机械故障数值模拟驱动的生成式对抗网络及智能诊断原理

向家伟^{*}

温州大学机电工程学院, 温州 325035

*E-mail: jwxiang@wzu.edu.cn

收稿日期: 2020-05-04; 接受日期: 2020-07-27; 网络版发表日期: 2020-10-20

国家自然科学基金重点支持项目(批准号: U1909217, U1709208)资助

摘要 预测性维护是智能制造领域潜在爆发点. 人工智能诊断作为其关键一环, 成为近年来工程领域研究的热点, 发展出一系列极具应用前景的诊断方法. 众所周知, 完备故障样本是激活智能诊断模型的关键, 然而, 在工程实践中, 机械系统实际发生的故障远多于我们能预先从运行状态下获得的故障样本. 因此, 基于机械故障数值模拟驱动的生成式对抗网络, 获得完备故障样本, 架设人工智能模型与实际运行的机械系统故障诊断之间的桥梁, 提出新型智能诊断原理意义重大. 首先, 采用有限元仿真得到机械系统缺失故障样本, 与预先获得的故障样本一起, 组成相对完备故障样本. 其次, 为进一步提高故障样本质量, 利用生成式对抗网络生成大量与相对完备故障样本相似的新样本, 与相对完备故障样本一起, 构成完备故障样本(合成故障样本). 最后, 以完备故障样本作为训练样本, 以待检测未知故障样本作为测试样本, 基于人工智能模型进行故障分类. 以故障轴承公共数据集、故障齿轮实验台、故障转子实验台为例, 通过与常用的人工智能诊断模型比较研究, 验证了所提出的智能诊断原理有效性, 为推广智能诊断模型至实际运行的机械系统带来了新希望.

关键词 机械传动系统, 故障, 数值模拟, 生成式对抗网络, 人工智能诊断

1 引言

故障是装备的部件/组件劣化、丧失完成某项规定功能能力的反常状态时, 部件/组件所处的状态. 基于这一本质属性, 可以利用运行过程中设备模型、状态参数、动态响应和故障征兆进行动态监测、识别、诊断, 从而达到故障预测的目的. 由于设备的工频振动、电噪声、液压系统脉动噪声, 以及传递环节调制

与噪声干扰, 导致在线监测特征信息微弱, 特征提取方法鲁棒性差. 因此, 机械故障诊断的新解决方案一直是国内外研究的热点和难点^[1].

人工智能(artificial intelligence, AI)故障诊断与预测有望成为装备安全服役保障的一把利器: 利用人工神经网络等智能算法实现装备运行状态的判断和预测, 以便做出合理的维修决策. 智能诊断与预测摆脱了传统故障诊断过分依赖故障机理、诊断专家, 以及专

引用格式: 向家伟. 机械故障数值模拟驱动的生成式对抗网络及智能诊断原理. 中国科学: 技术科学, 2021, 51: 341–355

Xiang J W. Numerical simulation driving generative adversarial networks in association with the artificial intelligence diagnostic principle to detect mechanical faults (in Chinese). Sci Sin Tech, 2021, 51: 341–355, doi: [10.1360/SST-2020-0182](https://doi.org/10.1360/SST-2020-0182)

业技术人员的困境, 因此成为“智造中国”的核心技术^[2,3]。人工智能经过几十年的理论研究, 已涌现出众多学习算法, 而最优秀当属深度学习^[4], 随着AlphaGo的成功, 增强版深度学习^[5]迅速在语音识别、语音唤醒、人脸识别、图片文字识别、机器翻译、智能营销、增强现实、故障诊断中得到广泛的应用。文献[6]应用粒子群优化算法优化深度信念网络, 实现轴承故障诊断; 文献[7]提出基于卷积神经网络的电机状态实时监测方法; 文献[8]建立了货运列车运行状态监测的卷积神经网络模型; 文献[9]提出一种卷积神经网络与隐马尔可夫混合模型进行轴承故障多分类, 取得了良好的效果。与传统机器学习方法相比, 深度学习方法具有更多重的网络结构与更强的特征学习能力。

现有智能故障诊断与预测理论和技术存在不足在于数据获取方面: 实测数据难免受到测试误差等随机因素的影响, 具有一定的数据波动性; 实测数据规模虽大, 但某些关键部位难以直接布置物理传感器, 获取的数据不够完备。在解决数据波动性方面, 深度学习神经网络需要精心打造的成本函数, 而构建一个普适性强的成本函数异常困难^[10], 在解决故障样本缺失方面, 半监督与无监督人工智能诊断模型效果差强人意, 因此, 现有的智能故障诊断在工程应用中鲜有成功的报道。

生成式对抗网络(generative adversarial networks, GANs)^[11]可以通过生成器与判别器之间复杂的对错规则, 生成一个普适性强的成本函数, 从而完成对抗训练过程。GANs作为一个具有“无限”生成能力的模型, 其直接应用就是建模, 利用欠完备的两组样本数据, 生成与真实数据分布一致的数据样本, 因此, 入选MIT发布2018年“全球十大突破性技术”。文献[11]提出利用GANs来将一个低清模糊图像变换为具有丰富细节的高清图像; 文献[12]用深度卷积网络作为判别器, 用参数化的残差网络表示生成器, 生成了细节丰富的图像; 文献[13]提出利用GANs来生成与实际交通场景分布一致的图像, 再训练一个基于循环神经网络的转移模型, 实现预测目的; 文献[14]提出利用仿真图像和真实图像作为训练样本来实现人眼检测; 文献[15]提出一种利用无标签真实图像来丰富细化仿真图像的GANs方法, 使得合成图像更加“真实”。综上所述, 对装备智能诊断而言, GANs可极大地弥补实测数据波动性影响的缺陷。

数值模拟是研究故障机理的最佳手段^[16], 首先根据研究对象的物理特点, 建立相应数学力学模型; 然后通过仿真研究获得其响应特征; 再结合实验修正模型, 准确地获知某一故障的表征。这一反复式的研究过程是故障机理及故障样本获取的有效手段, 可从根本上解决某些关键部位难以直接布置物理传感器获得故障样本的难题。为研究机械系统关键零件故障机理, 一些研究者进行了开创性探索, 提出了一些损伤动力学模型, 例如, 文献[17]采用传递矩阵方法, 建立了含故障的曲柄活塞机构损伤动力学模型并分析大端轴承的故障机理; 考虑基础振动的旋转轴系故障的动力学有限元(finite element method, FEM)模型^[18]; 考虑预加载荷和轴承接触角的轴承转子系统非线性动力学有限元模型^[19]。然而, 仅依赖数值模拟方法, 不能保证含故障机械结构系统动力学模型与实际物理系统匹配。为消除物理系统的不确定性(运行边界条件、阻尼、零部件接触面配合状况等), 必须进行模型修正^[20], 通过修正数值模拟模型边界条件参数, 保证数值模拟与实际测量动态响应信号之间距离(欧式距离、明可夫斯基距离、海明距离等)或相似度(余弦相似度、皮尔森相关系数、对数似然相似度等)。

