doi:10.3969/j.issn.1001-4837.2025.01.010

检验与维护

基于静/动态因素协同的承压设备损伤智能识别技术

朱建新[1,2],徐越遥[1,2],高振宇[1,2],乔　松[1,2],胡久韶[1,2]
(1.合肥通用机械研究院有限公司,合肥 230031;2.国家压力容器与管道安全工程技术研究中心,合肥 230031)

摘　要:在承压设备损伤模式识别技术标准、基于风险的检验(RBI)案例基础上,训练了融合标准与专家经验的损伤模式智能识别模型,包括以静态因素和动态因素为主要参数的识别模型,两者相结合用于设备损伤模式的识别。利用9 522个工程风险评估样本进行模型训练,并用2 459个样本进行验证。结果表明,29种损伤模式中,其中,19种的识别率在0.75以上,14种的识别率在0.85以上,12种的识别率在0.93以上。同时,对部分损伤模式识别率偏低的原因进行了分析,提出了进一步提高模型识别率的措施;利用该模型对7 063个RBI评估中记为"未知腐蚀"的损伤模式进行了分析,对未知腐蚀样本可能的损伤模式进行了探讨。该技术在某常减压装置上开展应用验证,显示出较好的应用效果。

关键词:承压设备;损伤模式;智能识别;机理分析;工况数据
中图分类号:TH49;O346.5;TP391.4　　**文献标志码:**A

Intelligent damage recognition technology for pressure equipment based on the collaboration of static and dynamic factors

ZHU Jianxin[1,2],XU Yueyao[1,2],GAO Zhenyu[1,2],QIAO Song[1,2],HU Jiushao[1,2]
(1.Hefei General Machinery Research Institute Co.,Ltd.,Hefei 230031,China;
2.National Technology Research Center for Safety Engineering of Pressure Vessels and Pipelines,Hefei 230031,China)

Abstract: Based on the standards for damage mode recognition technology for pressure equipment and risk-based inspection (RBI) cases,an intelligent damage recognition model that integrates standards and expert experience was developed.The model is composed of two sub-models,one is for static factors and the other is for dynamic factors.The combination of these two models was used for the recognition of damage modes of pressure equipment.The model was trained with 9 522 RBI cases and validated with 2 459 cases.The results show that the recognition rates for 19 out of 29 damage modes are above 0.75,the recognition rates for 14 damage modes exceed 0.85,and those for 12 damage modes reach over 0.93.Meanwhile,the causes for the low recognition rates for some damage modes were analyzed and measures for further enhancing the model's recognition rates were proposed.Furthermore,the model was utilized to analyze damage modes labeled as "unknown corrosion" in 7 063 RBI cases,aiming to ascertain possible damage modes for these instances of unknown corrosion.This technology has been successfully applied and validated on a specific atmospheric-vacuum distillation unit,yielding favorable application outcomes.

Key words:pressure equipment;damage model;intelligent recognition;mechanism analysis;working condition data

0　引言

承压设备在复杂的服役条件下发生"材料-工艺介质-服役工况"耦合的相互作用会发生损伤或失效,表现为腐蚀减薄、环境开裂、材料劣化和机械损伤4种典型形态[1]。由于材料类型、工艺介质种类、工况数据波动的多样性与复杂性,设备表现出的损伤模式多达80余种。大量工程案例分析表明,承压设备在复杂服役条件下发生的损伤是耦合多变的,即在同一工况下可能同时存

收稿日期:2024-10-06　**修回日期:**2024-12-22
基金项目:国家重点研发计划项目(2022YFB3306400);合肥通用机械研究院有限公司青年基金项目(2024011175)

在多种不同的损伤机制，一些损伤机制相互促进、一些相互抑制，设备的失效总体表现为由多种失效机制交互作用下主导损伤模式所决定[2]。

损伤的分析涉及到材料、设计、制造、工艺、腐蚀、力学等多学科交叉，要全面掌握需要大量的专业知识。近年来，通过国际合作与技术消化吸收再创新，合肥通用机械研究院有限公司等国内机构研发了基于风险的检验（Risk based inspection，RBI）、基于风险与寿命的设计方法（Risk based design，RBD）等技术及配套软件，其中包括基于机理的损伤模式识别模块[3-6]。借助这些技术及软件，在专业数据库支持下，通过收集承压设备相关数据，采用机理模型对这些设备在特定服役条件下可能的损伤模式加以分析，结合专家经验可以实现承压设备损伤模式的科学判定，并在此基础上提出合理可行的检验检测与风险控制措施，对保障承压设备的长周期安全运行发挥了重要作用[7]。

