

文章编号:1671-1637(2025)05-0001-22

基于种群的桥梁结构健康监测研究综述与挑战

余忠儒,单德山*,孙榕徽

(西南交通大学 土木工程学院,四川 成都 610031)

摘要:为克服桥梁结构健康监测(BSHM)领域面临的数据缺乏、标签缺失、运营环境差异化大以及监测计算成本高等现实挑战,对基于种群的结构健康监测(PBSHM)框架进行了系统性综述与总结。通过分析近年来的相关文献,对PBSHM的基础概念进行了简述,从几何、材料与拓扑3个方面阐述了不同结构种群类型的定义,包括同质种群和异质种群,并总结了PBSHM拟解决的关键问题;从结构相似性度量、不同种群类型下的知识迁移方法及其运用方面,对PBSHM领域的研究现状进行了回顾与分析,总结了该框架下的应用场景与解决思路,分析了不同技术方法的功能与联系;针对BSHM领域面临的工程实际问题,讨论了桥梁PBSHM存在的挑战与潜在解决思路。研究表明:结构种群是PBSHM框架的基础,利用桥梁结构力学行为相似性和数据分布相似性能有效判断桥梁种群成员之间的知识可迁移性;显式迁移方法在桥梁结构群的异常监测和特征分布对齐方面表现出良好的应用效果,而基于深度神经网络模型的隐式迁移方法具有更强的适应性,可自动提取更具表征力的特征,满足BSHM实际应用中的端到端需求;基于知识迁移技术,PBSHM框架在处理桥梁结构健康监测任务中的复杂运营条件差异与数据不平衡的影响、损伤识别、数据预测与生成、特征对齐与归一化等方面具有巨大潜力。

关键词:桥梁工程;结构健康监测;综述;知识迁移;结构种群

中图分类号:U448.2 **文献标志码:**A **DOI:**10.19818/j.cnki.1671-1637.2025.05.001

Population-based structural health monitoring of bridges: Review and challenges

YU Zhong-ru, SHAN De-shan*, SUN Rong-hui

(School of Civil Engineering, Southwest Jiaotong University, Chengdu 610031, Sichuan, China)

Abstract: To solve the practical challenges faced in bridge structural health monitoring (BSHM), such as data scarcity, label deficiency, large operational environment variations, and high monitoring computational costs, the framework of population-based structural health monitoring (PBSHM) was systematically reviewed and summarized. A brief overview of the fundamental concepts of PBSHM was provided by thoroughly analyzing relevant studies reported in recent years. The definitions of different structural population types, including homogeneous populations and heterogeneous populations, were elaborated on from three perspectives: geometry, material, and topology. Key issues that PBSHM aims to solve were also summarized. Research status in the field of PBSHM was reviewed and analyzed in detail from two aspects:

出版历程:2024-05-09 收稿,2025-06-24 修回,2025-08-07 录用

基金项目:国家自然科学基金项目(51978577)

* **通信作者:**单德山(1968-),男,四川大竹人,西南交通大学教授,工学博士,从事桥梁健康监测、大跨桥梁施工控制研究。

引用格式:余忠儒,单德山,孙榕徽.基于种群的桥梁结构健康监测研究综述与挑战[J].交通运输工程学报,2025,25(5):1-22.

Citation: YU Zhong-ru, SHAN De-shan, SUN Rong-hui. Population-based structural health monitoring of bridges: review and challenges [J]. Journal of Traffic and Transportation Engineering, 2025, 25(5): 1-22.

structural similarity measurement, and knowledge transfer methods and applications under different population types. Specific application scenarios and solution approaches under this framework were summarized, and the functions and connections of different technical methods were analyzed. In light of the practical engineering problems faced in the field of BSHM, the challenges and potential solutions for PBSHM of bridges were discussed. Review results indicate that structural populations form the basis of the PBSHM framework. Utilizing indicators of structural mechanical behavior similarity and data distribution similarity can effectively determine the knowledge transferability among bridge population members. Explicit transfer methods show good performance in anomaly monitoring and feature alignment for bridge structural populations, while implicit transfer methods based on deep neural network models exhibit stronger adaptability, which can automatically extract more representative features, meeting the end-to-end requirements in practical BSHM applications. Based on leveraging knowledge transfer technology, the PBSHM framework shows great potential in addressing issues such as differences in complex operational conditions, data imbalance impacts, damage identification, data prediction and generation, feature alignment, and normalization in bridge structural health monitoring tasks.

Keywords: bridge engineering; structural health monitoring; review; knowledge transfer; structural population

Publication history: Received 2024-05-09; Received in revised form 2025-06-24; Accepted 2025-08-07

Funding: National Natural Science Foundation of China (51978577)

* **Corresponding author:** SHAN De-shan (1968-), male, professor, PhD, dsshshan@163.com.

0 引 言

结构健康监测 (Structural Health Monitoring, SHM) 技术在过去 40 年间得到了长足的发展^[1-3], 并广泛运用于大跨桥梁的模式识别、状态评估和损伤检测任务中, 且随着计算机技术的发展, 桥梁 SHM 技术趋向于数据驱动和智能化的发展方向^[4-5]。以往的桥梁结构健康监测 (Bridge Structural Health Monitoring, BSHM) 模型通常基于单个结构或系统的大量数据构建, 其假定训练数据和测试数据遵循相同的分布, 并期望该模型能够用于此结构或系统未来的监测数据中^[6]。受限于监测成本, 绝大多数桥梁长期健康监测数据和结构状态标签严重缺乏, 这限制了桥梁状态判别模型的高精度训练与实际部署^[7]; 此外, 由荷载、运营条件乃至结构差异导致的训练数据和测试数据分布差异将直接影响桥梁状态判别模型在目标任务中的精度与效率^[8]。

迁移学习 (Transfer Learning, TL)^[9] 利用数据、任务或模型之间的相似性, 将在已知领域 (源域) 学习到的知识迁移运用至目标领域 (目标域) 任务。基于特征匹配、领域分布适应、特征对齐、领域泛化

等手段^[10], 迁移学习可处理源域与目标域数据分布不一致的情况, 提高模型解决新问题的能力与速度^[11]。近年来, 迁移学习已成功运用于跨域图像分类^[12]、故障诊断^[13]等领域。Gardner 等^[14]研究了迁移成分分析 (Transfer Component Analysis, TCA)、联合分布适应 (Joint Distribution Adaptation, JDA) 和基于适应正则化的迁移学习 (Adaptation Regularisation-based Transfer Learning, ARTL) 的有效性, 结果显示域适应技术显著提升了跨领域分类任务的精度。Han 等^[15]将 JDA 方法与神经网络进行融合, 全面提升了神经网络在跨域故障诊断中的精度。

2016 年, Vamvoudakis-Stefanou 等^[16-18]利用回归预测模型对一组名义上相同的结构群体进行了损伤检测, 但这一理念并未得到发展。近年来, 在迁移学习理论的支撑下, Bull 等^[19-21]提出了基于种群的结构健康监测 (Population-based SHM, PBSHM) 框架, 以应对传统 SHM 所面临的问题与挑战, 并提供了新的解决思路。PBSHM 提供了一个通用的框架, 在此框架下通过将种群中结构 A 的状态关联信息迁移至数据缺失 (如数据丢失、状态标签缺失等) 的相似结构 B, 实现对结构 B 的健康状态诊断。