近年来, 作者团队已提出一些故障模拟驱动的机械系统个性化诊断具体方法, 通过建立轴承-转子系统^[21]、齿轮传动系统^[22]、轴承^[23]等机械系统有限元仿真分析模型, 仿真获得相应机械系统的大量故障特征样本, 作为人工智能模型的训练样本, 可弥补某些关键部位难以获得故障样本的难题。

综上所述, 无论是数值模拟仿真或是在线监测手段, 均难以得到“真实”的多故障模式样本数据, 而以生成式对抗网络为桥梁, 充分发挥数值模拟仿真与在线监测数据的作用, 训练出更加“真实”的故障样本数据, 构建机械故障数值模拟驱动的生成式对抗网络, 形成智能诊断原理, 具有重要的意义。

2 故障数值模拟驱动的生成式对抗网络

2.1 生成式对抗网络

GANs的思想源于“零和博弈论”, 即整体总量保持不变, 一方所得即为另一方所失。GANs由生成器(generator, G)和判别器(discriminator, D)组成, 分别代表博弈论中的一方, 如图1所示。从任意一个分布中采集随

图 1 (网络版彩图)GANs基本网络结构

Figure 1 (Color online) Basic network architecture of GANs.

机噪声 z (如高斯分布 $z \sim N(0, 1)$ 、指数分布 $z_3 \sim E(1)$ 、泊松分布 $z_4 \sim P(1)$ 、瑞利分布 $z_5 \sim R(1)$ 等, 本文采用 $z \sim u(-1, 1)$ 的均匀分布), 作为生成器的输入, 其目的是生成“逼真”的数据, 并输入到判别器, 因此判别器的输入是真实的数据 x 和由生成器生成的假数据 $G(z)$, 其目标是识别出输入数据的来源, 即估计输入数据是来自真实数据 x 还是来自于生成的数据 $G(z)$ 的概率 $D(\cdot)$. $D(\cdot)$ 的值越接近于1, 则输入数据来自真实数据的可能性越大. 这意味着, 生成的数据 $G(z)$ 被认为是“真实数据”, 因此, 判别器的目标表示如下式:

$$D_{\text{goal}} : \max_D D(G(z)). \quad (1)$$

对于生成器, 通过学习真实数据 x 的潜在统计特性, 生成能欺骗判别器的新数据 $G(z)$, 使得判别器不能将 $G(z)$ 识别为假数据. 因此, 生成器的目标是将 x 和 $G(z)$ 之间的差异最小化, 表示为

$$G_{\text{goal}} : \min_G (1 - D(G(z))). \quad (2)$$

训练开始, 允许判别器先对真实数据进行学习, 使其具备初级判别能力, 随后判别器和生成器的训练交互进行, 彼此竞争. 至关重要, 生成器无法从真实数据中直接学习, 它学习的唯一方法是通过与判别器鉴别结果的交互, 达到学习的目的, 最终生成足以以假乱真的新数据. 判别器从假数据和从真实数据中进行学习, 通过判断输入数据是来自真实数据还是来自生成器生成的假数据, 提供“这是假数据”的信息. 并将这个信息传递给生成器, 用于调整训练生成器. 通过不断对抗训练, 生成器不断优化并生成高质量假数据, 并且当假数据输入到判别器中, 判别器认为它是来自于真实数据的时候, 结束训练.

2.2 机械系统个性化诊断原理

针对实际情况下机械设备存在个体差异而导致的精准诊断需求, 采用数值模拟/仿真分析手段建立复杂机械系统高精度仿真分析模型, 从而获取大量反映实际运行条件的不同类型故障样本, 并与智能诊断方法结合, 形成了机械故障个性化诊断的原理^[21~23], 流程如图2所示. 在实际工程应用中, 机械系统部分故障样本能预先从运行状态下获得, 但是, 某些关键部位难以直接布置物理传感器, 导致故障样本缺失, 因此, 图2所示机械故障个性化诊断的原理可用于缺失的故障样本模拟, 补全缺失的故障样本.

(1) 建立及修正数值模拟模型. 利用有限元方法或集中参数模型方法构建机械系统的初始数值模拟模型. 振动信号是机械设备动力学特性的直接反映, 轴承在运行状态下的振动时域响应, 蕴含了刚度、阻尼、载荷等重要参数. 为使数值模拟模型与实际物理系统相互匹配, 消除结构在实际运行状态下具有不确定性的边界条件、阻尼、零部件配合状况等影响, 通过物

图 2 机械故障个性化诊断流程图

Figure 2 The flowchart of the personalized fault diagnosis method for mechanical systems.

理系统测试与数值模拟模型仿真得到的振动响应, 利用数据相似性度量标准进行匹配分析, 二者相似度超过预设相似度阈值(本文采用余弦相似度, 阈值为0.6^[22,23])时, 可认为修正的数值模拟模型有效, 否则更新数值模拟模型参数, 迭代求解, 直至达到预设阈值要求, 最终建立机械系统正常状态下的“高保真”数值模拟模型。

(2) 获取训练样本. 预定义机械系统可能出现的故障模式, 构建故障几何模型或数学模型并添加至正常状态下的“高保真”数值模拟模型, 获得含故障机械系统数值模拟模型, 进行振动响应计算, 得到能真实反映实际机械系统故障状态的仿真信号. 根据原始信号消噪及人工智能诊断模型对输入数据的要求, 将每个仿真得到的原始信号做基于统计分析或信号处理方法的预处理, 构建仿真故障样本, 作为人工智能模型的训练样本。

(3) 识别故障类型. 定期或在线对机械系统进行振动测试, 获得实测原始信号, 同样根据原始信号消噪及人工智能诊断模型对输入数据的要求, 将每个实测原始信号做基于统计或信号处理方法的预处理, 构建实测样本, 作为人工智能模型的测试样本. 将测试样本与训练样本一起输入至人工智能模型, 最终识别出故障类型, 从而实现机械系统故障个性化诊断。