我国流程工业规模庞大，承压设备量大面广，设备运行过程中，工艺介质及操作参数波动导致设备发生的损伤时刻在进行。研究一种承压设备损伤模式智能筛选方法，将技术标准中的损伤模式识别方法与专家经验融入到智能模型中，利用模型在线监测设备损伤模式的动态变化，并结合RBI软件对设备风险开展分析，对预防和避免设备失效具有重要的作用。近年来，随着数字化及智能技术的快速发展，开发具备智能分析功能的软件、实现设备损伤的在线监测与预警[8-10]，对保障设备的长周期安全运行具有重要意义。

目前，人工智能技术在相关领域的应用已逐渐成熟，如医疗领域疾病诊疗[11]、商业及政务事务处理[12-13]，以及设备维护等[14]，基于大数据的设备故障诊断与模式识别技术也已逐渐开始[15-16]。针对承压设备损伤智能监测的迫切需求，在承压设备损伤模式相关标准和工程风险评估案例基础上，研究一种静态/动态因素相结合的损伤模式智能识别技术，以解决不同使用条件、工艺波动条件下承压设备损伤的智能识别难题。

1 损伤智能识别模型的提出

损伤模式识别是开展承压设备风险防控的前提，目前，相关技术标准（如API 571，GB/T 30579—2022《承压设备损伤模式识别》等）已对如何开展损伤模式识别做了详细规定，基于这些标准开展工程风险评估工作已进行多年，积累了丰富的经验。如何融合标准、RBI工程风险评估案例及专家经验，开发承压设备损伤模式智能识别模型并用于工程实践，是实现承压设备智能化维护的重要内容。

1.1 损伤模式影响因素分析

依据服役过程中随时间的变化特点，可以将影响设备损伤的因素分为静态和动态两类。静态因素如设备类型、所属装置、设备名称及部位、材料牌号、盛装的工艺介质等，这些因素一般在服役过程中不发生变化。静态因素蕴含了与设备损伤模式相关的丰富信息，如设备所处的装置名称为“加氢裂化”，表明其可能涉及高温、高压、临氢、复杂腐蚀等；静态因素也可能包含设备服役过程中隐含的潜在动态信息，如设备名为“焦炭塔”，预示其可能存在热机疲劳等。动态因素是指服役过程中有可能变化的因素，如操作压力、操作温度、介质pH值、H_2S含量等。

依据GB/T 30579—2022等相关技术标准，将两类影响设备损伤模式的因素分别记为$\boldsymbol{X}_{\text{静态因素}}$和$\boldsymbol{X}_{\text{动态因素}}$。$\boldsymbol{X}_{\text{静态因素}}$一般为描述承压设备设计制造与使用条件的文本型信息，$\boldsymbol{X}_{\text{动态因素}}$一般为记录承压设备服役工况的数值型数据。两类因素一般包括以下内容：

$$\boldsymbol{X}_{\text{静态因素}}=\{\text{装置名称, 设备名称, 设备类型, 部位, 材料, 工艺介质, 损伤形态, …}\} \tag{1}$$

$$\boldsymbol{X}_{\text{动态因素}}=\{\text{操作压力, 操作温度, pH值, } H_2S\text{含量, } H_2O\text{含量, } CO_2\text{含量, 硫化物含量, } NH_3\text{含量, 氯离子含量, } O_2\text{含量, } H_2\text{含量, …}\} \tag{2}$$

1.2 损伤智能识别模型

开展损伤模式识别时一般对静态和动态因素进行协同分析。通过对静态因素开展分析，判断该因素下设备最可能的损伤模式，计算不同损伤模式的可能性；利用动态因素开展分析，构建数据模型分析设备最可能的损伤，给出不同损伤模式的可能性，两者结合用于损伤模式的识别。

