

建模的方法。利用生成对抗网络学习故障声的声像图特征，并利用迁移学习将学习到的知识迁移到更多故障样本特征的学习中。算法框架如图22所示。

首先初始化生成器和判别器的权重，储蓄池，学习声像故障1的声像图，经过训练，生成对抗网络获得了更新后的权重，并将更新后权重迁移到罕见故障二的声像图生成任务中，以此类推。声像对抗迁移融合学习算法无需针对样本分布学习以及可以进行多任务迁移学习的优势，适用于复杂场景下的声像小样本学习任务。

3.3 基于机器学习、流形学习、深度学习的多维信号特征提取算法^[13,14]

通过激光超声感知系统获取被检测结构在正常状态、不同损伤状态下超声响应信号，针对超声信号维度高、模态众多等问题，结合不同时域特征/频域特征/时频特征/相关分析特征，研究原始超声信号及其特征集的降维特征提取算法，深度分析损伤表征与信号特征之间的对应关系：

(1) 针对小数据样本情况，研究基于机器学习的信号特征提取算法，探索简单模型在激光超声信号处理的适应性；

(2) 针对多维特征数据的维度冗余问题，研究基于流形学习的多维信号特征提取算法，获取激光超声信号的低维流形特征；

(3) 针对多种损伤情况下的大数据样本情况，研究基于深度学习的多维信号特征提取算法，获取激光超声信号的非线性融合特征。

1) 机器学习特征提取

为了对结构损伤进行最终成像表征，需要获取超声源信号的损伤特征。本文研究基于机器学习的高维激

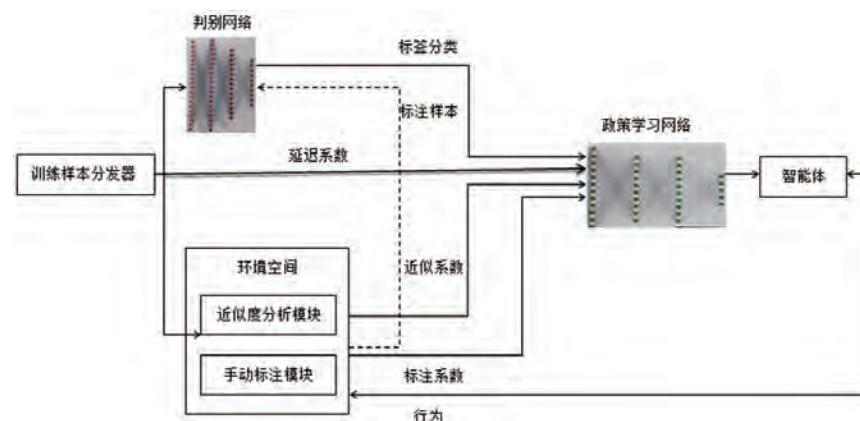


图21 声像强化学习计算框架图



图22 小样本生成对抗网络计算框架

光超声信号特征提取技术，探索算法参数对结构损伤特征提取模型适应性的影响及参数优选方法。

a. 基于主成分分析的损伤特征提取技术

本文研究基于主成分分析的损

伤特征提取技术：融合主成分特征更容易处理和后续成像分析，同时可以获取超声信号在低维尺度的相关特征，去除数据中包含的噪声。为此，研究构建如图23所示的损伤特征提取技术：

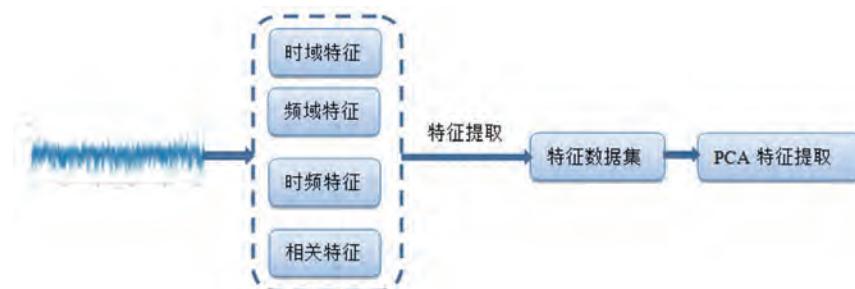


图23 基于主成分分析的损伤特征提取技术示意图

首先从超声信号中获取的多类超声特征集，通过计算超声特征集矩阵的协方差，然后得到协方差矩阵的特征值和特征向量，选择k个特征值最大的特征向量组成的矩阵，从而将数据矩阵转换到低维空间中，获得超声信号的损伤特征。