Worden 等^[22]对 PBSHM 框架进行了总结,指出迁移学习及其相关方法是解决 PBSHM 问题的有力工具。

由于桥梁结构健康状态数据缺乏、标签缺失、运营条件差异和计算成本的限制,桥梁结构健康监测依旧面临诸多挑战^[6-7]。尽管 PBSHM 框架及其方法已在广义的 SHM 领域初步应用^[23],但是在 BSHM 领域的研究相对较少。为促进 PBSHM 相关理论与方法在 BSHM 领域的应用,本文综述了近5年来涉及 PBSHM 框架与方法的主要论文,跟进最新的研究进展,阐明 PBSHM 的技术背景,根据桥梁结构面临的问题场景总结了相应的解决思路与技术路线,期望相关研究能为解决 BSHM 问题提供启发。

1 文献来源与统计分析

为总结 PBSHM 的技术发展脉络,对其核心文





图 1 文献数量分布

Fig. 1 Distributions of publication number

图 1(a)表明绝大部分文献集中在 2019~2024 年,占比达到了 93.5%,并且相关研究工作在近年来逐年增加。从文献来源看,收集的文献主要来源于 *Mechanical Systems and Signal Processing*, *Structural Health Monitoring* 和 *Journal of Sound and Vibration* 等高水平期刊。由图 1(b)可知,PBSHM 在机械结构领域的应用数量最多,占比达到了 32.35%,在桥梁结构领域的研究次之,占比为 28.43%。分析表明,尽管 PBSHM 框架源于机械结构领域^[22],但该框架已逐步向桥梁结构领域延伸。既有研究的专业领域分布也证实了 PBSHM 框架在桥梁工程领域具有较强的适应性。

按照文献作者关联性与关键词关联性进行聚类

文献进行追踪与梳理。由于 PBSHM 的理念新颖,现有数据库如 WoS (Web of Science)、EI (The Engineering Index)等并未形成有效的知识发展脉络。在文献收集阶段,考虑时间范围在 2016 年之后,并着重关注 2019~2024 年内发表的研究性论文。以文献 [19]~[21]为核心,并在 Google Scholar 上以“Population-based structural health monitoring”“SHM”“Damage detection”和“Transfer learning”等为关键词进行检索,通过引用分析和主题相似性分析进行文献的收集与筛选。

在文献总结与梳理前,根据主题信息共收集相关文章 180 篇,文献类型包括期刊文章、会议论文和预印本论文。进一步根据本文的知识架构进行筛选,保留相关性强的文献 136 篇作为本文核心论文,包括研究性论文 98 篇、综述性论文 30 篇、以及公开的桥梁健康监测数据集论文。文献年度分布和专业领域的分布情况如图 1 所示。

分析,形成作者信息与关键词聚类网络图谱,如图 2 所示。从图 2 中可以发现,文献的梳理主要围绕 Worden、Bull、Gardner、Gosliga 以及 Luleci 等的研究工作进行。在统计的文献中,以 Worden 等为核心的研究 66 篇,是 PBSHM 研究工作的主要贡献者。在关键词关联性分析中,“Population-based structural health monitoring”“Transfer learning”“SHM”“Damage detection”和“Domain adaptation”为关联次数最多的关键词,涉及相关文献 116 篇。

2 结构种群

Bull 等^[19]与 Gardner 等^[21]初步定义了种群的类型,同质种群由名义上相同的结构组成,异质种群

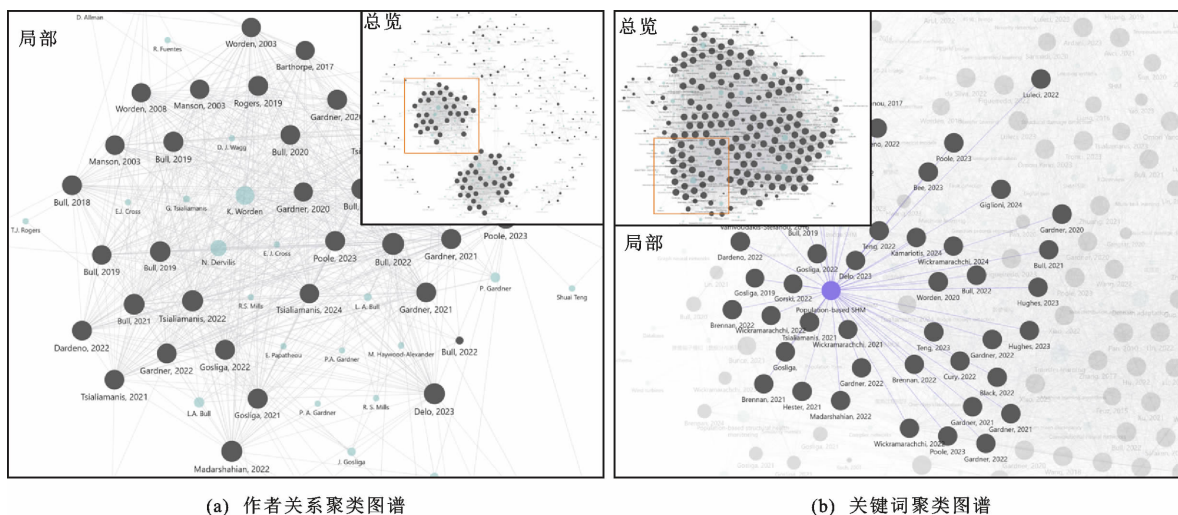


图2 作者关系与关键词聚类图谱

Fig. 2 Clustering network maps of author relationships and keywords

由名义上不同的结构组成。Bull 等^[19]进一步区别了强同质种群与一般同质种群,并提出了 Form 的概念对种群进行建模表示。与传统 SHM 关注单个结构或数据域不同, PBSHM 研究的对象是结构种群,即由相同或不同个体所组成的结构群体。结构种群至少包含 2 个以上的个体,并期望知识能从已知个体向目标未知个体传播与迁移利用^[19-21]。PBSHM 的核心是知识迁移,为明确那些知识可以迁移,以及以何种方式迁移,本节从结构几何、材料与拓扑 3 个方面界定种群的类型。

2.1 几何、材料与拓扑

结构个体间的差异表现在几何形状、材料与拓扑结构等方面,依据结构个体间的差异可以区别为同质种群和异质种群^[19, 21-22]。具体表现如下^[21]。

(1) 几何形状: 与结构个体的形状、大小和比例有关,例如一组不同长度、宽度和厚度的矩形铝板;

(2) 材料: 与结构的不同材料类别、特定材料及其特性有关,例如,相同尺寸的铝制和钢制矩形板;

(3) 拓扑结构: 以节点和线对复杂结构体进行抽象和拓扑表示,例如,具有相同材料与几何形状的梁结构,其中一根是悬臂梁,另一根是固支梁,其拓扑结构差异体现在不同的边界条件。

实际结构个体间的几何形状、材料与拓扑结构即存在显著区分,也存在相互交叉,用韦恩图表示如图 3 所示。

利用节点与线对复杂结构进行简化是结构拓扑抽象表达的一种方式^[20],可用于展示结构之间的差异。图 4 中展示了 4 个结构拓扑图^[19]。其中,图 4(a)与(b)具有相似的结构布局和相同的边界,二者