以轴承-转子系统、齿轮、轴承为例, 以有限元仿真为工具, 阐明有限元仿真模型构建与修正途径、提出有限元模拟驱动卷积神经网络(convolutional neural networks, CNN)、极限学习机(extreme learning machine, ELM)、支持向量机(support vector machine, SVM)的轴承-转子系统、齿轮、轴承的故障个性化精准诊断系列方法^[21~23], 通过实验系统分析个性化诊断效果, 验证了机械故障个性化诊断原理的普适性和有效性, 但是诊断精度有待提高. 可利用更精细的数值模型修正方法或其他数据处理手段获得相似度更高的仿真信号。

2.3 故障数值模拟驱动的生成式对抗网络

GANs作为生成式模型, 虽可以生成大量具有共同统计特征的新数据, 但无法在没有输入数据样本的情况下生成能反映机械系统具有个性化特征的新数据. 因此, 若结合2.2节所述机械系统个性化诊断原理, GANs正好可弥补仿真信号与物理系统实测信号的误

差导致的故障样本偏差, 有望提高诊断精度。

3 新型人工智能诊断原理

按第2节所述的故障数值模拟驱动的GANs, 获得完备的故障样本数据, 搭建人工智能模型与实际运行的机械系统故障诊断之间的桥梁, 形成新型人工智能诊断原理, 图3给出了具体步骤。

(1) 构建相对完备故障样本. 首先利用数据采集设备(传感器和采集仪器)对监测对象进行故障样本采集, 得到预先获得的故障样本(实测故障样本); 其次, 利用有限元仿真计算(预定义缺失故障类型、建立含故障的机械系统有限元模型、仿真计算获得仿真故障样

图3 (网络版彩图)新型智能诊断原理流程图

Figure 3 (Color online) The flowchart of the new AI diagnosis principle.

本);最后,预先获得的故障样本与有限元仿真缺失故障样本共同构建相对完备故障样本。

(2) 生成完备故障样本. 为提高故障样本质量,利用GANs生成与相对完备故障样本相似的 N 个新样本(生成故障样本),与相对完备故障样本共同构成完备故障样本(合成故障样本)。

(3) 故障分类. 以完备故障样本作为AI模型的训练样本,以待检测未知故障样本作为测试样本,进行故障分类,形成新型人工智能诊断原理. 对某一故障样本标签而言,无论是预先获得的某种故障样本,抑或是仿真某种缺失故障样本,均经过GANs处理,生成大量与原始样本具有相同统计特征的同一标签故障样本,可弥补相对完备故障样本与待检测的未知故障样本之间的样本偏差,必然大幅提高诊断精度。

4 典型机械系统有限元模型构建

利用机械故障数值模拟驱动的生成式对抗网络及智能诊断原理,以故障轴承公共数据集、故障齿轮与故障转子系统为例,通过比较研究,评估所提出智能诊断原理的有效性。

4.1 轴承有限元模型构建

(1) 故障轴承公共数据集. 凯斯西储大学轴承数据集^[24]是故障诊断领域公开的轴承数据. 选择的轴承型号为KF6205;工作状态为:转速为 1797 r min^{-1} ,数据采集端为:驱动端,采样频率为 12 kHz ;共选择九类轴承数据,分别为: 0.1778 mm 内圈故障(IRF)、 0.1778 mm 外圈故障(ORF)、 0.1778 mm 滚动体故障(BF)、 0.3556 mm IRF、 0.3556 mm ORF、 0.3556 mm BF、 0.5334 mm IRF、 0.5334 mm ORF和 0.5334 mm BF。

(2) 故障轴承有限元模型构建. 图4所示为轴承的几何参数。

故障轴承的有限元模型如图5(a)所示^[23]. 采用SO-LID164实体单元对三维体进行网格划分,所有部件的材料设置为线性弹性材料,材料密度为 7860 kg m^{-3} ,弹性模量为 $2.06 \times 10^{11} \text{ Pa}$,泊松比为0.3. 并根据故障轴承的实际工况,限制了轴承座外表面节点的所有自由度. 图5(b)~(d)分别表示IRF, ORF, BF. 通过理论计算和模型修正技术^[23],确定①接触参数(法向惩罚刚度因子、

图4 轴承的几何尺寸

Figure 4 Geometric dimensions of the bearing.

图5 (网络版彩图)故障轴承有限元模型. (a) 轴承; (b) 内圈故障; (c) 外圈故障; (d) 滚动体故障

Figure 5 (Color online) FEM model of the fault bearing. (a) The bearing; (b) IRF; (c) ORF; (d) BF.

动摩擦系数、黏滞阻尼系数)和②载荷参数(轴重力载荷、加工误差引起的偏心载荷、轴承装配径向预紧载荷)等参数,如表1所示。

(3) 实验设计. 设计了三组故障缺失实验组,分别记为FM1, FM2和FM3,如图6所示。

图6中,空白框表示该类故障缺失. 图6(a)的同一类型故障样本缺失,图6(b)的同一严重程度的IRF, ORF和BF故障样本缺失,图6(c)的不同严重程度、不同故障类型样本缺失. 根据缺失故障的类型,基于表1参数建立含故障轴承有限元模型,可计算得到有限元仿真故障样本。

4.2 齿轮有限元模型构建与实验

(1) 故障齿轮实验台. 故障齿轮实验台如图7所示,转速 1474 r min^{-1} ,采样频率 5.12 kHz . 图8(a)~(d)分别

表 1 轴承有限元模型参数

Table 1 Parameters for the bearing FEM model

接触参数	数值	载荷参数	数值
法向惩罚刚度因子	0.12	轴重力载荷	500 N
外圈-滚动体摩擦系数	0.016	偏心载荷	0.1 MPa
内圈-滚动体摩擦系数	0.02	内圈转速	1797 r min^{-1}
黏滞阻尼系数	0.0015	径向预紧载荷	1 MPa

图 6 (网络版彩图)三组轴承故障部分缺失实验组。(a) FM1; (b) FM2; (c) FM3

Figure 6 (Color online) Three experimental groups of bearings with partial missed faults. (a) FM1; (b) FM2; (c) FM3.

