times r$ 维的基矩阵， V 为 $r \times n$ 维的

系数矩阵， r 的取值满足 $(m+n)r < mn$ ， m 为变量个数， n 为样本个数。根据基于 F 范数的近似迭代法，以 X 与 UV 的误差最小作为目标函数，可以得到 U 和 V 的更新法则如下：

$$U = X V^T (V V^T)^{-1} \quad (2)$$

$$V_{ij} \leftarrow V_{ij} \sqrt{\frac{[U^T X]_{ij}^+ + [(U^T U)^- V]_{ij}}{[U^T X]_{ij}^- + [(U^T U)^+ V]_{ij}}} \quad (3)$$

设： Q_{ij}^+ 和 Q_{ij}^- 分别为矩阵 Q 的正值和和负值部分。其计算为：

$$Q_{ij}^+ = (|Q_{ij}| + Q_{ij}) / 2, \quad Q_{ij}^- = (|Q_{ij}| - Q_{ij}) / 2 \quad (4)$$

显然， $Q_{ij} = Q_{ij}^+ - Q_{ij}^-$ 。

通过 Semi-NMF 对代表样本静态特性的基矩阵进行提取，组成特征集。给定一组有标签数据集包含正常状态和若干故障状态。实际工业过程中，数据量庞大且存在噪声干扰，利用 NMF 抗噪声的特性，先对原始数据集使用 Semi-NMF 进行特征提取。具体步骤为：①对正常状态和故障状态的数据集等间隔划分成若干小段；②采用 Semi-NMF 提取每一段的基矩阵，保留标签信息，形成由特征向量构成的新数据集 X_c 和 X_f ，其中 X_c 表示正常态， X_f 表示故障态。其优势在于：①噪声信息隔离在系数矩阵 V 中，而基矩阵 U 则作为特征矩阵表示该段数据的代表性特征；②数据段的简短使得数据流的变化信息体现在 U 的变化中。如此，单一矩阵 U 代表了一小段数据的静态特征，由多个 U 组成的特征集代表了整个数据流的动态变化。因此提取后的特征集既能反应原始数据的本质特征，又能体现其动态变化，具有很强的可解释性。

1.3 模型训练

二分类 NMF 网络核心在于训练多个二分类模型。每个模型针对一种故障，判断输入信号是正常状态还是该种故障状态。包含正常态和各类故障态的原始数据集通过特征提取在保留数据静态和动态特征的同时，大大降低了数据计算规模。特征数据集被分为正常态组成的集合以及由 d 类故障特

征组成的集合, 将每一类故障集合与正常态集合搭配形成训练矩阵, 输入运算模型中, 得到对应类别故障的二分类模型。

通过 1.2 节处理得到了正常态特征集 X_c 和故障态特征集 $X_f = [X_{f1}, X_{f2}, X_{f3}, \dots, X_{fd}]$ 。其中, X_{fi} 表示第 i 类故障特征集, 并且一共有 d 类故障。将 X_c 与每一个故障态特征集 X_{fi} 组合形成新的数据集 $X_{train}^i \in R^{m \times k}$, ($i=1, 2, \dots, d$), 对任一个新数据集, 构造目标函数如下^[2]:

$$\min_{U, V} \|X_{train}^i - UV\|_F^2 + \alpha \|V^T V - W\|_F^2 \quad (5)$$

st. $V \geq 0$

式中: $U \in R^{m \times 2}$ 为由正常态和故障态组成的基矩阵。 $V \in R^{2 \times k}$ 则可以初始化为由标签信息组成的系数矩阵。对于 X_{train}^i 中的每一个特征列向量 X_j , 若 X_j 属于正常态, 则 $V_{1j} = 1, V_{2j} = 0$; 若 X_j 属于故障态, 则 $V_{1j} = 0, V_{2j} = 1$, 所以 $V = \begin{bmatrix} 1_p & 0_p \\ 0_p & 1_p \end{bmatrix}$