图3 结构种群个体差异来源

在结构拓扑上是等价的;图 4(c)的结构布局与图 4(b)一致,但是其边界节点存在差异,二者在结构拓扑上不等价;而图 4(d)与前 3 种拓扑结构存在显著差异,和前 3 种结构不具有相似性。

2.2 同质种群

随着种群中结构个体间几何形状、材料与拓扑结构差异不断减小,结构种群可视为同质种群。Bull 等^[19]给出了同质种群的形式化定义。

对于一个包含 M 个结构的种群 $\{S_1, S_2, \dots, S_M\}$,若结构个体的拓扑结构是成对等价的,同时材料、几何形状等物理参数 θ_k 服从相同分布 $p(\theta_k)$,则定义种群 $\{S_1, S_2, \dots, S_M\}$ 为同质种群。其中 k 表示个体编号, k 为 $1 \sim M$ 。

简单而言,同质种群即为名义相同结构的集合^[19]。为阐明其物理意义,以相同截面的多座简支梁桥为例进行说明。当这些简支梁桥的结构设计标准、材料与结构边界相同,但由于材料变异、施工误差等影响,其具体结构尺寸、材料特性和边界连接存

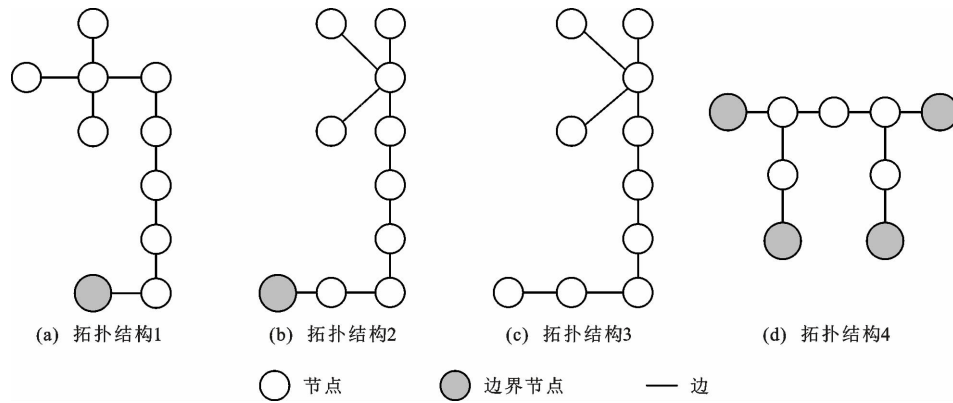


图 4 拓扑结构

Fig. 4 Topology structures

在差异时,这些简支梁桥构成的同质种群属于一般同质种群^[19]。

强同质种群定义了一种理想化的种群形式,其物理参数 θ_k 服从低离散的正态分布^[19]。这意味着种群中每个结构个体实际上是相同的,仅因结构制造误差和运营条件等的轻微扰动而表现出行为差异^[19]。在实际工程中,由于边界条件的复杂性,即使物理参数 θ_k 相同的结构个体组成的种群,也更趋向于一般同质种群,而非强同质种群^[19,21]。

2.3 异质种群

当结构种群的个体在几何形状、材料或拓扑结构中任一方面存在显著差异时,该种群被视为异质种群^[21]。值得注意的是,异质种群没有严格意义的数学形式定义,它是区别于同质种群的、更为一般的种群形式。

此外,除几何形状、材料与拓扑结构的异质外,数据层面的异质也不可忽视^[24]。例如,桥梁结构传感器布置位置的差异、采样频率的差异以及数据类型的差异等,都会导致测试数据的分布差异,进而影响 PBSHM 的具体解决思路。

一般而言,任意结构或数据域集合都能构成种群。PBSHM 重点在于如何衡量个体之间的差异,以及如何减小不同结构个体或数据域的分布差异,使得从结构 A 学习到的知识/模型,能迁移至结构 B 的健康监测任务中。

2.4 PBSHM 拟解决的问题

同质种群与异质种群的概念表明,种群中结构个体之间存在差异^[19,21]。由于已知结构个体的数量有限,故仅能迁移部分个体有价值的信息,并期望用于整个种群^[10-11,22]。实现 PBSHM 的关键在于:如何在消除个体差异的同时,有效迁移与利用已知有限个体的知识,并将其传播迁移至其它结构个体,

以降低数据收集和模型训练的计算成本^[22]。

既有相关研究工作奠定了 PBSHM 的基础^[19-22],PBSHM 框架可为困扰 SHM 的以下问题提供解决方案^[25-27]。

方案 1:将某一种特定结构的知识扩展运用到另一类似结构。如既有斜拉桥的 SHM 研究成果应用于新的斜拉桥时,如何将已有的数据、标签信息、模型等进行快速推广运用。

方案 2:在种群个体之间交换数据、信息和更新模型,以减少种群个体建模的不确定性。如利用大量已知桥梁种群个体的数据,构建描述桥梁种群整体行为的通用鲁棒模型。

方案 3:描述结构变异、运营条件差异对种群个体行为的影响,以实现某种特定意义的归一化。如桥梁种群个体间的变异性和结构运营环境的差异,都会导致个体行为的差异,利用 PBSHM 方法可消除或缓解此类差异,进而减轻计算成本。

3 结构相似性度量

确保知识在种群不同个体之间的有效迁移与利用是实现 PBSHM 的重要步骤^[20,22]。迁移学习理论表明^[10,28],源域与目标域任务越相近,知识迁移成功的概率越大;从数据分布的角度来说,源域数据分布与目标域数据分布的差异越小,知识越容易迁移^[28]。源域与目标域结构在几何、材料与拓扑上的相似,是保证其数据分布相似的重要前提^[20,24]。Wickramarachchi 等^[29]利用几何思想阐述了 PBSHM 中度量结构和数据相似程度的必要性。为避免 PBSHM 中的负迁移问题^[30],Hughes 等^[31]提出了一种新的决策框架来选择合适的知识迁移方法。因此,衡量 2 个结构或者种群个体间的相似性,剔除结构差异过大的个体,并构建合理的结构种群,

对确保 PBSHM 的有效部署至关重要^[20,24,29]。

在结构相似性度量的研究中^[20,32-34],一个主流的技术路线是先对结构的重要部件与属性进行简化与抽象表达,再对简化抽象后的结构进行度量。基于不可约元素(Irreducible Element, IE)模型,如梁、板、壳等,Gosliga 等^[20]用边、线将 IE 模型关联,并将材料属性和几何尺寸等参数附加至节点中,形成包含结构材料和几何信息的属性图(Attributed Graph, AG)。AG 本质上是结构抽象表达的一种拓扑结构图,当种群中 2 个个体间的 AG 一致时,即可确认它们所组成的种群为同质种群^[20]。

通过对 AG 度量的研究,研究人员构建了多种度量策略与指标来衡量结构个体间的相似程度。Gosliga 等^[20]将 AG 的某个局部定义为子图,并提出了最大公共子图(Maximum Common Subgraph, MCS)的概念,并采用改进的 Bron-Kerbosch 算法搜寻 2 个 AG 间的 MCS,并利用 MCS 的大小与 Jaccard 相似性系数对结构个体间的相似程度进行定量描述,研究表明,2 个结构个体的 AG 越相似,这 2 个结构具有越多相同的子图,其 MCS 也将更大。Delo 等^[35]将此方法应用于复杂桥梁和飞机结构的相似性度量,解释了桥梁和飞机的不同之处。Gardner 等^[24,36]基于 AG 度量的方式比较了 2 个机翼结构的相似性,并选取了它们的最大公共部分进行知识迁移。Gosliga 等^[37]基于 IE 模型开发了超图(Hypergraphs)模型,该模型相比 AG 模型具有更加灵活的 IE 模型关联方式。其研究采用图匹配算法与 Jaccard 相似性系数对超图模型进行度量,成功衡量了 5 座不同类型桥梁结构间的相似性,但是对桥梁结构的抽象表达表现出异常的复杂性。