图 7 (网络版彩图)故障齿轮实验台。① 速度控制器; ② 数据采集仪器; ③ 电机; ④ 变速箱; ⑤ 加速度传感器; ⑥ 圆柱滚子轴承; ⑦ 从动齿轮; ⑧ 主动齿轮

Figure 7 (Color online) Test rig for fault gears. ① Speed controller; ② data acquisition instrument; ③ motor; ④ gearbox; ⑤ acceleration sensor; ⑥ rolling element bearings; ⑦ driven gear; ⑧ driving gear.

为主动齿轮裂纹故障、主动轮齿面剥落故障、主动轮断齿故障、从动轮断齿故障。本实验针对图8(a)~(c)中的三种单点故障、主动轮齿面剥落故障和从动轮断齿故障与主动轮断齿故障和从动轮断齿故障以及无故障齿轮, 共计六种齿轮状态进行研究, 如表2所示。

图 8 (网络版彩图)四种齿轮故障。(a) 主动齿轮裂纹; (b) 主动轮齿面剥落; (c) 主动轮断齿; (d) 从动轮断齿

Figure 8 (Color online) Four gear faults. (a) Crack in the driving gear; (b) tooth surface spalling in the driving gear; (c) tooth broken in the driving gear; (d) tooth broken in the driven gear.

表 2 齿轮故障描述及故障模式

Table 2 The descriptions of fault gears and their fault modes

故障描述	故障模式
主动齿轮裂纹	1
主动轮齿面剥落	2
主动齿轮断齿	3
主动轮齿面剥落+从动轮断齿	4
主动轮断齿+从动轮断齿	5
无故障齿轮	6

(2) 故障齿轮有限元模型构建。图9所示为故障齿轮有限元模型^[22]。将齿轮和齿轮箱体简化为四个支座, 并采用接触副模拟轴承的刚度和阻尼特性。所有部件的材料设置为线弹性材料。材料密度为 7860 kg m^{-3} , 弹性模量为 $2.06 \times 10^{11} \text{ Pa}$, 泊松比为0.3, 修正后的有限元模型参数如表3所示。

(3) 设计实验。计了三组故障缺失实验组, 如图10所示, 空白方块表示该类故障缺失。图10(a)为单点故障样本缺失; 图10(b)为复合故障样本缺失; 图10(c)为单点故障和复合故障均有部分故障样本缺失, 分别记为FM4, FM5和FM6。根据缺失故障的类型, 基于表3参数建立含故障齿轮有限元模型, 可计算得到有限元仿真故障样本。

4.3 转子有限元模型构建与实验

(1) 故障转子试验台。如图11所示转子系统^[21], 转

图 9 (网络版彩图)故障齿轮有限元模型. (a) 故障齿轮传动系统; (b) 故障模式1; (c) 故障模式2; (d) 故障模式3; (e) 故障模式4; (f) 故障模式5

Figure 9 (Color online) FEM model for fault gear. (a) The fault gear transmission system; (b) fault mode 1; (c) fault mode 2; (d) fault mode 3; (e) fault mode 4; (f) fault mode 5.

表 3 齿轮有限元模型参数

Table 3 Parameters for the gear FEM model

修正参数	参数值
轮齿接触摩擦系数	0.08
齿轮啮合刚度因子	0.15
齿轮啮合阻尼比	0.03
圆柱滚子轴承支撑刚度因子	0.12
圆柱滚子轴承支撑阻尼比	0.09

速 600 r min^{-1} , 采样频率为 3000 Hz .

本实验采集了不同严重程度的三种转子故障, 通过将三个配重螺钉依次安装在圆盘的螺栓孔上得到不同程度的不平衡故障, 螺钉的质量分别为 $0.007, 0.015, 0.023\text{ kg}$, 螺栓孔的位置距离圆盘中心 0.052 mm ; 通过调整实验台上带刻度盘的螺钉来使转子产生相对于电机轴的平移(平移距离分别为 $0.174, 0.254, 0.508\text{ mm}$)得到不同程度的不对中故障; 用一根金属棒沿 x 方向与轴接触, 通过调整金属棒的伸出量(伸出量分别为 $0.15, 0.3, 0.5\text{ mm}$)得到不同程度的碰摩故障, 对应故障模式如表4所示.

(2) 构建故障转子有限元模型. 根据故障转子试验

故障模式						实验组
	2		4	5	6	(a) FM4
1	2	3			6	(b) FM5
1		3	4		6	(c) FM6

图 10 (网络版彩图)三组齿轮故障部分缺失实验组. (a) FM4; (b) FM5; (c) FM6

Figure 10 (Color online) Three experimental groups of gears with partial missed faults. (a) FM4; (b) FM5; (c) FM6.

图 11 (网络版彩图)故障转子实验台. ① 电机; ② 速度控制器; ③ 数据采集仪器; ④ 联轴器; ⑤ 转轴; ⑥ 位移传感器; ⑦ 质量圆盘; ⑧ 滑动轴承; ⑨ 带刻度盘的螺钉

Figure 11 (Color online) Test rig for fault rotors. ① Motor; ② speed controller; ③ data acquisition instrument; ④ coupling; ⑤ shaft; ⑥ displacement sensor; ⑦ mass disc; ⑧ sliding bearing; ⑨ screw with dial.

表 4 转子故障描述及故障模式

Table 4 The descriptions of fault rotors and their fault modes

故障描述	故障模式
0.007 kg不平衡故障	1
0.015 kg不平衡故障	2
0.023 kg不平衡故障	3
0.174 mm不对中故障	4
0.254 mm不对中故障	5
0.508 mm不对中故障	6
0.15 mm碰摩故障	7
0.3 mm碰摩故障	8
0.5 mm碰摩故障	9

图 12 (网络版彩图)转子的有限元模型. (a) 转子的几何尺寸; (b) 线性轴承模型

Figure 12 (Color online) FEM model of the rotor. (a) Geometric dimensions of the rotor; (b) linear bearing model.

台, 建立简化的一维单元有限元模型, 转子的几何形状与支撑轴承的线性轴承模型分别如图12(a)与(b)所示. 其中, 转轴的材料密度为 7850 kg m^{-3} , 弹性模量为 $2.06 \times 10^{11} \text{ Pa}$, 泊松比为0.3, 质量为2.219 kg, 而质量圆盘的材料密度为 2700 kg m^{-3} , 弹性模量为 $7 \times 10^{10} \text{ Pa}$, 泊松比为0.3, 质量为0.627 kg. 如图12所示, 采用BEAM188单元建立转轴, 质量圆盘被简化为质量单元(MASS21), 利用COMBINE14单元模拟两端滑动轴承的刚度和阻尼, 并对COMBINE14单元端点(轴承外圈)设置全约束. 由于实验装置几何对称, 可认为两轴承在同一方向上的支承刚度和阻尼系数相同, 根据文献[25], 阻尼系数被设定为经验值 1100 N s m^{-1} .