本文研究基于奇异值分解的损伤特征提取技术：奇异值分解常用于数据降维，具有大量超声特征的数据集

可以被归约成与检测问题最相关的更小特征子集。为此研究构建如图24所示的损伤特征提取技术：通过计算超声信号特征集矩阵与其转置矩阵之积的特征向量，得到超声信号特征集的左奇异向量矩阵，然后计算超声信号特征集转置矩阵与其本身之积的特征向量，得到右奇异向量矩阵，从而利用奇异值分解矩阵将数据矩阵转换到低维空间中，获得超声信号的损伤特征。

b. 基于隐马尔科夫模型的损伤特征提取技术

本文研究基于奇异值分解的损伤特征提取技术：隐马尔科夫模型可以描述动态系统的内在状态与外在表象之间的关系，适用于非平稳超声信号序列的动态建模。为此，研究通过激光超声平台获取到正常状态下检测结构的超声信号，得到检测结构无损坏状态下的超声信号特征集。利用贝叶斯公式获取HMM状态转移的似然概率，求解HMM模型参数，完成模型训练。输入待检测信号获得相似度输出作为损伤状态离群特征。

2) 流形学习特征提取

利用流形上超声信号特征集的状态参数，结合流形学习算法可以得出新检测数据的状态参数，从而实现特征数据集的降维和优选。本文研究基于流形学习的高维激光超声信号特征提取技术，研究不同流形学习方法对激光超声传感数据特征降维的适应性，提升无标签或少标签情况下的损伤特征提取可靠性。

a. 基于局部线性嵌入的损伤特征提取技术

本文研究基于局部线性嵌入的损伤特征提取技术：局部线性嵌入可以保持邻域内样本之间的线性关系，根据局部的信息对数据进行重构降维。研究通过计算多个损伤状态下超声信号特征集的最近邻k个特征点的欧氏距离，然后对每个样本求它在邻域里的K个近邻的线性关系，得到线性关系权重系数，从而利用权重系数将数据矩阵在低维空间重构，获得超声信号的低维特征。

b. 基于等度量映射的损伤特征提取技术

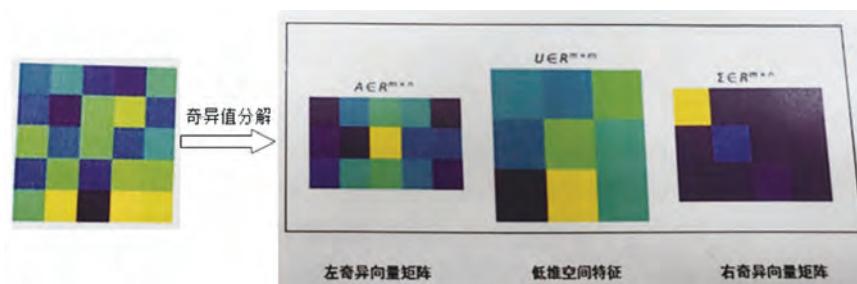


图24 基于奇异值分解的损伤特征提取技术示意图

本文研究基于等度量的损伤特征提取技术：等度量映射计算高维几何空间的测地线距离，再运用多维尺度变换方法把数据点从高维输入空间投影到低维非线性拓扑空间中，获得保持样本间测地距离不变的低维流形。研究先确定多个损伤状态下超声信号特征集中每一样本点的K个欧式距离最近点，通过这K个相连接点之间的欧式距离构造邻接矩阵，然后用最短路径计算方法计算所有样本点之间的最短距离，最后再使用经典的多维尺度变换算法对该矩阵处理，实现高维数据的降维。