桥梁结构个体间的力学行为(包括静、动力行为)越接近,表明个体结构间的相似程度越大,知识迁移的成功率也越高,即结构个体间的力学行为亦能度量结构的相似性^[38-40]。Giglioni 等^[40]在探讨 Z24 和 S101 两座桥梁的知识可迁移性时,创新地采用交叉模态保证准则(Cross Modal Assurance Criterion, CMAC)衡量了这两座桥梁不同模态的振型相似性,并以 CMAC 保证率较大的前两阶固有模态频率作为特征,成功实现了知识迁移。Poole 等^[38-39]同样利用模态保证准则(Modal Assurance Criterion, MAC)衡量了 Z24 桥和 S101 桥之间的相似性,进而判断知识迁移的可能性。

除 AG 模型和结构力学行为相关的结构相似性度量外,Wickramarachchi 等^[41-42]为实现有效的迁

移学习,基于种群个体的数据分布和距离函数,度量了结构个体间的相似性,实现了快速、自动分析大量种群数据,并确定合适的源域和目标域数据。此外,Brennan 等^[43-45]基于图神经网络(Graph Neural Networks, GNN)探讨了 PBSHM 结构相似性度量问题。

利用结构的拓扑表示来衡量种群成员之间的相似性是一个值得肯定的技术思路^[20,32-34],但是由于实际桥梁体量巨大且边界连接复杂,结构简化与抽象难以实现,实际应用过程中将不可避免地面临计算量大、效率低下等困难。此外,受 AG 模型及相关算法的影响,既有研究结果出现了飞机与桥梁结构间的相似程度^[20]大于桥梁与桥梁结构间的相似程度^[37]的情况,这显然有悖于客观现实。在 Gosliga 等^[37]的研究中,还出现了拱桥与斜拉桥之间的相似程度相对最大这种令人费解的结果。目前,既有研究并未对相似性度量指标作出符合工程依据的证明^[20,37],也未对知识能否成功迁移作出判断。相较而言,从桥梁结构行为、数据分布等角度讨论种群个体间的相似性程度^[40,42],进而确定合适的特征和迁移方法更具实际工程意义。事实上,在构建桥梁结构种群时,应有意识避免个体差异过大的桥梁种群,从而尽可能确保知识能相互迁移与利用。

4 知识迁移与不同种群类型的运用

Gardner 等^[21]认为 PBSHM 的技术难点在于知识迁移与匹配。在 PBSHM 中,将种群个体划分为源域结构和目标域结构,源域结构的数据与标签信息完整,而目标域结构的数据与标签信息不完整^[19,21]。用领域 D 表示源域和目标域结构的数据及其概率分布^[10-11],领域 D 的样本数据包括:输入数据 x (特征)、输出数据 y (标签)及联合概率分布为 $p(x, y)$,即样本数据服从分布 $(x, y) \sim p(x, y)$ 。 X 和 Y 分别表示输入与输出对应的特征空间与标签空间^[21],对任意的样本 (x_i, y_i) ,有 $x_i \in X_i, y_i \in Y_i$ 。

源域中包含的所有数据样本可表示为 $D_s = \{(x_i, y_i), p_s(x_i, y_i)\}$;目标域数据样本可表示为 $D_t = \{(x_j, y_j), p_t(x_j, y_j)\}$ 。其中 $x \in X, y \in Y$,下标 s 和 t 表示数据来源分别为源域和目标域; $i \in [1, N_s], j \in [1, N_t]$ 表示样本编号, N_s 和 N_t 分别为源域和目标域的样本大小。PBSHM 主要讨论源域和目标域之间知识迁移的以下 3 种情况^[10-11]。

(1)特征空间不一致,即 $X_s \neq X_t$;

(2) 标签空间不一致, 即 $Y_s \neq Y_t$;

(3) 特征空间与标签空间一致, 但概率分布不同, 即 $p_s(x_i, y_i) \neq p_t(x_j, y_j)$ 。

在上述 3 种情况至少一种成立时, 利用源域数据去学习目标域上的预测函数 $f(x_j)$, 使得 $f(x_j)$ 在目标域上拥有最小的预测误差, 用 $\arg\min_{\theta} E\{L[f(x_j), y_j]\}$ 衡量, 其中, $L[f(x_j), y_j]$ 用于衡量预测误差, θ 为可调整的优化参数, E 表示期望。

PBSHM 中的知识迁移属于约束优化问题^[10], 即利用源域数据不断寻优求解目标域预测函数 $f(x_j)$ 。预测函数 $f(x_j)$ 既可显式求解^[14], 也可隐式表达^[46]。本文将基于概率推论、特征变换等显式方法定义为显式迁移, 包括高斯过程回归^[47]、迁移成分分析^[14]等; 将神经网络寻优求解过程定义为隐式迁移, 如深度域适应^[46]、对抗迁移^[48]等。以下内容通过分析显式迁移与隐式迁移在不同种群类型中的具体应用, 综述和总结 PBSHM 问题的解决思路与策略。值得注意的是, 区别于飞机机翼、转子轴承等机械结构, 多自由度系统振子、框架结构以及梁/板单元模型等是桥梁结构的基础力学模型, 对此类结构的研究与评述同样对桥梁结构具有指导意义。为此, 本节用列表方式呈现了总体研究现状, 并聚焦于桥梁工程及其相关结构的研究工作进行评述, 期为桥梁结构健康监测提供思路与启发。

4.1 显式迁移

显式迁移方法基于概率推论对目标域预测函数进行建模^[47], 或者通过显式求解特征变换函数来减小源域与目标域数据的概率分布差异^[14]。显式迁移方法具有坚实的数学理论基础, 基于高斯过程回归建模、边缘分布自适应和条件分布自适应的知识迁移方法^[14, 21, 47]广泛应用于结构异常监测任务。

4.1.1 同质种群

为解决同质种群的 SHM 问题, Bull 等^[19]于 2019 年提出了 Form 概念, 奠定了同质种群结构损伤识别的一般架构。Form 定义了同质种群中所有个体遵循的一般行为^[17], Bull 等^[19]利用部分成员的数据构建 Form, 作为描述整个种群的通用模型, 以推断其他个体是否存在损伤^[47]。Form 具体表现为同质种群中某些特征或测试向量的统计描述^[49-50]。例如, 在由一批特定型号标准螺栓构成同质种群中, 螺栓的几何尺寸应服从某一特定分布, 当检测到某个螺栓的几何尺寸超出该分布时, 即可判定该螺栓不合格。从已知标签信息的种群子集数据中学习 Form 表达, 如学习健康状态的子集信息, 训练得到

种群的 Form 表达可用于种群其他个体的状态评估^[19, 50]。在同质种群的 SHM 中, 基于 Form 显式迁移的 3 个关键要素为 Form 特征选取、Form 预测模型构建、损伤指标。