在故障转子实验中, 支承刚度系数 K_x , K_y , 阻尼系数 C_x , C_y , 以及综合偏心距 e 为影响转子振动的主要因素, 分别采用模态频率、瞬态响应信号, 以及稳态振动响应进行辨识, 得到^[21]: $K_x = 23.5 \times 10^7 \text{ N m}^{-1}$ 和 $K_y = 20.5 \times 10^7 \text{ N m}^{-1}$; $C_x = 1500 \text{ N s m}^{-1}$, $C_y = 1700 \text{ N s m}^{-1}$; $e = 0.164 \text{ mm}$.

(3) 实验设计. 本实验设计三组故障缺失实验组,

实验组	(a) FM7	(b) FM8	(c) FM9
已知故障	<div>2 3</div> <div>5 6</div> <div>8 9</div>	<div>1 2</div> <div>3 4</div> <div>5 6</div>	<div>2 3</div> <div>4 6</div> <div>7 8</div>
缺失故障	<div>1 4</div> <div>7</div>	<div>7 8</div> <div>9</div>	<div>1 5</div> <div>9</div>

图 13 (网络版彩图)三组转子故障部分缺失实验组. (a) FM7; (b) FM8; (c) FM9

Figure 13 (Color online) Three experimental groups of rotors with partial missed faults. (a) FM7; (b) FM8; (c) FM9.

如图13所示. 图13(a)为故障严重程度最低的故障样本缺失, 图13(b)为同一类型的故障样本缺失, 而图13(c)为不同严重程度、不同故障类型故障样本缺失, 分别记为FM7, FM8和FM9. 根据缺失故障的类型, 基于转子系统模型参数, 建立含故障转子有限元模型, 可计算得到有限元仿真故障样本.

5 新型人工智能诊断结果比较分析

由第4节可知, 对于故障轴承公开数据集、故障齿轮实验和故障转子实验均设计了三组不同故障缺失的实验组FM1~FM3, FM4~FM6, FM7~FM9. 为验证新型人工智能诊断原理的有效性和优越性, 设置四个对照组G1~G4: G1表示训练样本采用相对完备故障样本(机械系统个性化诊断原理系列方法采用的样本^[21~23]); G2表示训练样本采用GANs处理相对完备故障样本得到的生成故障样本; G3表示对相对完备故障样本进行过采样方法^[26]处理 N 次之后得到的 N 个故障样本, 与相对完备故障样本合成的故障样本; G4为本文方法得到的完备故障样本.

5.1 轴承故障人工智能诊断

(1) 轴承数据分析. 对于轴承缺失的故障样本, 利用有限元仿真获得仿真故障样本, 图14给出了缺失轴承仿真故障样本与对应的实测故障样本时域波形图($t=1 \text{ s}$). 利用GANs对仿真故障样本进行处理, 得到的生成仿真故障样本与仿真故障样本的频谱对比, 如图15所示, 可知二者在故障频率特征上十分吻合、幅值上有一定差异, 说明了GANs生成的故障样本有效.

(2) 诊断结果与分析. 对9种轴承故障的每个实测故障样本或仿真故障样本均选择12000个数据点, 按子

图 14 (网络版彩图) 仿真故障样本与对应的实测故障样本时域波形图. (a) 0.1778 mm IRF; (b) 0.178 mm BF; (c) 0.3556 mm IRF; (d) 0.5334 mm IRF; (e) 0.5334 mm ORF; (f) 0.5334 mm BF

Figure 14 (Color online) Time-domain wave forms of the simulation and measured fault samples. (a) 0.1778 mm IRF; (b) 0.178 mm BF; (c) 0.3556 mm IRF; (d) 0.5334 mm IRF; (e) 0.5334 mm ORF; (f) 0.5334 mm BF.

样本长度为300个数据点进行分割, 获得40个子样本. 对每个子样本计算23个指标(标准差、峰值、偏斜度、峭度、均方根值、峰值指标、裕度指标、波形指标、脉冲指标、小波包分解能量、集合经验模态分解能量)得到子样本指标集^[27]. AI模型的训练样本按G1~G4选取, 而测试样本(待检测的未知故障)则选择图6所示FM1, FM2, FM3的三种轴承缺失故障样本(用实测数据替代).

按以上样本处理方式, 在G1和G2中, 训练样本和测试样本(待测试故障)分别为 40×9 和 40×3 . 而对于G3和G4, 在相对完备故障样本的基础上分别都增加9个过采样样本和9个生成故障样本, 则训练样本和测试样本(待测试故障)分别为 400×9 和 40×3 (保持不变), 如表5所示. 本实验选择的是SVM和ELM, 主要参数: SVM, 选择径向基核函数, 惩罚因子和径向基函数半径分别为3和0.83; ELM, 隐藏神经元数目为70, 激活

图 15 (网络版彩图) 仿真故障样本与对应的生成仿真故障样本频谱图. (a) 0.1778 mm IRF; (b) 0.178 mm BF; (c) 0.3556 mm IRF; (d) 0.5334 mm IRF; (e) 0.5334 mm ORF; (f) 0.5334 mm BF

Figure 15 (Color online) Frequency spectrums of the simulation and generated fault samples. (a) 0.1778 mm IRF; (b) 0.178 mm BF; (c) 0.3556 mm IRF; (d) 0.5334 mm IRF; (e) 0.5334 mm ORF; (f) 0.5334 mm BF.

函数为默认的sigmoid函数. 表5中列出了AI模型诊断结果.