将静态和动态因素分别开展分析，得到承压设备发生第i种损伤模式的可能性，并分别用$P_{i1}=P(\boldsymbol{X}_{\text{静态因素}})$和$P_{i2}=P(\boldsymbol{X}_{\text{动态因素}})$表示。为简化分析，一般认为在一定范围内，静态和动态因素是相互独立的。在两种因素数据完备的情况

下，优先使用逻辑关系“与”来判断设备损伤模式的可能性，以实现损伤模式的精准分析，如式（3）所示。

$$P_i = P_{i1} \cdot P_{i2} = P(\boldsymbol{X}_{静态因素}) \cdot P(\boldsymbol{X}_{动态因素}) \quad (3)$$

在因素不完备的情况下，为避免信息不全面可能导致损伤模式识别遗漏，建议以“或”的方式判断设备损伤模式的可能性，如式（4）所示。

$$\begin{aligned} P_i &= P_{i1} + P_{i2} - P_{i1} \cdot P_{i2} \\ &= P(\boldsymbol{X}_{静态因素}) + P(\boldsymbol{X}_{动态因素}) \\ &\quad - P(\boldsymbol{X}_{静态因素}) \cdot P(\boldsymbol{X}_{动态因素}) \end{aligned} \quad (4)$$

2 样本准备与模型训练

2.1 工程案例样本

文中训练样本主要来自约12 000个RBI工程风险评估案例，这些案例涵盖了石化行业全系列各类装置的承压设备，具有广泛的代表性。案例中包含了未知腐蚀、保温层下腐蚀、大气腐蚀、硫化物应力腐蚀开裂等30种典型的损伤模式，如表1所示。但不同损伤模式的样本数量分布并不均匀（数量相差高达140余倍），如图1所示（图中横坐标为损伤模式代号，具体内容见表1）。

表1 损伤模式代号

Tab.1 Table of codes for various damage modes

代号	损伤模式	代号	损伤模式
1	未知腐蚀	16	机械疲劳
2	保温层下腐蚀	17	胺开裂
3	大气腐蚀	18	回火脆化
4	硫化物应力腐蚀开裂	19	碱开裂
5	氢致开裂	20	氢脆
6	冷却水腐蚀	21	CO_2腐蚀
7	环烷酸腐蚀	22	内衬损伤
8	高温硫化氢/氢腐蚀	23	连多硫酸应力腐蚀开裂
9	酸性水腐蚀	24	液氨应力腐蚀开裂
10	酸性酸水腐蚀	25	再热裂纹
11	氯化物应力腐蚀开裂	26	σ相脆化
12	高温氢损伤	27	盐酸腐蚀
13	蠕变	28	硫酸腐蚀
14	珠光体球化	29	氯化铵垢下腐蚀
15	胺腐蚀	30	罐底板土壤腐蚀

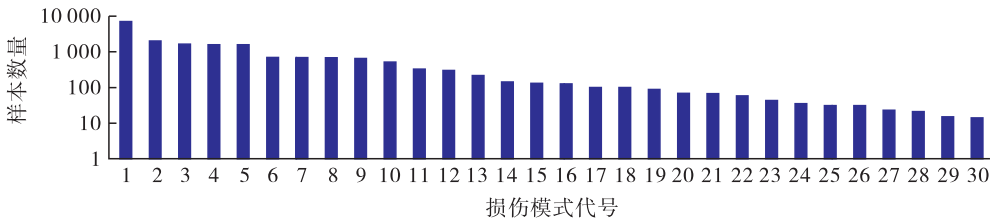


图1 工程风险评估案例中不同损伤模式的样本数量分布

Fig.1 Distribution of number of samples for various damage modes in engineering risk assessment cases

受多种损伤模式交互作用规律的影响，单个样本有可能包含多种损伤模式，拆分后全部工程案例包含了约20 000个样本，其中包括一类标记为“未知腐蚀”的损伤模式，其数量高达7 000多个。利用训练得到的损伤模式智能识别模型，对此类标记为“未知腐蚀”的损伤模式开展分析，可以检验模型的应用效果。