按预测模型、Form 特征、损伤指标和应用场景等信息进行分类, 表 1 汇总了同质种群 Form 显式迁移相关的研究工作。从表 1 可以看出: Form 显式迁移采用概率推论并结合结构频响函数、模态频率和时程响应数据的方式来构建预测回归模型。Bull 等^[19]以 8 自由度弹簧振子试验模型为基础, 通过对结构的质量、刚度和阻尼参数进行变异模拟了一个包含 20 个成员的同质种群。基于频响函数 (Frequency Response Function, FRF), Bull 等^[47]定义了振子系统同质种群的 Form, 采用高斯过程回归 (Gaussian Process Regression, GPR) 建立预测模型, 以多元离群统计量的马氏平方距离 (Mahalanobis Square Distance, MSD) 为损伤指标, 判断其它个体的损伤。研究结果证实了该方法在同质种群损伤识别中的应用潜力^[19, 47]。Da Silva 等^[51]提出了一种利用桥梁仿真数据和实测桥梁数据混合训练高斯过程回归模型的新方法, 该模型在检测由支座沉降引起的结构变化和由温度引起的变化时, 表现出令人满意的性能。为消除外部运营条件变化对桥梁结构应变的影响, Buckley 等^[52]引入了一种动态谐波回归时间序列模型对应变数据进行建模, 实现了桥梁损伤的自动检测和结构状态标签的更新。

如表 1 所示, 为全面评估模型的损伤识别性能与预测精度, 选取了多种损伤敏感性指标进行量化分析。这些指标包括归一均方误差 (Normalized Mean Squared Error, NMSE)、平均标准化对数损失 (Mean Standardized Log Loss, MSL), 边际似然之和 (Sum of the Marginal Likelihood, SML)、欧几里得范数 (Euclidean Norm)、负对数似然 (Negative Log Likelihood, NLL)、预测对数似然 (Predictive Log Likelihood, PLL)、均方根误差 (Root Mean Square Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 以及平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)。

在同质种群的显式知识迁移场景下, Form 建模方法可将损伤判别模型泛化应用至未知结构, 并能正确判断目标领域正常状态和大损伤状态。然而, 由于种群个体之间的变异性, 该手段在分辨小损

表 1 同质种群 Form 显式迁移

Table 1 Explicit transfer of the form in homogeneous population

预测模型	Form 特征	损伤指标	应用场景
高斯过程回归	频响函数	MSD	多振子结构损伤识别 ^[19]
	频响函数	MSD	多振子结构损伤识别 ^[47]
	运行功率	NMSE,MSLL	风力电机异常检测 ^[53]
	固有频率	95% Confidence Interval	桥梁结构损伤识别 ^[51]
	运营风速	NMSE	环境影响因素归一化 ^[54]
高斯过程重叠混合模型	频响函数	SML	直升机旋翼叶片试验结构损伤识别 ^[49]
	频响函数	SML	直升机旋翼叶片试验结构损伤识别 ^[50]
监督主成分分析多模型自回归方法	加速度响应	Euclidean Norm	无人机旋翼复合悬臂叶片损伤识别 ^[16]
无监督随机系数高斯混合自回归模型	加速度响应	MSD,NLL	无人机旋翼复合悬臂叶片损伤识别 ^[17]
无监督多模型统计时间序列类型方法	频响函数	L2 范数	无人机旋翼复合悬臂叶片异常诊断 ^[18]
动态谐波回归方法	结构应变	RMSE,MAE,MAPE	实际桥梁结构损伤识别 ^[52]
分层贝叶斯建模		PLL	工程基础设施数据建模 ^[55]

伤方面仍存在局限性。从文献梳理结果来看,涉及桥梁结构健康监测的研究较少,研究基础缺乏。同时,受桥梁结构差异、运营条件差异、环境噪声等因素影响,该手段的精度将可预见地大幅下降。综述结果表明,FRF 特征在同质种群的健康监测中应用广泛,但是对于实际桥梁结构,其频响函数难以获取。

在显式迁移方法下,学者们开发了针对同质种群新的应用场景。由于外部运营条件扰动,同一结构在不同运营环境下的数据可视为从一个同质种群中采样得到。Da Silva 等^[56]基于 TCA 技术开发了一种新的结构温度补偿方法,实现了某种意义上的数据归一化。类似地,桥梁结构在加固维修前后的力学响应存在差异,这为桥梁长期健康监测数据的对齐与标准化提供了解决思路,从而实现结构状态标签的更新^[57]。同质种群的显式迁移方法在桥梁结构健康监测领域展示出了较大潜力,可为桥梁结构群的异常检测、数据预测等方面提供解决方案。

4.1.2 异质种群

相对于同质种群,异质种群个体间的差异更大,基于概率推论的显式迁移模型难以建立^[19,21]。基于特征变换的迁移方法^[10]为异质种群的知识迁移提供了解决方案,该方法通过寻优求解特征变换函数,将源域与目标域数据映射到再生核希尔伯特空间(Reproducing Kernel Hilbert Space, RKHS),以确保源域与目标域数据的分布差异最小^[14]。基于特征变换的知识迁移主要包括统计特征和几何特征变换两大类方法^[9-10],已广泛运用于机械 SHM 以及图像分类^[58-59]等知识迁移中。其中,基于统计特征变换方法有:TCA^[60]、JDA^[61]、平衡分布适应^[62]

(Balanced Distribution Adaptation, BDA);基于几何特征变换方法包括:测地线流核^[63](Geodesic Flow Kernel, GFK)、统计对齐(Statistic Alignment, SA)、相关性对齐(Correlation Alignment, CORAL)、正常条件对齐(Normal-Condition Alignment, NCA)等方法^[40,64]。综合特征变换知识迁移的特点以及异质种群知识迁移的需求可知^[9,10,21-22],实现异质种群 SHM 的 2 个关键要素在于特征空间的选择和有效的特征变换。

基于特征变换的跨领域结构健康监测目前已通过数值试验^[21]、缩尺模型试验^[14]和实际工程结构^[40]得到初步验证。表 2 对异质种群 SHM 显式迁移方法与手段进行了统计,并按照其面临的问题场景、选取的特征与应用对象进行分类。在异质种群 SHM 领域,Gardner 等^[21]基于 JDA 和 K 最近邻(K-Nearest Neighbors, KNN)分类器,以结构固有频率为特征,讨论了不同自由度剪切结构间的领域自适应问题,同时研究了源域与目标域标签空间不一致的情况。Poole 等^[64]将 N 标准化(N-standardization)、A 标准化(A-standardization)、CORAL、NCA 以及正态相关性对齐(Normal-correlation Alignment, NCORAL)等技术作为数据归一化和分布对齐的预处理方式,并在 Z24 桥梁和 KW51 桥梁构成的异质种群数据中采用高斯混合模型(Gaussian Mixture Model, GMM)进行聚类,取得了令人满意的效果。Omori 等^[65]利用 3 座实际桥梁的监测数据,对比分析了 TCA、JDA 和最大独立域适应方法在不同桥梁结构跨域知识迁移与损伤分类的有效性。Figueiredo 等^[66]将桥梁有限元生成的健康监测数据与训练的分类模型扩展应用至实际