c. 基于最近最远距离保持投影的损伤特征提取技术

研究最近最远距离保持投影的损伤特征提取技术：距离保持投影是流形学习算法中拉普拉斯特征映射(LE)的一种线性逼近过程，避免了LE算法无法有效处理测试样本的问题，提高了算法的泛化能力。研究首先对原特征数据集求出任意两个数据之间的欧式距离得到距离矩阵，由距离矩阵产生最小生成树，然后对最小生成树按从小到大，从左到右顺次投影，同时在低维空间精确保留每一数据点到其最近邻点和最远点的距离来达到降维的目的。

3) 深度学习特征提取

深度学习网络具有比传统前馈网

络更多的神经元，通过层与层连接的不同映射形式，能够实现自动提取特征。本文研究无监督/半监督深度学习方法的高维激光超声信号特征提取技术和损伤特征增强表示技术，研究不同深度学习方法对激光超声传感数据特征融合的适应性，探索激光超声信号的损伤离群特征提取方法。

a. 基于深度置信网络的损伤特征提取技术

本文研究基于深度置信网络的损伤特征提取技术：深度信念网络是由多层玻尔兹曼机 RBM 堆叠而成的学习网络，可以通过组合低层特征形成更高层抽象表示，并发现数据分布式特征表示的学习网络，即高层在一定程度上能表征低层数据特征，网络具有保持原始数据信息能力。研究先采集多个损伤状态下超声信号特征集作为深度信念网络的输入数据，输入数据作为可视层经低层的玻尔兹曼机学习后输出隐藏层，并作为高一层玻尔兹曼机的可视层输入，依次逐层传递。网络最后一层输出值为隐藏层概率值，为对应隐藏节点被激活的概率，数值大小可以作为损伤程度的指标。

b. 基于深度自编码网络的损伤特征提取技术

本文研究自编码网络的损伤特征提取技术：深度自编码网络由多个浅层自编码构成深度网络，可以从激光

超声信号的特征数据集中通过无监督方式进行深层次特征学习，通过数据重构误差调整网络达到更好的融合特征提取效果。研究以多种损伤状态下超声信号特征集作为自编码网络的输入，通过隐藏层非线性映射获取低维表示，同时使得重构信号与原始信号的误差最小。将多个三层自编码网络进行堆叠，不断压缩原始特征数据集的维度，来达到降维的目的。

3.4 多模态感知融合云平台及边云协同部署技术

3.4.1 多模态感知融合云平台架构设计

(1) 多模态感知融合云平台设计

如图25所示，多模态感知融合云平台有三个层次：①工业IaaS层，包括计算、存储和网络；②工业PaaS层，包括算法、多厂区共享和评价服务；③工业SaaS层，包括边端可视化、模型在线管理、模型开发和算法评估验证系统。如图25

1) 工业IaaS层

工业IaaS层是为多模态感知融合云平台提供基础设施资源的物理硬件层次。工业IaaS层基于资源，提供计算、存储和网络计算资源，用户能够部署和运行任意软件，包括操作系统和应用程序。其中计算包括虚机和容器；存储包括块存储，网络存储和对象存储；网络包括负载均衡和VPC（虚拟私有云）。工业IaaS层将计算、存储、网络通过虚拟化技术整合为统一管理的资源池，实现共享云平台资源的目的。