2.2 模型训练样本的准备

2.2.1 静态因素模型样本准备

静态因素模型处理的是包括设备装置名称、设备名称、设备类型、设备部位、材料类型、工艺介质、热处理状态、代表性介质等文本信息，一些专有符号如H_2S，H_2，H_2O等工艺介质，以及16MnR，Q245R等材料牌号也需要专门考虑，故需要构建专用因素库进行分析[17]。通过对约20 000个拆分后的样本开展分析，文中建立了一个包含10 512个静态因素库用于分析。

静态因素模型的效果与所选用的算法有关，需要考虑样本的特点、上下文关系、算力开支等，本文采用常用的词频——逆文档频率TF-IDF方法开展静态因素的分析[18]。当然，静态因素的分析还可以选用其他模型（如Bert等）[19]，文中不再赘述。

2.2.2 动态因素模型的样本准备

文中利用约20 000个工程案例中的数据构成了动态因素模型的样本，考虑到工程风险评估案例的实际情况，筛选了11个对损伤模式判定具有重要影响的动态因素组成了向量，具体组成如表2所示。表2中，温度、压力是直接影响介质相态的关键因素，而其他则是对材料腐蚀具有重要影响的参数。需要指出的是，在数据完备的情况下，一些对损伤模式具有潜在重要影响的数据，如设备材质中S，P含量、材料轧制温度、焊接热处理温度等也可以考虑在内。一个动态因素向量对应

一个损伤模式，这样就可以得到约20 000个动态因素样本。常用的分类模型，如贝叶斯、决策树、逻辑回归等都可用于上述多分类问题的求解[20-21]，文中采用决策树开展分析。

表2 动态因素模型数据

Tab.2 Data of dynamic factor model

序号	1	2	3	4	5	6	7	8	9	10	11
参数	温度	压力	pH值	H_2S含量	H_2O含量	CO_2含量	硫化物含量	NH_3含量	氯离子含量	O_2含量	H_2含量
单位/数值	℃	MPa	0~14	μg/g	μg/g	μg/g	μg/g	μg/g	μg/g	μg/g	μg/g

2.3 单样本多损伤模式情况的处理

GB/T 30579—2022规定了承压设备四大类80余种典型的损伤模式，同一使用条件下可能存在多种损伤模式，如特殊情况下一个样本对应着多达5种损伤模式。在检验检测、风险评估等工作中，单样本多损伤模式的情况普遍存在[22-23]，如环烷酸腐蚀常常伴随着高温硫化物腐蚀、氢致开裂通常伴随着硫化物应力腐蚀开裂等。采用模型分析时，由于模型的输入信息是固定的，模型输出结果也必然是确定的，即相同的输入条件下，一般只能得到唯一的可能性最高的损伤模式。如果以可能性最高为判定依据，其他损伤模式都无法被正确识别，这显然与实际情况不符。因此，常规的大数据算法中，准确率难以客观描述模型的应用效果[21]。

针对这一问题，为科学评估模型的应用效果，本文在验证时对可能性高的几种损伤模式同时进行分析，输出可能性最高的3种损伤模式及其可能性数值，并设定一个临界值，低于临界值的损伤模式被舍弃，保留的损伤模式中只要与实际损伤模式相符，即认为模型输出了正确的结果，以此统计模型的识别率。

3 模型训练与应用

依据第2节提出的方法，将约20 000个样本按1∶1分为训练集与测试集，将判定为“未知腐蚀”的7 063个样本归集到测试集中。采用逻辑回归模型进行静态因素分析，采用决策树模型进行动态因素分析，两个模型分别进行验证，并依据式(3)进行模型的综合验证。

3.1 模型测试结果及分析

3.1.1 模型测试结果

利用第2.3节提出的方法对测试集中2 459个损伤模式开展识别结果分析，综合识别率以式(3)进行统计，其测试结果如图2所示。图2中还给出了训练集与测试集中不同损伤模式的样本数量。