表 2 异质种群显式迁移

Table 2 Explicit transfer for the heterogeneous population

应用场景	特征	对象	涉及的方法与手段
跨域损伤分类	固有频率与阻尼比	数值框架模型、试验框架模型	TCA、JDA、ARTL ^[14]
	固有频率	数值剪切模型	JDA ^[21]
	频响函数	直升机机翼结构	TCA、BDA ^[38]
	固有频率	实际桥梁结构	TCA、JDA、MIDA ^[65]
	固有频率	数值桥梁模型、实际桥梁结构	TCA ^[66]
	固有正交模态	数值桥梁模型、实际桥梁结构	JDA-kernel ^[67]
	频响函数	飞机机翼结构	TCA ^[69]
	传递率函数	飞机机翼结构	KBTL ^[70]
	固有频率	数值框架模型、框架试验模型	KBTL ^[71]
	固有频率	钢格桅杆结构	M-JDA ^[72]
跨域损伤检测	频响函数	飞机尾翼结构	TCA ^[73]
	频响函数	飞机尾翼结构	KBTL ^[74]
	固有频率	数值框架结构、试验框架结构	TCA、GPR ^[75]
跨领域非监督聚类	固有频率	实际桥梁结构	DA-GMM ^[68]
特征对齐与归一化	固有频率	数值桥梁模型、实际桥梁结构	JDA、NCA ^[40]
	固有频率	数值框架模型、实际桥梁结构、多自由度振子模型	N 标准化、A 标准化、CORAL、NCA、NCORAL ^[64]
	固有频率	实际桥梁结构	NCA ^[76]

桥梁结构,并利用 TCA 方法减小结构频率特征在源域与目标域之间分布的差异,克服了有限元模型更新过程中的限制。Ardani 等^[67]同样利用桥梁有限元模型来生成足够的源域训练数据,并结合迁移学习将训练好的模型推广至实际桥梁的损伤识别任务中。在 PBSHM 场景下,Gardner 等^[68]提出了域自适应高斯混合模型(Domain-adapted Gaussian Mixture Model, DA-GMM)来解决跨域非监督聚类问题,并通过包含两座桥梁的异质种群证明了该方法的有效性。

在异质种群显式迁移中,具有多种典型的领域自适应与特征对齐方法,如表 2 所示。包括核化贝叶斯迁移学习(Kernelized Bayesian Transfer Learning, KBTL)、最大独立域适应(Maximum Independence Domain Adaptation, MIDA)、基于度量信息的联合分布适应(Metric-informed Joint Distribution Adaptation, M-JDA)、N 标准化、A 标准化等。

Gigliani 等^[40,76]讨论了 BSHM 的跨领域分类任务,其中源域数据来自 Z24 桥梁,目标域数据来自 S101 桥梁。两座桥梁具有相似的结构类型与损伤状况,但是严格意义上二者构成异质种群。为选择合适的特征空间,Gigliani 等^[40,76]从结构的力学行为出发,对两座桥梁的模态振型相似性进行比较,结果如表 3 所示。从表 3 可知,2 座桥梁的前 2 阶模

表 3 两座桥梁的模态振型相似性结果

Table 3 Modal shape similarity results of two bridges

模态阶次	模态振型类型	固有频率/Hz		交叉模态保证率
		Z24 桥梁	S101 桥梁	
1	对称弯曲模态	3.851	4.042	0.98
2	横向/扭转模态	4.911	6.280	0.85
3	非对称弯曲模态	9.772	9.713	0.58

态振型具有较高的交叉模态保证率,这意味着它们的振动型态较为相似。为此,Gigliani 等^[40,76]选取模态振型相似性高的桥梁前 2 阶固有频率构建特征空间,并将 NCA 与 JDA 技术融合,实现了更加有效的特征变换。

图 5 展示了 2 座桥梁的频率特征分布情况,以及利用核密度估计计算的频率特征密度分布函数。从图 5(a)、(c)可以发现:在执行域适应之前,两座桥梁固有频率的均值与标准差存在较大差异,其特征向量的核密度分布也不一致。经 NCA 处理之后,频率特征被转化并投影到新的共享潜空间,频率的统计特征归于一致,核密度分布趋于相同。也就是说,在新的共享潜空间中,频率特征遵循更加相似分布,这意味利用带标签的源域数据训练的分类模型可以对目标域数据进行正确分类。

本节研究表明,异质种群的显式迁移方法在工程结构健康监测中已初步验证有效,并取得了理想的试验结果。然而,TCA 方法在处理高维和大规模

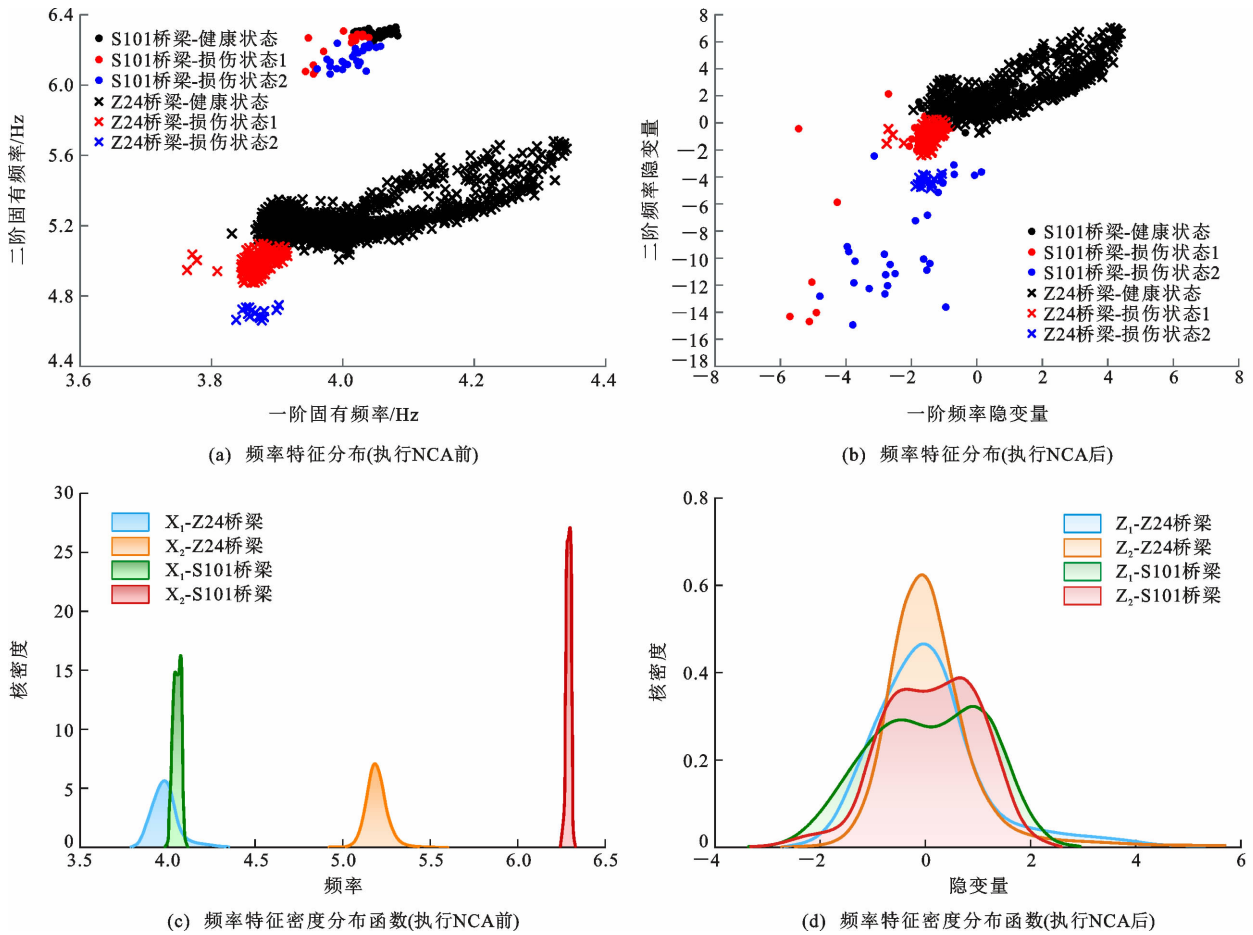


图 5 频率特征分布与频率特征密度分布函数^[40]