由表5可知, 对FM1, FM2, FM3给出的三种轴承缺失故障样本诊断而言, SVM和ELM两种模型在利用G4这一完备故障样本作为训练样本时, 分类准确率最高, 分别为93.33%和100%、96.67%和96.67%与95.83%和100%. 与G1相比, 分类准确率提高了6.66%和10.83%, 5%和5%与7.5%和10%, 这验证了所提轴承故障数值模拟驱动的生成式对抗网络及人工智能诊断原理的优越性. 与G3相比, 平均准确率提高5%, 3.33%和6.25%, 说明了本文采用GANs方法进行故障样本扩容比过采样方法能获得更高的精度. 比较G1和G2的准确率发现分类精度基本一样, 进一步说明了GANs高质量样本生成能力. 此外, FM1, FM2和FM3三种情况下, 采用G1作为训练样本, AI模型分类的准确率不低于86.67%, 说明了有限元仿真得到的仿真样本可替代实测故障样

表 5 故障轴承分类结果

Table 5 The classification results of fault bearings

实验组	对照组	相对完备故障样本	生成故障样本	SVM准确率(%)	ELM准确率(%)	平均准确率(%)
FM1	G1	40×9	0	86.67	89.17	87.92
	G2	0	40×9	86.67	92.5	89.59
	G3	40×9	360×9	90	93.33	91.67
	G4	40×9	360×9	93.33	100	96.67
FM2	G1	40×9	0	91.67	91.67	91.67
	G2	0	40×9	91.67	92.5	92.09
	G3	40×9	360×9	92.5	94.17	93.34
	G4	40×9	360×9	96.67	96.67	96.67
FM3	G1	40×9	0	88.33	90	89.17
	G2	0	40×9	90	90.83	90.42
	G3	40×9	360×9	90	93.33	91.67
	G4	40×9	360×9	95.83	100	97.92

本, 本文方法是其进一步提高分类准确度的有力工具.

5.2 齿轮故障人工智能诊断

(1) 齿轮数据分析. 对于齿轮缺失的故障样本, 通过有限元仿真获得仿真故障样本, 图16为齿轮缺失的仿真故障样本与对应的实测故障样本域波形图($t=1$ s).

为了说明GANs得到的生成故障样本的有效性, 图17进一步给出了GANs生成仿真故障样本与原始仿真故障样本的频谱, 范围[2200, 3000]Hz, 对比表明二者基本一致.

(2) 诊断结果与分析. 对6种齿轮故障的每个实测故障样本或仿真故障样本均选择12500个数据点, 按子样本长度为250个数据点进行分割, 获得50个子样本. 同样, 从与仿真故障样本相对应的实测故障样本中选取10000个数据点作为测试数据, 按子样本长度同样为250个数据点进行分割, 获得40个子样本. AI模型的训练样本按G1~G4选取, 而测试样本(待检测的未知故障)则选择图10所示FM4, FM5, FM6的两种齿轮缺失故障样本(用实测数据替代).

按以上样本处理方式, 在G1和G2中, 训练样本和测试样本(待测试故障)分别为 50×6 和 40×2 . 而对于G3和G4, 在相对完备故障样本的基础上分别都增加2个过采样样本和2个生成故障样本, 则训练样本和测试样本(待测试故障)分别为 150×6 和 40×2 (保持不变), 如表6所示. 本实验选择的是CNN、堆栈自编码器(SAE), 主要参数: CNN, 模型包括三个卷积层(32-64-128)、三

图 16 (网络版彩图)仿真故障样本与对应的实测故障样本时域波形图. (a) 故障模式1; (b) 故障模式2; (c) 故障模式3; (d) 故障模式4; (e) 故障模式5

Figure 16 (Color online) Time-domain wave forms of the simulation and measured fault samples. (a) Mode 1; (b) mode 2; (c) mode 3; (d) mode 4; (e) mode 5.

个下采样层(尺度为2), 一个全连接层(512个神经元)批大小、训练次数和卷积核大小分别为40, 100和3; SAE, 模型结构250-200-100-40-6, 即输入层尺寸为

图 17 (网络版彩图)仿真故障样本与对应的生成仿真故障样本频谱图。(a) 故障模式1; (b) 故障模式2; (c) 故障模式3; (d) 故障模式4; (e) 故障模式5

Figure 17 (Color online) Frequency spectrums of the simulation and generated fault samples. (a) Mode 1; (b) mode 2; (c) mode 3; (d) mode 4; (e) mode 5.

250×1、第1~3隐藏层的神经元分别为200、100和40, 批大小和学习率分别为40和0.5, 预训练与微调训练次

数均设为1000. 表6中列出了AI模型诊断结果.

由表6可知, 在FM4, FM5和FM6的两种缺失故障情况下, 对CNN与SAE两种方法而言, G4的平均准确率最高, 分别达到100%, 98.13%和98.34%, 比采用过采样方法处理的G3平均准确率高5.63%, 5%和6.86%, 进一步说明了本文采用GANs方法进行故障样本扩容比过采样方法能获得更高的精度. 此外, G2比G1准确率略高, 可知CNN与SAE两种分离器采用的故障样本经过GANs处理后, 分类精度不会降低.

5.3 转子系统故障人工智能诊断

(1) 转子数据分析. 转子系统缺失的仿真故障样本与对应实测故障样本时域波形图($t=1$ s)如图18所示. 图19分别为仿真故障样本与对应的生成故障样本的时域波形图($t=1$ s), 分别从图18与19可知, 波形保持高度一致, 这说明有限元仿真故障样本与GANs生成故障样本具有足够的精度.

(2) 诊断结果与分析. 对9种转子系统故障的每个实测故障样本或仿真故障样本均选择20000个数据点, 按子样本长度为500个数据点进行分割, 获得40个子样本. 同样, 从与仿真故障样本相对应的实测故障样本中选取20000个数据点作为测试数据, 按子样本长度同样为500个数据点进行分割, 同样获得40个子样本. AI模型的训练样本按G1~G4选取, 而测试样本(待检测的未知故障)则选择图13所示FM7, FM8, FM9的三种转子

表 6 故障齿轮分类结果

Table 6 The classification results of fault gears

实验组	对照组	相对完备故障样本	生成故障样本	CNN准确率(%)	SAE准确率(%)	平均准确率(%)
FM4	G1	300	0	88.75	80	84.375
	G2	0	300	95	85	90
	G3	300	600	92.5	96.25	94.37
	G4	300	600	100	100	100
FM5	G1	300	0	88.75	83.75	86.25
	G2	0	300	91.25	86.25	88.75
	G3	300	600	95	91.25	93.13
	G4	300	600	100	96.25	98.13
FM6	G1	300	0	85	82.5	83.75
	G2	0	300	93.5	88.75	91.13
	G3	300	600	95.83	87.13	91.48
	G4	300	600	99.17	97.5	98.34

图 18 (网络版彩图) 仿真故障样本与对应的实测故障样本时域波形图。(a) 故障模式1; (b) 故障模式4; (c) 故障模式5; (d) 故障模式7; (e) 故障模式8; (f) 故障模式9

Figure 18 (Color online) Time-domain wave forms of the simulation and measured fault samples. (a) Mode 1; (b) mode 4; (c) mode 5; (d) mode 7; (e) mode 8; (f) mode 9.