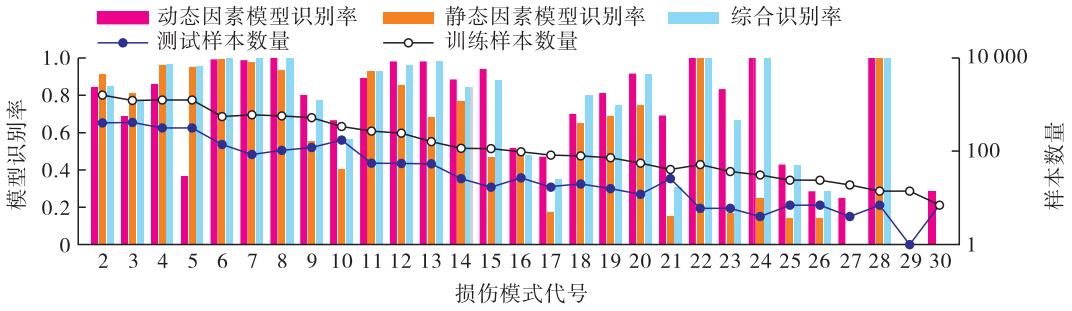


图2 基于静态/动态因素及综合的损伤模式智能识别结果

Fig.2 Intelligent recognition results of damage modes based on static/dynamic factors and comprehensive factors

从验证结果看，无论是静态还是动态因素模型，其用于损伤模式的识别都取得了较好的效果。除少数情况(如氢致开裂等)外，大多数情况下动态因素模型的识别效果较好，但两者差别较小。此外，相对而言，静态因素模型对样本数量更为敏感。

3.1.2 验证结果分析

从测试结果看，在全部29种损伤模式中，其中19种损伤模式的识别率在0.75以上，14种的识别率在0.85以上，12种的识别率在0.93以上，表明该方法具有较好的识别率。总体而言，按式(3)计算的准确率为84.9%，按式(4)计算的准确率为85.1%，两者相差不大，从侧面也说明静态因素模型和动态因素模型识别结果的一致性较好。但仍有一些损伤模式的识别率偏低，对这些识别率偏低的情况进行分析，主要有以下原因。

(1)训练样本偏少且不均匀。在9 000多个用于训练的样本中，图2中损伤模式编号为25及以

后（如再热裂纹、σ相脆化、盐酸腐蚀等）的训练样本数量均不足25个，不同损伤模式的样本数量相差高达140余倍，过少的训练样本影响了模型的识别效果。当然对于特征明显的损伤模式，如硫酸腐蚀，即使样本数量少，模型仍具有很高的识别率。总体而言，增加样本数量可以提高模型识别率。

（2）单样本多种损伤模式问题。如氢致开裂、保温层下腐蚀、硫化物应力腐蚀开裂、酸性酸水腐蚀4种损伤模式多发生在同一使用条件中。然而，采用多分类模型对相同的样本进行分析时，通常只能得到一个可能最高的损伤模式，客观上也影响了识别率。

（3）与服役历程相关的损伤模式（如机械疲劳）的识别率低。这是由于这类损伤模式与服役历程有关，单从服役工况、设备材质和工艺介质上很难反映出来，导致识别率偏低。

3.1.3 基于智能模型的“未知腐蚀”分析

据上所述，全部样本中包括了7 063个未知腐蚀样本，其中，4 316个是“未知腐蚀”为单一损伤模式的样本，其余2 747个为包含“未知腐蚀”的多损伤模式样本。“未知腐蚀”产生的原因如下：（1）在暂未发现明显的损伤模式时，从偏保守的角度人为设定了一个腐蚀减薄因素，暂定为“未知腐蚀”；（2）虽然发现其他损伤模式（如应力腐蚀开裂），但未发现减薄类损伤模式，从偏保守估计而人为设定了这种腐蚀。

识别为“未知腐蚀”的样本，或因数据不全，或使用条件与现有的损伤模式存在明显差异。为分析这些损伤模式为“未知腐蚀”的样本，利用损伤模式智能识别模型对这些样本进行了分析，识别结果如图3所示。