Fig. 5 Distribution functions of frequency feature and frequency feature density^[40]

数据时能力较差,而 BSHM 依赖大量监测数据,这将导致其计算能力大幅下降。JDA 和 BDA 方法同时考虑了数据的边缘分布和条件分布,对目标域数据质量依赖较强,其在面对 BSHM 中数据不平衡场景时的精度将受较大影响。此外,已有研究对不同特征变换方法的精度进行了对比分析^[14,38,57,64-65],但尚无一种方法展示出显著优势。在异质种群问题下,个体差异更大,基于特征变换的知识迁移方法成为主流手段,模态参数特征成为常用损伤判别特征。这与 BSHM 领域技术路线中将桥梁模态参数作为损伤判别特征的应用场景很好地契合。从异质种群显式迁移方法的应用场景来看,其可为桥梁结构监测数据的预处理提供便利;同时,开发跨领域的桥梁结构异常检测与特征聚类无监督方法,有助于加快 PBSHM 手段在桥梁健康监测领域的实际应用。

4.2 隐式迁移

随着深度神经网络技术的蓬勃发展,越来越多的研究人员使用深度神经网络进行知识迁移^[77-78]。在 PBSHM 中,深度神经网络可用于同质种群和异

质种群的结构健康监测任务,相较于显式迁移方法,其具有更强的适应性与表征能力^[65,79]。深度神经网络能自动提取更具有表征力的特征,满足实际应用中的端到端(End-to-End)需求^[80]。基于模型预训练微调^[81]、深度神经网络域适应^[82]、生成对抗^[83]和领域泛化^[84]的深度知识迁移方法广泛应用于机械结构的健康监测与损伤识别任务中。无论是同质种群还是异质种群,都面临从源域到目标域跨域执行 SHM 任务的难点。一种经典的、基于深度神经网络的域适应方法可由以下步骤构建^[85]:(1)预训练源域分类模型;(2)微调目标域特征提取器;(3)执行目标域任务。在执行源域到目标域的跨域 SHM 任务中,几乎所有的域适应网络模型都可在其基础上发展得到^[80-83]。

隐式迁移方法利用深度神经网络来提取和变换种群深度特征,构建可执行源域和目标域 SHM 任务的通用模型。基于深度神经网络的域适应方法,有效解决了 SHM 领域中的特征提取、跨域特征分布对齐及标签重利用等问题,从方法论上解决了部

分 PBSHM 实现技术路线中的困难^[82]。图 6 中展示了一种典型的深度域适应网络模型架构,该架构通过最小化源域的分类损失,以及源域特征和目标

域特征的最大均值差异,通过不断优化特征提取器,从而对齐源域和目标域的特征分布,最终实现目标域预测误差最小。

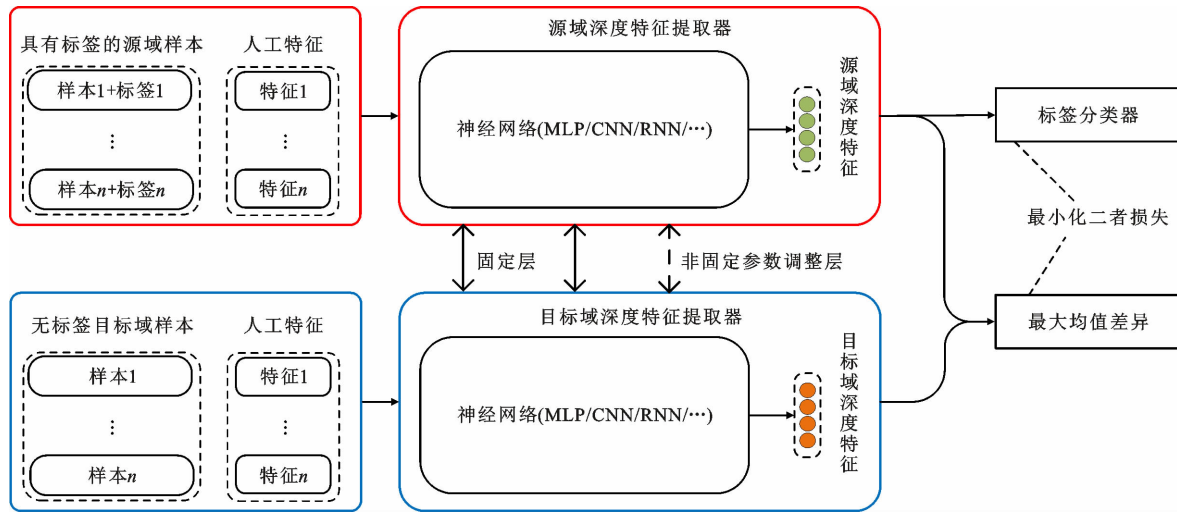


图 6 深度领域自适应方法神经网络架构

Fig. 6 Neural network architecture of deep domain adaptation method

4.2.1 同质种群

表 4 中总结了同质种群隐式知识迁移问题及其解决策略。与显式迁移方法(如 Form^[19])不同,隐式迁移采用数据增强^[86]和迁移学习架构^[87],构建具有强泛化能力的深度神经网络模型^[62,85]。文献统计表明,隐式迁移在同质种群 SHM 研究中主要关注特征对齐与归一化,而对深度挖掘种群个体间的不变表征以及构建通用预测模型的研究相对较少。

在 PBSHM 问题中, Tsialiamanis 等^[88-89]采用功能子空间与元学习的方式来提升模型的预测能力,准确预测了新结构的行为,同时在处理数据不平衡且难以获取的损伤演化问题上显示出潜力。Saida 等^[90]通过引入基于迁移学习的高斯过程回归代理模型(Gaussian Process Regression Surrogate Model with Transfer Learning, TL-GPRSM),在桥梁桥墩的抗震性能可靠性分析中充分利用了源域与目标域相似的输入-输出关系,极大地降低了计算成本。Teng 等^[79]采用数字孪生技术生成大量源域桥梁损伤数据,在目标域上微调已训练的模型并执行目标域 SHM 任务,结果表明迁移学习技术地引入能加速模型训练的收敛速度,可提高损伤分类的精度。Teng 等^[86]利用数值仿真手段,对某桁架桥梁进行结构尺寸变异,形成具有多个源域数据的训练集,并通过集成学习将模型的检测能力扩展到单个结构之外,结果表明模型执行目标域任务的精度得到了显著提升。Tian 等^[91]提出了一种基于迁移学