缺失故障样本(用实测数据替代)。

按以上样本处理方式, 在G1和G2中, 训练样本和测试样本(待测试故障)分别为 40×9 和 40×3 。而对于G3和G4, 在相对完备故障样本的基础上分别都增加4个过采样样本和4个生成故障样本, 则训练样本和测试样本(待测试故障)分别为 160×9 和 40×3 (保持不变), 如表7所示。本实验选择的是CNN、堆栈自编码器(SAE), 主要参数: CNN, 模型包括三个卷积层(8-16-32)、三个下采样层(尺度为2), 一个全连接层(512个神经元)批大小、训练次数和卷积核大小分别为40, 200和3; SAE, 模型结构500-200-100-80-9, 即输入层尺寸为 250×1 、第1~3隐藏层的神经元分别为200, 100和80, 批大小和学习率分别为40和0.5, 预训练与微调训练次数分别为200和500。表7中列出了AI模型诊断结果。由表7可知, 在FM7, FM8和FM9的三种缺失故障情况下, G4的平均准确率最高, 均达到100%, 比G3高4.17%、5.42%与2.5%。其他结论与轴承与齿轮诊断类似。

图 19 (网络版彩图) 仿真故障样本与对应生成仿真故障样本时域波形图。(a) 故障模式1; (b) 故障模式4; (c) 故障模式5; (d) 故障模式7; (e) 故障模式8; (f) 故障模式9

Figure 19 (Color online) Time-domain wave forms of the simulation and generated fault samples. (a) Mode 1; (b) mode 4; (c) mode 5; (d) mode 7; (e) mode 8; (f) mode 9.

6 结论

本文针对传统人工智能难以成功应用于机械系统故障诊断这一表象下的“卡脖子”问题——缺乏完备故障样本, 提出以数值模拟仿真为桥梁, 以生成式对抗网络为手段, 提出机械系统故障数值模拟驱动的GANs, 形成新型智能诊断原理。(1) 利用数值模拟常用手段——有限元仿真得到机械系统缺失故障样本(包含所有故障样本全部缺失这一极端情况), 与预先获得的故障样本组合一起, 构建相对完备故障样本。(2) 利用GANs生成大量与相对完备故障样本相似的新样本, 与相对完备故障样本一起, 构成完备故障样本(合成故障样本)。(3) 以完备故障样本作为人工智能模型的训练样本, 以待检测未知故障样本作为测试样本, 进行故障分类。

以故障轴承公共数据集、故障齿轮实验台、故障转子实验台为例, 任意选取SVM, ELM, CNN, SAE四

表 7 故障转子分类结果

Table 7 The classification results of fault rotors

实验组	对照组	相对完备故障样本	生成故障样本	CNN准确率(%)	SAE准确率(%)	平均准确率(%)
FM7	G1	360	0	90	87.5	88.75
	G2	0	360	98.33	92.5	95.42
	G3	360	1440	98.33	93.33	95.83
	G4	360	1440	100	100	100
FM8	G1	360	0	89.17	80.83	85
	G2	0	360	95.83	96.67	96.25
	G3	360	1440	95.83	93.33	94.58
	G4	360	1440	100	100	100
FM9	G1	360	0	95	86.68	90.84
	G2	0	360	95	90.83	92.92
	G3	360	1440	96.67	98.33	97.5
	G4	360	1440	100	100	100

种人工智能模型为分类器, 均可获得满意的分类准确度. 通过比较研究, 表明: (1) 与过采样方法扩容训练样本比较, 利用GANs进行样本扩容具有更高的精度; (2) 与作者提出的机械系统个性化诊断原理系列方法比较, GANs进行样本扩容能大幅度提高分类精度. 因此, 本文所提出的新型诊断原理有效性, 为推广智能诊断模型至实际运行的机械系统故障诊断带来了新希望. 然而, 由于实际机械装备大多非常复杂, 以下几个方面值得进一步的深入研究.

(1) 为进一步提高智能诊断模型分类精度, 可在更高精度的数值模拟模型修正、实测信号消噪、采用具有不同分布的随机噪声作为生成式对抗网络生成器的输入等方面开展深入的研究, 弥补仿真信号与实测信号的误差导致的故障样本偏差, 衍生出一系列智能诊断方法, 满足实际运行中的机械系统故障分类与寿命预测对智能诊断的迫切需求.

(2) 若实测信号与仿真信号来源于不同的工况, 显然会对诊断结果带来很大的影响, 其可能的解决办法

如下: 按实际工况进行仿真, 用时频分析方法将实测信号与仿真信号分别分解至子频段, 再采用本文智能诊断原理开展故障分类; 迁移学习或深度迁移学习^[2]亦可部分弥补实测信号和仿真信号来源于不同工况所产生的差异.

(3) 实际机械装备大多非常复杂, 包含机械系统功能部件、电气功能部件、机电耦合功能部件等. 对具体机械装备而言, 其机械系统的关键易损功能部件往往比较单一. 因此, 重点监测这些相对简单的机械结构系统, 比如: 高速离心泵变速箱、大型游乐设施的重载齿轮箱、燃气轮机轴承转子系统等, 可直接应用本文智能诊断原理. 而对于需考虑机电耦合的复杂装备, 需深入研究鲁棒性强的故障检测与隔离技术^[28], 建立基于状态方程的机电装备故障检测与隔离数学模型, 实现考虑易损机械系统、电气系统耦合影响的机电系统混合模型, 继而开展数值仿真, 实现仿真数据与实测数据互补, 为推动智能诊断模型在机电装备故障诊断领域的应用带来可能.