2) 工业PaaS层

工业PaaS层是将研究各种服务能力进行整合的云端软件层次。服务层包括算法服务，实现声成像和超声成像智能算法；多厂区共享服务，实现

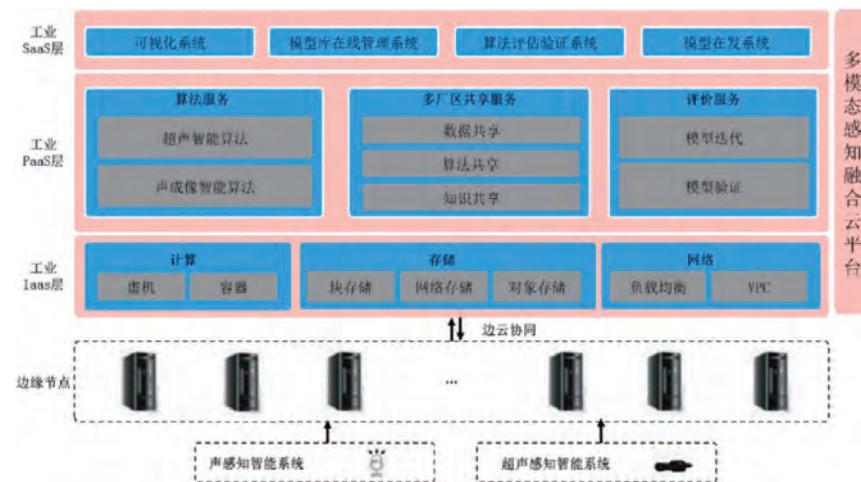


图25 多模态感知融合云平台架构

数据、算法和知识在多厂区的共享评价服务，实现云端模型迭代、验证。工业PaaS层为云平台提供基础的运行环境，降低了重复技术性研究带来的资源浪费。

3) 工业SaaS层

工业SaaS层是将资源抽象封装成服务并部署在云平台上的云端软件层次。工业SaaS层包括构建边端可视化管理系统，实现边端推理的实时监控；模型在线管理系统，实现模型的在线剪并；模型开发系统，实现应用场景的程序开发；算法评估验证系统，实现算法模型的评估。

(2) 多模态感知融合云平台主要建设内容

多模感知系统需要大量数据和计算资源进行训练，仅依靠纯云存在实时性差、带宽有限、负载不均衡等问题，仅靠边端存在算力不足、模型迭代、迁移困难等问题。所以基于AI的多模感知系统应用需要边缘计算与云计算技术相结合，通过建立“云+边”的新型系统结构，云端协同，可以提高工业数据AI运算的处理效率，提升AI运算的整体运力。边云协同系统的核心关键技术就是多区域多厂区边云协同技术。如图26

3.4.2 多区域多厂区边云协同技术框架包括以下五个关键技术：

(1) 云端训练边端推理的边云协同技术

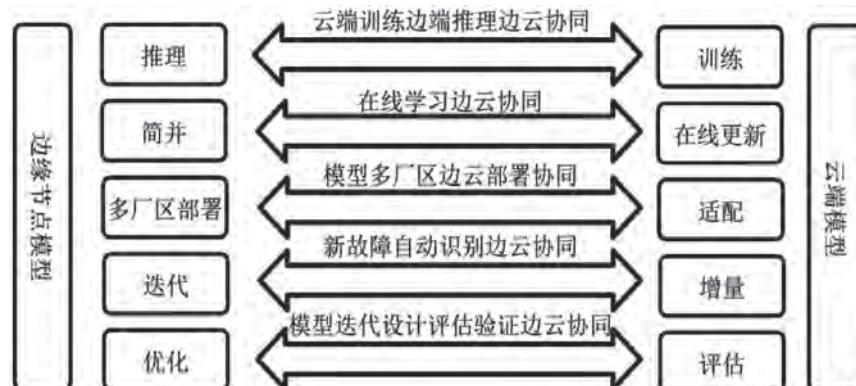


图26 多区域多厂区边云协同技术

云端训练边端推理的边云协同是边缘节点和云端之间的学习适配技术。云端通过训练产生深度学习模型并下发到边缘节点，边缘节点根据智能感知系统采集到的数据完成推理，再反馈推理结果到云端优化训练模型。该技术利用了网络带宽，保证网络传输的效率，提高了模型计算的实时性。

(2) 在线学习的边云协同技术

在线学习的边云协同是边缘节点和云端之间的数据适配技术，应用于新增样本学习。边缘节点根据智能感知系统采集到的数据上传到云端，云端的计算模型随着数据不断更新自身网络结构，并反馈到边缘节点实现模型简并。该技术适用于学习样本的在线增加，克服了故障样本短缺问题。