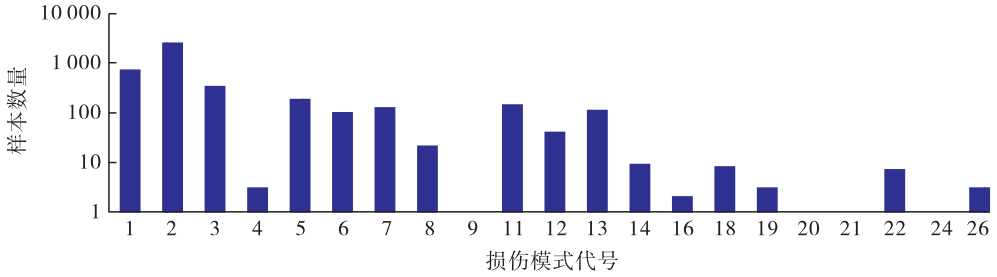


图3 “未知腐蚀”样本的智能识别结果

Fig.3 Intelligent recognition results for the “unknown corrosion” samples

图3中损伤模式代号见表1，代号为“1”的样本是通过本智能模型仍无法正确识别的样本，可以认为是真正意义上的“未知腐蚀”。基于模型开展分析表明，“未知腐蚀”为单一损伤模式的4 316个样本中，识别为保温层下腐蚀、大气腐蚀、氢致开裂、氯化物应力腐蚀开裂、环烷酸腐蚀、蠕变和冷却水腐蚀的比例较高，分别占58.1%，7.7%，4.2%，3.3%，2.9%，2.6%，2.3%。这些损伤模式的识别率较高，可以认为识别是较为可信的。特别需要指出的是，分析发现测试集中716个样本不属于任何一种已知的损伤模式，占比16.6%。建议对这部分设备开展跟踪，若发现设备在服役过程中发生损伤，则有助于发现新的损伤模式。

3.2 模型在常减压装置上的应用验证

文中训练得到的智能识别模型在某常减压装置上开展了验证。该装置开展RBI评估时，共对368台设备/部件开展了分析，识别了24类不同的损伤模式组合，每种组合包括若干种伴随的损伤模式，如高温硫/环烷酸腐蚀、未知腐蚀/保温层下腐蚀等。24类中分布较多的组合为：高温硫/环烷酸腐蚀（145个）、未知腐蚀（120个）、未知腐蚀/保温层下腐蚀（23个）、盐酸腐蚀（12个）、大气腐蚀/未知腐蚀（11个）、盐酸腐蚀/氢致开裂/应力导向氢致开裂（硫化氢环境）（10个）等。

利用文中训练的模型开展了分析，结果显示：除120个“未知腐蚀”样本外，其余248个样本分别采用静态因素模型、动态因素模型、静态/动态因素协同（关系为“与”）、静态/动态因素协同（关系为“或”）4种模型进行分析，总体识别率分别为92.3%，90.7%，92.3%，91.9%，表明模型具有较好的应用效果。在全部样本中，高温硫/环烷酸腐蚀、未知腐蚀/保温层下腐蚀、氢致开裂/应力导向氢致开裂（硫化氢环境）/酸性水腐蚀、冷却水腐蚀/大气腐蚀等14类实现了全部识别，保温层下腐蚀/酸性水腐蚀等其余2类识别率在87.5%以上。但模型对盐酸腐蚀（12个）、大气腐蚀/盐酸腐蚀（2个）均未正确识别，这可能与模型训练时盐酸腐蚀的样本数量不足有关。此外，工况数据模

型将475 ℃脆化损伤模式识别为σ相脆化或蠕变，这可能与模型基于多因素综合寻优有一定关系。总体上，利用该智能模型开展损伤模式智能识别是可行的。

4 结论与展望

（1）提出了静态/动态因素相结合的承压设备损伤模式智能识别技术，分析结果表明，在训练样本充足的情况下，两种模型都可以取得较好的识别效果。两者相结合开展分析，总体损伤模式识别率可达85%以上。

（2）受部分训练样本数量偏低、不同损伤模式样本数量分布不均匀性影响，模型对再热裂纹、σ相脆化、盐酸腐蚀的识别率偏低，这可以通过增加样本数量来加以克服。

（3）利用该损伤模式智能模型对标记为“未知腐蚀”的损伤模式开展分析，识别了最为可能的损伤模式，对设备损伤的预防与控制具有重要作用。约16.6%的设备无法识别明确的损伤模式，对这些样本开展跟踪并分析设备可能的损伤，对探寻承压设备新的损伤模式具有指导作用。