$p = k / 2$ 。为了在迭代求解 U 的过程中, 减小标签信息的损失, 同时能反应训练样本在基矩阵下的几何动态变化, 采用了对称 NMF 约束, 此处, W 定义为 0-1 权值。即, 如果 X_i 与 X_j 是同类标签, 则 $W_{ij} = 1$, 否则, $W_{ij} = 0$ 。

式(5)的求解可以通过解决以下最优化问题得到:

$$\min_{V > 0} L(U, V) = \|X_{train}^i - UV\|_F^2 + \alpha \|V^T V - W\|_F^2 =$$

$$\text{Tr}(X_{train}^i{}^T X_{train}^i - 2X_{train}^i UV + V^T U^T UV) +$$

$$\alpha \text{Tr}(V^T V V^T V - 2V^T V W + W^T W) \quad (6)$$

对 U 求偏导, 并使其结果为 0, 则,

$$U = X_{train}^i V^T (V V^T)^{-1} \quad (7)$$

引入拉格朗日算子 Φ , 参考文献[2]的过程, 可以得到更新法则为:

$$V_{ij} \leftarrow V_{ij} \frac{(U^T UV)_{ij}^- + (U^T X_{train}^i)_{ij}^+ + 2\alpha (VW)_{ij}}{(U^T UV)_{ij}^+ + (U^T X_{train}^i)_{ij}^- + 2\alpha (V V^T V)_{ij}} \quad (8)$$

因此, 对于每一个新数据集 X_{train}^i , 即可以提

取一个基矩阵 U , 作为代表该数据集静态特征的模型, 相应的表示矩阵 V 即为训练模型的动态特征。

1.4 在线故障分类

训练好的模型被用于在线测试数据的验证, 标签未知的测试特征集输入模型库得到静态距离, 并与预设的阈值比较, 如果所有模型的输出静态距离都大于阈值, 则说明产生了新的模型库中未收录的故障, 此时返回重新训练模型, 更新模型库。否则, 融合静态距离和训练模型与测试模型的动态变化的相似度量, 形成故障判别指标, 由该指标反应当前的故障状态和故障类型。

对于新采集的无标签数据, 经特征提取后, 组成待测数据集为 X_{test} , 则 X_{test} 与 V_{test} 之间存在以下关系:

$$X_{test} \approx UV_{test} \quad (9)$$

式中: U 为训练得到的模型, 因而只需求解 V_{test} 即可。建立目标方程如下:

$$\min_{V_{test} > 0} J(V_{test}) = \|X_{test} - UV_{test}\|_F^2 =$$

$$\text{Tr}(X_{test}^T X_{test} - 2X_{test} UV_{test} + V_{test}^T U^T UV_{test}) \quad (10)$$

引入拉格朗日算子 Ψ , 对 V_{test} 求偏导, 应用式(4)分解, 并根据 KKT 条件, 得到最终的更新规则如下:

$$(V_{test})_{ij} \leftarrow (V_{test})_{ij} \frac{(U^T UV_{test})_{ij}^- + (U^T X_{test})_{ij}^+}{(U^T UV_{test})_{ij}^+ + (U^T X_{test})_{ij}^-} \quad (11)$$

在得到 V_{test} 后, 通过判断 V_{test} 中两行数据的大小来检测故障状态。如果第一行的值大于第二行, 则说明处于正常态, 反之则发生 U 对应模型的故障。

理想状态下, 正常态的 V_{test} 矩阵会接近 $[1_p, 0_p]^T$, 而故障态的 V_{test} 矩阵会接近 $[0_p, 1_p]^T$ 。但在实际应用中, 根据 V_{test} 的不同初始化会发生局部最优问题, 而最终得到的结果虽然可以满足 X_{test} 与 UV_{test} 的近似, 却不一定使 V_{test} 矩阵满足不同状态的分离。所以, 本文采用特定指向的 V_{test} 的初始化。即分 2 种情况: 分别假设待检测样本是正常的, 此

时, V_{test} 初始化为 $[1_p, 0_p]^T$; 假设待检测样本是故障的, 此时, V_{test} 初始化为 $[0_p, 1_p]^T$ 。通过比较 2 种初始化结果下的残差距离, 选择比较小的作为判断依据, 也就是静态距离。根据预设的阈值, 判断静态距离与阈值的大小, 如果所有模型输出的静态距离都大于阈值, 则表明出现新的故障类别, 此时返回更新模型库, 反之, 则可以进行下一步的故障检测与判别。