(3) 模型多厂区边云协同部署技术

模型多厂区边云协同部署是边缘节点和云端之间的应用适配技术。云端将训练完成的模型同时下发到相同故障辨识类型的多厂区边缘节点上。提高场景应用类型的泛化性，实现相同应用模型的同步。

(4) 新故障自动识别的边云协同技术

新故障自动识别的边云协同是边缘节点和云端之间的标签适配技术，应用于新增故障类别。边端将新故障样本上传到云端，云端通过增量学习进行新故障自动学习，并将模型下放到边缘节点，实现新故障自动标注，提高系统的泛化性。

(5) 模型迭代设计评估验证的边缘协同技术

模型迭代设计评估验证协同是边缘节点和云端之间的验证适配技术，应用于新模型的评估。该技术通

通过对云端模型有效性进行验证，并将评价结果反馈到边缘节点，实现边缘节点模型的优化。针对故障辨识和小样一题，这两类问题有不同的性能指标。针对故障辨识问题的指标有accuracy、precision、recall F1分数；针对小样本辨识的问题有误差指标和拟合度指标。

4 行业应用结果

研究基于声像及超声成像智能感知的制冷产品品质检测、装备零部件故障辨识、自动装配线故障辨识等应用技术，实现工业多模态智能诊断系统（工业多模态智能感知与边云协同系统）集成，并完成边云部署和推广应用。

4.1 声像应用技术研究

制冷产品、五轴数控刀具磨床装备零部件、自动装配线等的部分故障，主要依靠人听来检测和排查。而人听检测的准确性、效率、结果一致性和可靠性都较低。研究拟依靠声像智能感知技术解决上述问题。

空调产品(制冷产品)总装完成后,须通电开机进行整机噪音检测,以排查运行故障。目前,在此过程中,空调产品可能出现贯流风叶碰底壳、蒸发器配管、管路之间碰、轴流风叶碰导流圈、贯流风叶钢轴脱出轴承、离心风叶碰蜗壳、毛细管部件碰后侧板、吸气管碰前侧板等20多种故障并引发故障声。研究针对空调产品总装检测,进行声像感知技术应用,实现空调产品故障的智能诊断。

4.2 声像应用技术实施效果

研究系统目前已部署至生产现场，通过实际生产数据与检测结果验证是否符合需求。数据源为同样工况下，存在不同缺陷的空调的声音，如图27所示。

进一步地，为了能够直观地看到各项因素对不同指标的影响，通过因素效应表的形式对实验数据进行了分析。

因素效应表采用平均值进行分析,由于每个因素在不同水平出现的次数是相同的,因此,可以将其项指标

图27 实际参数值

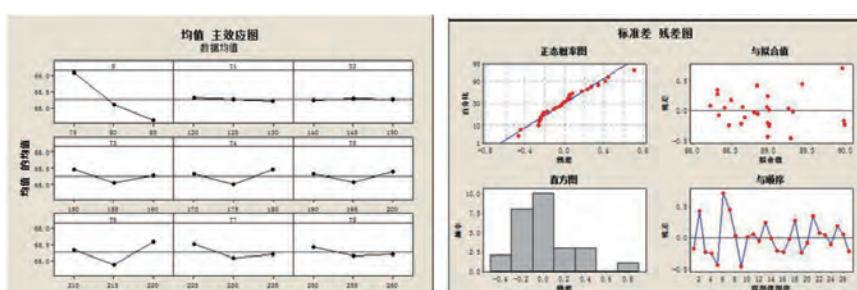


图28 数据分析图

在每项因素处于水平1时的所有数据结果取平均值,作为该因素在水平1时针对某项指标的效应值。以因素S(传送带速度)和指标GS(噪声故障率)为例,当传送带速度S处于水平1时,共进行了9999次实验,分为9组,噪声故障率GS共有9个实验结果,将这9个数值取平均值,结果表1、2所示:

$(2.51+2.59+2.57+2.52+2.55+2.54+2.56+2.54+2.53)/9=2.5455$ 。这个平均值2.5455就是因素S在水平1时针对指标GS的效应值,以同样的方法可以计算出因素S在水平2时针对指标GS的效应值为2.4677,S在水平3时针对指标GS的效应值为2.4322。在因素效应表中,每个因素在不同水平时针对某项指标的效应值的变化量及变化方向可以反应出该因素对这项指标的影响程度和影响方向。通过因素效应表的形式可以更加直观地表现出各项因素从水平1到水平3对某项指标的影响程度,研究各因素对关键指标的影响如表3、4所示,数据类型如表5所示:

表6为以上数据处理后得出的结果及准确率,由表格中的数据可知准确率达到9.985%,验证效果优秀。

使用多模态智能感知技术和边云协同技术后,产品检测准确率从97.8%提升至了99.6%。除此之外,检测系统还实现了设备故障自检提前预警功能,确保检测设备一直工作于健康状态,同时,系统能够根据新增的噪声测试数据,对模型进行优化,不断提高模型检测的准确率。

5 结论

通过研究基于声像智能感知的故障辨识与定位技术,采用深度卷积、声达时延差、波束成型等算法实现声源

表1 均值方差分析

来源	自由度	Seq SS	Adj SS	Adj MS	F	P
S	2	9.7939	9.79398	4.89694	7.53	0.014
T1	2	0.0401	0.04014	0.02007	0.03	0.970
T2	2	0.0077	0.00768	0.00384	0.01	0.994
T3	2	0.7844	0.78442	0.39221	0.60	0.570
T4	2	0.9709	0.97088	0.48544	0.75	0.504
T5	2	0.4661	0.46610	0.23305	0.36	0.709
T6	2	2.3481	2.34809	1.17405	1.81	0.225
T7	2	0.8883	0.88833	0.44416	0.68	0.532
T8	2	0.3885	0.38848	0.19424	0.30	0.750
残差误差	8	5.2021	5.20215	0.65027		
合计	26	20.8901				

表2 标准差的方差分析

来源	自由度	Seq SS	Adj SS	Adj MS	F	P
S	2	3.75035	3.75035	1.87518	7.55	0.014
T1	2	0.00681	0.00681	0.00341	0.01	0.986
T2	2	0.00498	0.00498	0.00249	0.01	0.990
T3	2	0.55655	0.55655	0.27828	1.12	0.373
T4	2	0.12544	0.12544	0.06272	0.25	0.783
T5	2	0.13009	0.13009	0.06505	0.26	0.776
T6	2	0.71535	0.71535	0.35768	1.44	0.292
T7	2	0.84318	0.84318	0.42159	1.70	0.243
T8	2	0.32996	0.32996	0.16498	0.66	0.541
残差误差	8	1.98775	1.98775	0.24847		
合计	26	8.45046				

表3 均值响应表

水平	S	T1	T2	T3	T4	T5	T6	T7	T8
1	66.07	65.31	65.24	65.46	65.32	65.31	65.34	65.51	65.43
2	65.11	65.26	65.28	65.04	65.01	65.08	64.87	65.09	65.16
3	64.62	65.22	65.27	65.29	65.47	65.39	65.58	65.19	65.21
Delta	1.45	0.09	0.04	0.42	0.46	0.31	0.71	0.43	0.28
排秩	1	8	9	5	3	6	2	4	7

表4 标准差响应表

水平	S	T1	T2	T3	T4	T5	T6	T7	T8
1	89.42	88.94	88.92	89.13	88.96	88.92	88.98	89.12	89.06
2	88.88	88.95	88.95	88.80	88.84	88.86	88.72	88.70	88.79
3	88.51	88.91	88.93	88.87	89.00	89.02	89.11	88.98	88.94
Delta	0.91	0.04	0.03	0.33	0.16	0.17	0.39	0.43	0.27
排秩	1	8	9	4	7	6	3	2	5