（4）提出的损伤模式智能识别模型基于大数据算法，受训练样本的容量限制及模型本身的适用性等问题，模型可作为损伤模式辅助识别，但不能取代RBI软件分析。

（5）文中研究的损伤模式智能识别技术可以将风险评估标准与专家经验软件化，用于在役承压设备损伤的智能监控。模型经进一步完善，相关数据通过第三方测评后，接入装置实时运行数据，可用于全部承压设备服役过程损伤的在线监测，为设备损伤智能化监测提供参考。

参考文献：

[1] 中国国家标准化管理委员会.承压设备损伤模式识别：GB/T 30579—2022[S].北京：中国标准出版社，2022.
China National Standardization Administration Committee. Damage modes identification for pressure equipments: GB/T 30579—2022[S]. Beijing: Standards Press of China, 2022.

[2] CHEN X D, AI Z B, YANG T C, et al. Several failure analysis cases of pressure equipment under the conditions of complex medium environment [C]// ASME 2011 Pressure Vessels and Piping Conference. Volume 1: Codes and Standards. Baltimore, Maryland, USA, 2011: 739-747.

[3] 陈学东，范志超，陈永东，等.我国压力容器设计制造与维护的绿色化与智能化[J].压力容器，2017，34(11)：12-27.
CHEN X D, FAN Z C, CHEN Y D, et al. Green and intelligent design, manufacturing and maintenance of pressure vessels in China [J]. Pressure Vessel Technology, 2017, 34(11): 12-27.

[4] 中国国家标准化管理委员会. 承压设备系统基于风险的检验实施导则 第1部分：基本要求和实施程序：GB/T 26610.1—2022[S].北京：中国标准出版社，2022.
China National Standardization Administration Committee. Guideline for implementation of risk-based inspection of pressure equipment system—Part 1: Basic requirements and implementation procedure: GB/T 26610.1—2022[S]. Beijing: Standards Press of China, 2022.

[5] 陈学东，范志超，崔军，等.我国压力容器高性能制造技术进展[J].压力容器，2021，38(10)：1-15.
CHEN X D, FAN Z C, CUI J, et al. Progress in high-performance manufacturing technology for pressure vessels in China [J]. Pressure Vessel Technology, 2021, 38(10): 1-15.

[6] CHEN X D, WANG B, AI Z B, et al. Design and manufacture of pressure-bearing equipment based on risk and life analysis [C]//ASME 2008 Pressure Vessels and Piping Conference. Volume 1: Codes and Standards. Chicago, Illinois, USA, 2008: 461-467.

[7] 陈学东，王冰，杨铁成，等.基于风险的检测(RBI)在中国石化企业的实践及若干问题讨论[J].压力容器，2004，21(8)：39-45.
CHEN X D, WANG B, YANG T C, et al. Practice of RBI in Chinese petrochemical enterprises and discussion about its several questions [J]. Pressure Vessel Technology, 2004, 21(8): 39-45.

[8] BHATIA K, KHAN F, PATEL H, et al. Dynamic risk-based inspection methodology [J]. Journal of Loss Prevention in the Process Industries, 2019, 62: 103974.

[9] LEONI L, BAHOOTOROODY A, DE CARLO F, et al. Developing a risk-based maintenance model for a natural gas regulating and metering station using bayesian network[J]. Journal of Loss Prevention in the Process Industries, 2019, 57: 17-24.

[10] ADITIYAWARMAN T, KABAN A, WAHYUADI J. A recent review of risk-based inspection development to support service excellence in the oil and gas industry: An artificial intelligence perspective [J].

ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems Part B-Mechanical Engineering, 2022:4054558.

[11] 温力,江卫星,孙丰龙,等.人工智能自然语言处理诊断肾癌T分期的研究[J].医学研究杂志,2023,52(4):112-116.
WEN L, JIANG W X, SUN F L, et al. Research on artificial intelligence natural language processing in diagnosing T-stage of renal carcinoma[J]. Journal of Medical Research,2023,52(4):112-116.

[12] 王婷,杨文忠.文本情感分析方法研究综述[J].计算机工程与应用,2021,57(12):11-24.
WANG T, YANG W Z. Review of text sentiment analysis methods [J]. Computer Engineering and Applications,2021,57(12):11-24.