事实上, 距离最小不一定是合适的。对于公式 $X_{\text{train}} = UV$, 可以理解为, 原始数据由 2 个模板向量组成的基矩阵, 通过表示矩阵 V 表达。则, 基矩阵可以理解为静态的特征矩阵, 而矩阵 V 的上下两行则表示源数据通过基矩阵中 2 个特征向量的动态变化表示。因而, 在模型训练时, 矩阵 V 不仅表示标签信息, 在迭代更新中亦包含了训练样本的变化信息。对于待检测样本, 判断状态时, 既要满足残差距离, 也要满足训练矩阵 V 和检测矩阵 V_{test} 的相似。综上, 制定一个状态判断指标 F_{dia} :

$$F_{\text{dia}} = \|X_{\text{test}} - UV_{\text{test}}\|_F^2 + \beta \times (1 - |\gamma(V, V_{\text{test}})|) \quad (12)$$

式中: γ 是皮尔逊相关系数, 用于度量训练矩阵 V 和检测矩阵 V_{test} 的相似性。二分类 NMF 网络每一个故障模型对应一个 F_{dia} 值, F_{dia} 越小则代表发生相应故障的可能性越大, 即判断发生该类故障。

1.5 故障退化评估

除了突变故障外, 故障的发生是一个渐变过程, 因而不同时间段, 设备性能的劣化程度不同。如何衡量渐变故障的恶劣程度, 此处定义了一个计算指标:

$$F_{\text{det}} = \text{mean}(V_{\text{test}})_{2j} \quad (13)$$

V_{test} 反应了待检测样本相对于故障模板的变化特征, 呈现一种动态变化特性。对 V_{test} 中反应故障的指示序列取平均值, 用以衡量在一个数据段内的故障严重程度。由于模型固定, 即基矩阵 U 固定, 则 V_{test} 的变化就反映了待测数据偏离模型的程度。当输入数据为训练数据本身时, 得到的 V_{test} 为原值, 即均值为 1; 当输入数据为劣化数据时,

应用同一故障模型, 得到的表示矩阵必然发生偏离, 劣化程度越高, 偏离程度越强。所以, 接近于 1 则表明故障表现不明显, 越远离 1 则说明设备性能劣化程度加深。

1.6 故障状态评估算法步骤

综合前文对方法的详细阐述, 本小节总结故障状态评估的步骤如下:

step 1: 数据处理和特征提取。将包含正常态和故障态的数据集, 在经过去粗大值、平滑处理后, 等间隔划分成若干小段。对每一小段, 通过式(1)提取特征矩阵。每一个训练集包含正常态特征和任一种类型的故障特征。

step 2: 训练模型。根据训练集的标签信息, 初始化矩阵 V 和 W 以及权重系数。不断迭代式(7)和(8), 得到每一类故障代表的标称模型 U 和 V 。

step 3: 测试模型。对待检测数据, 先进行数据处理和特征提取, 组成测试集。根据式(11), 对每一个故障模型迭代计算各自的表示矩阵。

step 4: 判断故障。计算每一个模型的表示矩阵与测试集的静态距离, 在与预设的阈值比较后, 计算表示矩阵与标称模型系数矩阵的相似度, 根据式(12), 计算判别指标, 最小的指标值代表的模型就是诊断结果。

step 5: 退化评估。当诊断出故障时, 根据式(13), 计算劣化评价指标, 衡量当前故障恶化程度。

2 执行器故障状态评估实验与仿真

2.1 基于双容水箱液位串级控制系统的实验案例

对于已经发生的故障, 通过在 OVATION 水箱实验平台, 模拟电动调节阀的故障进行实践验证, 实验设备如图 2 所示。实验采用双容水箱液位控制系统, 以下水箱液位作为控制目标。针对调节阀状态, 采集控制指令、阀位反馈及二者之间的差值、比值信号, 液位信号, 一共 5 个变量作为样本的构成。分别在正常态、恒增益故障、恒偏差故障、卡