参考文献

- 1 Lei Y G, Jia F, Kong D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era (in Chinese). *J Mech Eng*, 2018, 54: 94–104 [雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战. 机械工程学报, 2018, 54: 94–104]
- 2 Lei Y, Yang B, Jiang X, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mech Syst Signal Pr*, 2020, 138: 106587
- 3 Zhao R, Yan R, Chen Z, et al. Deep learning and its applications to machine health monitoring. *Mech Syst Signal Pr*, 2019, 115: 213–237

- 4 Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks. *Science*, 2006, 313: 504–507
- 5 Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521: 436–444
- 6 Shao H, Jiang H, Zhang X, et al. Rolling bearing fault diagnosis using an optimization deep belief network. *Meas Sci Technol*, 2015, 26: 115002
- 7 Ince T, Kiranyaz S, Eren L, et al. Real-time motor fault detection by 1-D convolutional neural networks. *IEEE Trans Ind Electron*, 2016, 63: 7067–7075
- 8 Sun J, Xiao Z, Xie Y. Automatic multi-fault recognition in TFDS based on convolutional neural network. *Neurocomputing*, 2017, 222: 127–136
- 9 Wang S, Xiang J, Zhong Y, et al. Convolutional neural network-based hidden Markov models for rolling element bearing fault identification. *Knowl-Based Syst*, 2018, 144: 65–76
- 10 Wang K F, Gou C, Duan Y J, et al. Generative adversarial networks: The state of the art and beyond (in Chinese). *Acta Automat Sin*, 2017, 43: 321–332 [王坤峰, 苟超, 段艳杰, 等. 生成对抗网络GAN的研究与展望. *自动化学报*, 2017, 43: 321–332]
- 11 Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks. arXiv: [1406.2661](https://arxiv.org/abs/1406.2661)
- 12 Ledig C, Theis L, Huszar F, et al. Photo-realistic single image super-resolution using a generative adversarial network. arXiv: [1609.04802](https://arxiv.org/abs/1609.04802)
- 13 Santana E, Hotz G. Learning a driving simulator. arXiv: [1608.01230](https://arxiv.org/abs/1608.01230)
- 14 Gou C, Wu Y, Wang K, et al. A joint cascaded framework for simultaneous eye detection and eye state estimation. *Pattern Recogn*, 2017, 67: 23–31
- 15 Shrivastava A, Pfister T, Tuzel O, et al. Learning from simulated and unsupervised images through adversarial training. arXiv: [1612.07828](https://arxiv.org/abs/1612.07828)
- 16 Wang G B, He Z J, Chen X F, et al. Basic research on machinery fault diagnosis—What is the prescription (in Chinese). *J Mech Eng*, 2013, 49: 63–72 [王国彪, 何正嘉, 陈雪峰, 等. 机械故障诊断基础研究“何去何从”. *机械工程学报*, 2013, 49: 63–72]
- 17 Chen J, Randall R, Feng N, et al. Modelling and diagnosis of big-end bearing knock fault in internal combustion engines. *P I Mech Eng C-J Mec*, 2014, 228: 2973–2984
- 18 Fan L, Wang S, Wang X, et al. Nonlinear dynamic modeling of a helicopter planetary gear train for carrier plate crack fault diagnosis. *Chin J Aeronaut*, 2016, 29: 675–687
- 19 Wei S, Han Q K, Dong X J, et al. Dynamic response of a single-mesh gear system with periodic mesh stiffness and backlash nonlinearity under uncertainty. *Nonlinear Dyn*, 2017, 89: 49–60
- 20 Sehgal S, Kumar H. Structural dynamic model updating techniques: A state of the art review. *Arch Computat Method Eng*, 2016, 23: 515–533
- 21 Gao Y, Liu X, Huang H, et al. A hybrid of FEM simulations and generative adversarial networks to classify faults in rotor-bearing systems. *ISA Trans*, 2020, doi: [10.1016/j.isatra.2020.08.012](https://doi.org/10.1016/j.isatra.2020.08.012)
- 22 Liu X, Huang H, Xiang J. A personalized diagnosis method to detect faults in gears using numerical simulation and extreme learning machine. *Knowl-Based Syst*, 2020, 195: 105653
- 23 Liu X, Huang H, Xiang J. A personalized diagnosis method to detect faults in a bearing based on acceleration sensors and an FEM simulation driving support vector machine. *Sensors*, 2020, 20: 420
- 24 Case Western Reserve University Data. 2017, <https://github.com/yyxyz/CaseWesternReserveUniversityData>
- 25 Xiang J, Zhong Y. A novel personalized diagnosis methodology using numerical simulation and an intelligent method to detect faults in a shaft. *Appl Sci*, 2016, 6: 414
- 26 Barua S, Islam M M, Yao X, et al. MWMOTE—Majority weighted minority oversampling technique for imbalanced data set learning. *IEEE Trans Knowl Data Eng*, 2014, 26: 405–425
- 27 Wang S, Xiang J, Zhong Y, et al. A data indicator-based deep belief networks to detect multiple faults in axial piston pumps. *Mech Syst Signal Pr*, 2018, 112: 154–170
- 28 Meskin N, Khorasani K. Fault Detection and Isolation: Multi-Vehicle Unmanned System. New York: Springer, 2011

Numerical simulation driving generative adversarial networks in association with the artificial intelligence diagnostic principle to detect mechanical faults

XIANG JiaWei

College of Mechanical and Electrical Engineering, Wenzhou University, Wenzhou 325035, China

Predictive maintenance (PM) is a potential outburst point in intelligent manufacturing. As the key issue of PM in recent years, artificial intelligence (AI) diagnosis has become a research focus in engineering research and developed a series of diagnostic methods with great application prospect. Complete faulty samples are essential to activate AI models. However, in engineering applications, faults are considerably more than the fault samples obtained in advance from real-world running mechanical systems. Therefore, a numerical simulation driving generative adversarial networks (GANs) is proposed to obtain relatively complete fault samples for building a bridge between AI models and real-world running mechanical systems and to present the new-type principle for AI diagnosis. First, the finite element method is employed to simulate missing fault samples of mechanical systems, which are combined with the fault samples obtained in advance to construct relatively complete fault samples. Then, a large number of new samples similar to the relatively complete fault samples are generated using GANs to improve the quality of fault samples. The new samples are further combined with the relatively complete fault samples to obtain complete fault samples (synthetic fault samples). The complete fault samples are employed as training samples of AI models, and the test samples of unknown faults are finally classified. The fault diagnostic performances are compared with the commonly used AI diagnostic models by using the public datasets of faulty bearings, the faulty gear test rig, and the faulty rotor test rig as examples. The effectiveness of the proposed AI diagnostic principle is verified and it brings the new hope to extend AI diagnostic models to detect faults in real-world running mechanical systems.

mechanical transmission systems, faults, numerical simulations, generative adversarial networks, artificial intelligent diagnosis

doi: [10.1360/SST-2020-0182](https://doi.org/10.1360/SST-2020-0182)