[13] 王昀,胡珉,塔娜,等.大语言模型及其在政务领域的应用[J].清华大学学报(自然科学版),2024,64(4):649-658.
WANG Y ,HU M ,TA N,et al.Large language models and their application in government affairs[J].Journal of Tsinghua University (Science and Technology), 2024,64(4):649-658.

[14] 刘雪媛.基于文本语义分析的设备故障库的设计与实现[D].大连:大连交通大学,2021.
LIU X Y. Design and implementation of equipment fault database based on text semantic analysis [D]. Dalian:Dalian Jiaotong University,2021.

[15] 朱建新,陈学东,吕宝林,等.基于多维高斯贝叶斯的机械设备失效/故障智能诊断及参数影响分析[J].机械工程学报,2020,56(4):35-41.
ZHU J X, CHEN X D, LYU B L, et al. Smart failure/fault diagnosis and influence analysis for mechanical equipment with multivariate gaussian bayesian method [J].Journal of Mechanical Engineering,2020,56(4):35-41.

[16] 朱建新,周杨,乔松,等.基于大数据的电脱盐系统智能优化与影响因素分析[J].高校化学工程学报,2023,37(1):95-102.
ZHU J X, ZHOU Y, QIAO S, et al. Intelligent optimization and influence factors analysis of electro-desalting system based on big data technology [J]. Journal of Chemical Engineering of Chinese Universities,2023,37(1):95-102.

[17] 贾骏,杨强,付慧,等.基于电力设备大数据的预训练语言模型构建和文本语义分析[J].中国电机工程学报,2023,43(3):1027-1037.
JIA J, YANG Q, FU H, et al. Research on pre-training language model construction and text semantic analysis based on power equipment big data [J]. Proceedings of the CSEE, 2023, 43(3): 1027-1037.

[18] 陈永刚,贾水兰,朱键,等.基于BERT+CNN_BiLSTM的列控车载设备故障诊断(英文)[J].Journal of Measurement Science and Instrumentation,2024,15(1):120-127.
CHEN Y G, JIA S L, ZHU J, et al. Fault diagnosis for on-board equipment of train control system based on BERT+CNN_BiLSTM [J]. Journal of Measurement Science and Instrumentation,2024,15(1):120-127.

[19] 吴茂贵,王红星.深入浅出Embedding:原理解析与应用实践[M].北京:机械工业出版社,2021.
WU M G, WANG H X. Embedding inside out: Principle analysis and application practice [M]. Beijing:Machinery Industry Press,2021.

[20] BISHOP C M. Pattern recognition and machine learning [M]. Singapore: Springer Science+Business Media,LLC,2006.

[21] 周志华.机器学习[M].北京:清华大学出版社,2017.
ZHOU Z H. Machine learning[M]. Beijing: Tsinghua University Press,2017.

[22] 程伟,陈炜,陈益辉,等.常压塔塔顶冷凝系统设备腐蚀计算与风险评估[J].压力容器,2024,41(9):68-76.
CHENG W, CHEN W, CHEN Y H, et al. Corrosion calculation and risk assessment of overhead condensing system equipments of atmospheric pressure tower[J]. Pressure Vessel Technology,2024,41(9):68-76.

[23] 刘仁杰,张盛,奚力军,等.蜡油加氢装置主汽提塔腐蚀泄漏原因分析及预防[J].压力容器,2023,40(10):75-82.
LIU R J, ZHANG S, XI L J, et al. Analysis and prevention of corrosion and leakage in the main stripper of wax oil hydrogenation unit [J]. Pressure Vessel Technology,2023,40(10):75-82.

作者简介:朱建新(1976),男,研究员,国机集团首席专家,主要研究方向为设备可靠性、工程风险分析及设备智能运维,通信地址:230031安徽省合肥市长江西路888号合肥通用机械研究院有限公司技术部,E-mail:zhujianxin@hgmri.com。

本文引用格式:
朱建新,徐越遥,高振宇,等.基于静/动态因素协同的承压设备损伤智能识别技术[J].压力容器,2025,42(1):78-84.
ZHU Jianxin, XU Yueyao, GAO Zhenyu, et al. Intelligent damage recognition technology for pressure equipment based on the collaboration of static and dynamic factors[J].Pressure Vessel Technology,2025,42(1):78-84.