死故障、粘滞故障、死区故障, 6 种情况下各采集 2 000 个数据样本。每 100 个样本组成一个片段, 利用 Semi-NMF 提取原始数据的静态特征。将正常态与每一种故障态的特征集组合, 形成训练集输入网络, 学习产生对应各类故障的二分类模型库。为验证网络的有效性, 再次在 6 种状态下各采集 1 000 个样本, 并提取特征, 构建测试集。根据专家经验, 设定阈值为 0.5, 指标系数 $\alpha=1$, $\beta=0.2$ 。



图 2 实验设备

Fig. 2 Experimental equipment

表 1 是各测试集对应网络输出的静态距离, 存在小于阈值的情况, 所以不需要更新模型库。表中每列表示一个二分类模型, 并且左边的数值是判断正常的静态距离, 而右边的数值表示判断特定故障的静态距离。每行表示一类检测样本。很显然, 残差距离越小表示检测数据越接近对应的判别分类, 故而最小的距离便代表了最终的分类结果, 如表中加粗的数值所示。对于正常数据, 所有的分类器都指向正常。对于单一的具体故障, 除粘滞故障外, 每个待检测故障在各自对应的故障二分类器中都有良好的效果。而即使粘滞判断错误, 其正确输出 7.79 与错误判断 7.74 也相差无几。静态距离作为故障分类的判别, 忽略了数据本身存在的动态特性, 片面的信息容易造成误判, 所以在引入训练模型与测试输出的表示矩阵的相似度后, 弥补了这一缺陷, 相关的指标判断结果如表 2 所示。显而易见, 在引入相似性考量后, 粘滞故障能够有效判断出来。

为了更好的比较本文算法框架的性能, 相同的数据集也被应用在其他诊断方法上进行对比测试, 得到的对比结果如表 3 所示。

表 1 网络输出的静态距离

Tab. 1 Static distance of network output

实际状态	恒增益模型		恒偏差模型		卡死模型		粘滞模型		死区模型	
正常	0.23	40.83	0.23	17.13	0.23	98.01	0.23	2.32	0.23	1.58
恒增益	38.46	0.22	38.46	22.42	38.46	127.69	38.46	38.77	38.46	38.20
恒偏差	16.60	23.24	16.60	0.23	16.60	110.94	16.60	17.04	16.60	16.39
卡死	120.00	164.40	120.03	138.91	120.03	3.27	120.03	119.97	120.03	120.51
粘滞	7.81	40.04	7.81	17.76	7.81	97.53	7.81	7.79	7.81	7.74
死区	1.40	40.09	1.40	16.68	1.40	97.46	1.40	1.0	1.40	0.24

表 2 故障判别指标结果

Tab. 2 Fault discrimination index results

实际状态	恒增益模型		恒偏差模型		卡死模型		粘滞模型		死区模型	
正常	0.42	41.01	0.42	17.28	0.42	98.17	0.42	2.50	0.42	1.73
恒增益	38.65	0.40	38.65	22.59	38.65	127.84	38.64	38.95	38.65	38.35
恒偏差	16.74	23.39	16.74	0.41	16.74	111.08	16.76	17.20	16.74	16.53
卡死	120.10	164.50	120.10	139.03	120.10	3.46	120.17	120.11	120.10	120.57
粘滞	8.01	40.20	8.01	17.88	8.01	97.66	7.88	7.85	8.01	7.92
死区	1.56	40.25	1.56	16.85	1.56	97.63	1.58	1.17	1.56	0.37

方法 1: 采用文献[2]提出的 TSNMF 方法, 其具体操作步骤请参阅相关文献, 在此不再赘述。

方法 2: 采用 Fisher 判别分析划分数据类型。分为原始数据集和特征数据集进行训练, 输入数据为不同类型故障状态数据, 输出是不同的分类结果。

方法 3: 应用最小二乘支持向量机(LSSVM)进行分类。采用“一对一”的分类模式构建 $d(d+1)/2$ 个二分类器, 选择 RBF 核函数, 根据“投票法”来判别数据的分类结果。分别使用原始数据集和特征数据集构建模型并验证, 输出为故障的诊断结果。

方法 4: 使用 BP 神经网络进行分类。采用 5-7-6 的结构, 输入层对应采集的变量信号, 隐藏层使用双曲正切函数, 输出层为 6 种不同的执行器状态, 分别利用原始数据集和特征数据集训练模型并检验。

表 3 不同方法的判别正确率对比

Tab. 3 Comparison of accuracy of different methods

方法		正确率
本文方法	特征集+二分类 NMF 网络	1
方法 1	特征集+TSNMF	0.65
方法 2	特征集+FDA	0.93
	原始集+FDA	0.86
方法 3	特征集+LSSVM	1
	原始集+LSSVM	0.985 2
方法 4	特征集+BP 神经网络	0.983 3
	原始集+BP 神经网络	0.829 2

说明:

(1) 由表 3 可见, 除了基于 TSNMF 的方法外, 其他方法都取得良好的诊断结果, 尤以本文算法和基于特征集的 LSSVM 最优。但是二分类 NMF 网络可以通过静态模型刻画故障的长期的固有属性, 通过表示矩阵描述故障数据短时的动态变化, 具备很高的可解释性, 而其他方法不具备以上条件;

(2) 基于特征集的分类效果普遍优于基于原始集的分类效果, 一方面是特征集集中了数据的典型特征而降低噪声干扰, 另一方面则是部分故障由于控制器的调节能力, 其动态变化会短暂处于正常状

态, 这造成传统方法的误判;

(3) TSNMF 将多种故障模式集中于一个模型矩阵 U 中表示, 再更新表示矩阵 V , 从而使 UV 接近 X 时, 由于矩阵乘法的运算性质, U 中不同故障代表的列向量都会对 V 造成影响, 使得 X 与 UV 的残差距离虽然达到最小, 但是 V 丧失了表达样本故障分类的能力, 而本文算法利用独立模型克服了不同故障之间的相互干扰, 并通过融合动态变化的相似度构建判别指标, 提高了分类的准确率。

2.2 基于 DAMADICS 的单回路仿真

DAMADICS 是一个广泛用于气动阀故障诊断理论研究的实验仿真平台, 以实际的阀门对象作为参考, 设置了 19 种故障包括突变和缓变故障。为验证二分类 NMF 网络在缓变故障检测、诊断与性能劣化评价中的性能, 选取阀塞或阀座下沉、阀或轴承摩擦增加、外部泄露、内部泄露 4 个缓变故障进行仿真实验。将 DAMADICS 平台作为一个模块, 添加入一个二阶单回路控制系统中。PID 输出即为该模拟平台的指令输入, 平台输出即为对象的输入, 系统对象 $G(s) = \frac{0.2}{5s^2 + 15s + 1}$, 系统结构如图 3 所示。

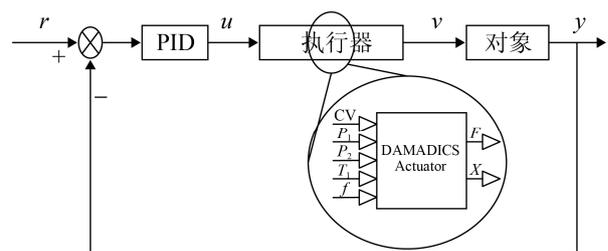


图 3 仿真原理图

Fig. 3 Simulation schematic

从故障开始出现, 每一类采集 6 000 个数据点, 划分每 300 个样本作为一个特征提取段, 利用 Semi-NMF 提取样本的静态特征组成特征集。其余参数如 2.1 节设置, 得到的部分指标如表 4 所示。

表 4 缓变故障判别指标结果
Tab. 4 Discrimination index results of incipient faults

实际状态	阀塞或阀座下沉		阀或轴承摩擦增加		外部泄露		内部泄露	
正常	0.34	0.42	0.15	0.24	0.17	0.21	0.16	0.16
阀塞或阀座下沉	0.31	0.21	0.70	0.71	0.71	0.79	0.70	0.71
阀或轴承摩擦增加	0.57	0.59	0.24	0.15	0.23	0.25	0.20	0.21
外部泄露	0.61	0.71	0.22	0.26	0.21	0.14	0.22	0.21
内部泄露	0.39	0.48	0.06	0.14	0.06	0.09	0.05	0.04

根据表 4 中加黑的数据, 可以清晰地判断出正常与缓变故障的发生。此外, 与故障已经发生的电动执行器案例不同, 观察同一二分类器对不同缓变故障的检测结果, 说明在起始阶段, 故障征兆不明显。由于 PID 的调节补偿作用, 在一定程度上抵消了调节阀的缓慢劣化对被控变量的影响, 而 PID 输出相应出现缓慢的补偿调节, 因而 2 个检测结果呈现微弱的差距, 但却表现不同的性状。

针对气动阀的缓变故障诊断, TSNMF, FDA, LSSVM 以及 BP 神经网络同样有着不同的性能效果, 其对比结果如表 5。对比表 3 和表 5, TSNMF, FDA, LSSVM 以及 BP 神经网络在诊断缓变故障时性能普遍低于故障已经发生的情况, 而二分类 NMF 网络依旧保持良好的诊断性能。其原因在于, 早期故障的数据变化不明显, 由于控制器的反馈调节作用, 相比于正常数据集只有微小的差距, 这导致 FDA, LSSVM 以及 BP 神经网络难以训练区分实际情况, 造成误判。此外, 本文特征集的提取方法在缓变故障诊断中仍然具有卓越的优化作用。具体体现在在 2 个实验案例中, 基于特征集的诊断效果普遍优于基于原始数据的分析结果。

表 5 缓变故障的不同方法对比
Tab. 5 Comparison of different methods for incipient faults

方法	正确率
特征集+二分类 NMF 网络	1
特征集+TSNMF	0.6
特征集+FDA	0.8
原始集+FDA	0.273 6
特征集+LSSVM	0.84
原始集+LSSVM	0.674 8
特征集+BP 神经网络	0.72
原始集+BP 神经网络	0.438 8

对于缓变故障, 随着时间的推移, 其恶化程度越来越高, 虽然在 PID 反馈补偿机制下, 故障初始阶段由于置于 PID 的调节能力范围内而使被控变量依旧呈现有效性能, 但是如果不及时发现故障, 必将变为不可控的故障形态。以单一缓变故障——内漏故障为例, 首先计算全行程下内漏故障二分类模型的分类效果, 其次通过退化指标来衡量设备的劣化程度。

图 4 描述了 27 000 个数据样本, 以每 300 个数据样本为一段提取出 90 个特征集, 并以每 5 个特征集为一组输入二分类模型中, 得到 18 个指标判断值。显然, 所有内漏故障的指标值都比判断正常来的小, 所以诊断出现内漏故障。针对加强故障程度后是否会出现误判的问题, 图 5 展示了不同二分类器的判断结论。从中可以清晰的发现, 代表内漏故障的指标值始终低于其他判断结果, 并且与它们保持一段很明显的距离。这充分说明, 二分类 NMF 网络在面对故障恶化的情况下依旧有良好的诊断性能。

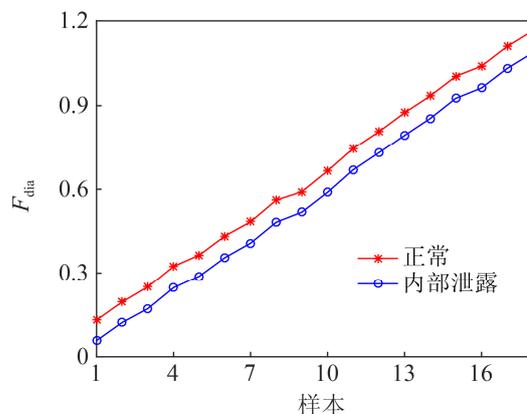


图 4 内漏故障诊断结果
Fig. 4 Internal leakage fault diagnosis results

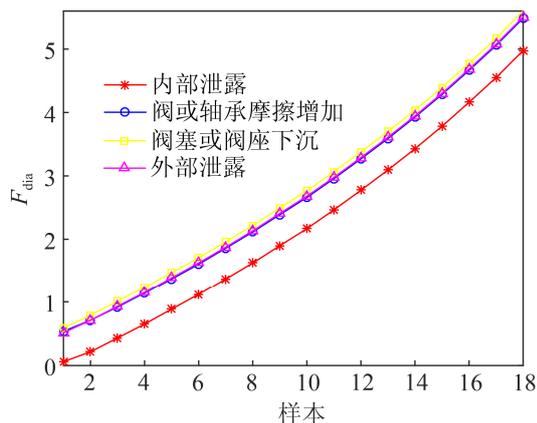
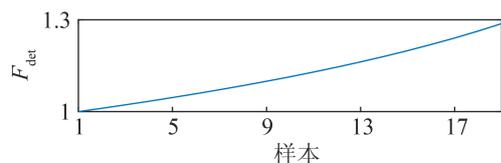


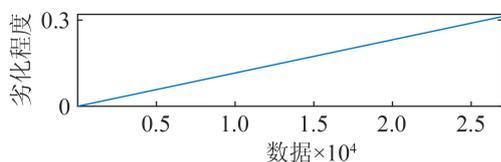
图5 逐渐加深的内漏故障诊断结果

Fig. 5 Diagnosis results of deepening internal leakage

图6为本文方法得到的劣化评估结果与实际情况的对比。图6(a)代表由二分类网络计算得到的故障恶化程度评价曲线，图6(b)则是DAMADICS平台模拟缓变故障的实际故障严重程度数值。在图6(a)中，指标值为1表示检测样本的故障强度与二分类器模型强度一致，超过1则表明故障恶化，而在本实验中，以刚发生内漏时的样本作为模型；在图6(b)中，0值代表没有故障，超过0值则代表故障增强。比较二者的结果，虽然基准不同(一个以1为基准，一个以0为基准)，但是故障恶化程度的评价结果相近，所以退化评估指标满足缓变故障的定性与定量标准。



(a) 故障恶化程度评价曲线



(b) 实际故障严重程度

图6 内漏故障劣化评价

Fig. 6 Evaluation of deterioration of internal leakage

3 结论

本文提出了一个新的基于非负矩阵分解的执

行器故障状态评估框架。该方法的优势在于，充分挖掘数据蕴含的静态和动态信息的同时，拓宽了在故障诊断和性能劣化评价上的功能应用。一方面融合静态距离与相似度量，提高故障判别的准确性，并且不受故障程度加深的影响；另一方面，挖掘数据的动态特征，衡量评估对象的故障恶化程度。在基于双容水箱的液位串级控制实验和基于DAMADICS平台的仿真实验中，通过对比分析，充分证明了反馈回路中，执行器故障检测、诊断与评估的优越性能。

参考文献:

- [1] Shi H, Li P, Su C, et al. Robust Constrained Model Predictive Fault-tolerant Control for Industrial Processes with Partial Actuator Failures and Interval Time-varying Delays[J]. Journal of Process Control (S0959-1524), 2019, 75: 187-203.
- [2] Jia Q, Zhang Y, Chen W. Simultaneous Fault Detection and Isolation Based on Transfer Semi-nonnegative Matrix Factorization[J]. Ind. Eng. Chem. Res (S0888-5885), 2019, 58(19): 8184-8194.
- [3] Lee D D, Seung H S. Algorithms for Non-negative Matrix Factorization[C]// Conference on Neural Information Processing Systems. Cambridge, USA: MIT Press, 2000: 556-562.
- [4] Ding C, Li T, Jordan M I. Convex and Semi-nonnegative Matrix Factorizations[J]. IEEE Trans Pattern Anal Mach Intell (S0162-8828), 2010, 32(1): 45-55.
- [5] 何俊, 杨世锡, 甘春标. 一类滚动轴承振动信号特征提取与模式识别[J]. 振动, 测试与诊断, 2017, 37(6): 1181-1186, 1281.
He Jun, Yang Shixi, Gan Chunbiao. Feature Extraction and Pattern Recognition of Vibration Signals in a Rolling Bearing[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(6): 1181-1186, 1281.
- [6] 全聪, 李晨亮, 吴黎兵. 基于二阶段迭代的非负矩阵分解的分类模型[J]. 武汉大学学报(理学版), 2020, 66(2): 190-196.
Quan Cong, Li Chenliang, Wu Libing. 2-STGNMF: Supervised 2-Stage Iterative Nonnegative Matrix Factorization Model for General Classification[J]. Journal of Wuhan University(Natural Science Edition), 2020, 66(2): 190-196.
- [7] 刘国庆, 卢桂馥, 张强. 一种稀疏图正则化的非负低

- 秩矩阵分解算法[J]. 重庆邮电大学学报(自然科学版), 2020, 32(2): 295-303.
- Liu Guoqing, Lu Guifu, Zhang Qiang. A Non-negative Low-rank Matrix Factorization Algorithm for Regularization of Sparse Graphs[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2020, 32(2): 295-303.
- [8] 黄鹏飞, 孔祥兵, 景海涛. 一种改进的高光谱解混非负矩阵分解初始化方法[J]. 激光与光电子学进展, 2020, 57(6): 219-226.
- Huang Pengfei, Kong Xiangbing, Jing Haitao. Improved Hyperspectral Unmixed Initialization Method based on Non-negative Matrix Factorization[J]. Laser & Optoelectronics Progress, 2020, 57(6): 219-226.
- [9] 高茂庭, 王正欧. 几种文本特征降维方法的比较分析[J]. 计算机工程与应用, 2006(30): 157-159.
- Gao Maoting, Wang Zheng'ou. Comparing Dimension Reduction Methods of Text Feature Matrix[J]. Computer Engineering and Applications, 2006(30): 157-159.
- [10] 李煜, 何世钧. 基于投影梯度的非负矩阵分解盲信号分离算法[J]. 计算机工程, 2016, 42(2): 104-107, 112.
- Li Yu, He Shijun. Blind Signal Separation Algorithm for Non-negative Matrix Factorization based on Projected Gradient[J]. Computer Engineering, 2016, 42(2): 104-107, 112.
- [11] 殷海青, 刘红卫. 一种基于 L1 稀疏正则化和非负矩阵分解的盲源信号分离新算法[J]. 西安电子科技大学学报, 2010, 37(5): 835-841.
- Yin Haiqing, Liu Hongwei. New Blind Source Separation Algorithm based on L1 Sparse Regularization and Nonnegative Matrix Factorization[J]. Journal of Xidian University, 2010, 37(5): 835-841.
- [12] 朱晓洁. 基于稀疏性非负矩阵分解的滚动轴承复合故障诊断[J]. 中国工程机械学报, 2018, 16(6): 553-558.
- Zhu Xiaojie. Fault Diagnosis of Bear's Compound Fault Based on Sparse No-negative Matrix Factorization[J]. Chinese Journal of Construction Machinery, 2018, 16(6): 553-558.
- [13] 牛玉广, 王世林, 林忠伟, 等. 基于多元统计过程监控的锅炉过程故障检测[J]. 动力工程学报, 2017, 37(10): 829-836.
- Niu Yuguang, Wang Shilin, Lin Zhongwei, et al. Fault Detection of Industrial Processes Based on Multivariate Statistical Process Monitoring[J]. Journal of Chinese Society of Power Engineering, 2017, 37(10): 829-836.
- [14] 成洁, 李思燃. 基于递归图和局部非负矩阵分解的轴承故障诊断[J]. 工矿自动化, 2017, 43(7): 81-85.
- Cheng Jie, Li Siran. Bearing Fault Diagnosis based on Recurrence Plots and Local Non-negative Matrix Factorization[J]. Industry and Mine Automation, 2017, 43(7): 81-85.
- [15] Rai A, Upadhyay S H. The Application of Semi-nonnegative Matrix Factorization for Detection of Incipient Faults in Bearings[J]. Proc Inst Mech Eng Part C J Mech Eng Sci (S0954-4062), 2019, 233(13): 4543-4555.