习的变精度代理模型用于壳体屈曲预测,其通过贝叶斯优化进行超参数调优和模型微调,在相同计算成本下,所提方法具有更高的预测精度,展示了处理多源数据和变精度问题的潜力。

表 4 中统计了多种典型的迁移学习与深度领域自适应方法,包括元学习(Meta-learning)、最大独立域适应(Maximum Independence Domain Adaptation, MIDA)、基于迁移学习的变可信度代理模型(Transfer Learning Based Variable-fidelity Surrogate Model, TL-VFSM)、领域泛化(Domain Generalization, DG)、卷积神经网络(Convolutional Neural Networks, CNN)、深度卷积迁移学习网络(Deep Convolutional Transfer Learning Network, DCTLN)、条件分布适应(Conditional Distribution Adaptation, CDA)、基于均衡适应正则化的迁移学习(Balanced Adaptation Regularization Based Transfer Learning, BARTL)、多核平衡分布适配-堆叠式自动编码器(Multi-core Balanced Distribution Adaptation-stacked Autoencoder, MBDA-SAE)、域适应卷积神经网络(Domain Adaptation Convolutional Neural Networks, DACNN)、具有宽第一层内核的深度卷积神经网络(Deep Convolutional Neural Networks with Wide First-layer Kernels, WDCNN)、自适应批归一化(Adaptive Batch Normalization, Adaptive BN)、多层多核最大均值差异、深度人工神经网络(Deep

表4 隐式迁移下同质种群问题及其解决方案

Table 4 Homogeneous population problems under implicit transfer and related solutions

问题场景	对象	知识迁移策略
基于通用模型的结构行为预测	试验铝板结构	Meta-learning ^[88-89]
	结构动力学方程	Meta-learning ^[87]
	钢混桥梁结构、桥墩	TL-GPRSM ^[90]
	壳单元结构	TL-VFSM ^[91]
数据增强的损伤分类模型泛化	试验桁架桥梁、实际桁架桥梁	预训练微调 ^[79]
	机械滚动轴承	DG ^[84]
	数值桁架桥、试验桁架模型	CNN ^[86]
不同运营条件下特征对齐与归一化/损伤分类	机械滚动轴承数据集	DCTLN ^[13]
	3种不同的机械结构数据集	JDA, MIDA, CDA ^[15]
	机械滚动轴承数据集	BARTL ^[62]
		MBDA-SAE ^[80]
		预训练微调 ^[81]
		SAE-DTL ^[82]
		DACNN ^[85]
		WDCNN, Adaptive BN ^[92]
		多层多核最大均值差异、DANN ^[93]
对称协同训练框架 ^[94]		

Artificial Neural Networks, DANN)以及对称协同训练框架。

从文献梳理结果来看,同质种群的隐式知识迁移方法研究主要集中在机械结构健康监测领域,解决不同运营工况下的特征对齐与损伤分类问题。在BSHM领域,类似的应用场景也大量存在。然而,实际桥梁结构相比机械结构具有更加复杂的运营环境,例如温度变化、风荷载、车辆可变作用等,这使得桥梁结构的振动响应数据复杂多变。此外,实际桥梁结构损伤工况复杂,如锈蚀、开裂、断裂等,针对少数损伤场景的知识迁移存在一定的局限性。在同质种群的隐式知识迁移场景下,隐式迁移方法相比显式迁移方法更具灵活性,能够高效提取和对齐源域与目标域的特征分布,并构建具有强泛化能力的预测模型。在基于种群的桥梁结构健康监测中,同质种群的隐式知识迁移方法仍需针对桥梁结构的特殊性进行改进,以提高模型的可靠性和适应性。

4.2.2 异质种群

由图6的深度知识迁移基本架构可知,该架构不仅适用同质种群的SHM任务,也适用异质种群的SHM任务。异质种群的隐式迁移更多侧重于不同结构的源域到目标域跨域SHM任务^[95-96],各种方法在网络架构设计上存在区别,但核心都是通过优化特征提取器来实现的。表5总结了在隐式迁移下异质种群问题及其解决策略。Tronci等^[97]利用人类语音信号预训练一个时延神经网络(Time-

delay Neural Network, TDNN),构建了一个强大的深度特征提取器,并在数值框架结构和Z24桥梁2个目标域结构上对其加速度信号进行深度特征的提取,实现了端到端的损伤分类任务。为解决不同桥梁结构的特征泛化问题,Xiao等^[95]提出了一种子域自适应深度迁移学习网络(Sub-domain Adaptive Deep Transfer Learning Network, SADTLN),并用3座不同桥梁的损伤分类任务对所提方法进行了交叉验证。基于多尺度的并行多通道特征提取器(Multi-channel Domain Adaptation Deep Transfer Learning, MDADTL)和多核局部最大均值差异的多通道子域自适应模块(Multi-channel Sub-domain Adaptation Deep-transfer Learning Network, MSADTL),Xiao等^[98-99]进一步调整和优化了网络结构,并同样进行了3座桥梁损伤分类任务的交叉验证。Lin等^[100]基于CNN网络架构,考虑了环境不确定性和建模偏差导致的跨域结构损伤检测任务,对有限元模型误差、刚度误差、支座模拟误差、材料和几何参数误差以及传感器噪声引起的信号误差等知识迁移场景进行探讨。

也有学者引入生成对抗网络来优化特征提取器,以减小源域特征与目标域特征的跨域特征分布差异。Luleci等^[101]对生成对抗网络(Generative Adversarial Network, GAN)模型在结构健康监测领域的应用进行全面的综述。Xu等^[96]在多层框架结构的跨域损伤分类任务中,设计了由特征提取器、损

表 5 隐式迁移下异质种群问题及其解决方案
Table 5 Heterogeneous population problems and related solutions under implicit transfer

问题场景	对象	知识迁移手段
不同结构下跨域损伤分类	多层建筑框架结构	PhyMDAN ^[96]
	2 座不同的实际桥梁、数值桥梁模型	SADTLN ^[95]
	2 座不同的实际桥梁、数值桥梁模型	MDADTL ^[98]
	2 座不同的实际桥梁、数值桥梁模型	MSADTL ^[99]
	数值简支梁模型、试验悬臂梁结构	RADA ^[102]
基于模型更新的结构损伤检测	多层框架结构、实际桥梁结构	TDNN ^[97]
	数值简支梁、试验简支梁	DAN ^[100]
	数值框架结构、框架试验模型	ARTL、MBU ^[104]
不同结构/状态下跨域数据生成	数值桁架桥梁结构	DGCG ^[48]
	钢框架结构、数值桥梁模型	1-D WDCGAN-GP ^[83]
	数值简支 T 梁结构	DGCG ^[103]
	钢框架结构	CycleWDCGAN-GP ^[105]
	钢框架结构	Improved-CycleWDCGAN-GP ^[106]

伤预测器和域判别器三部分组成的深度对抗域适应网络。在网络训练中,同时优化特征提取器和域判别器,确保提取的域不变特征在损伤预测器下具有最小的预测损失。为凸显域适应过程中共享标签空间的重要性,Wang 等^[102]开发了一种再加权对抗域适应(Re-weighted Adversarial Domain Adaptation, RADA)方法,用于跨域的结构损伤分类任务。RADA 网络通过对抗方式训练生成器和 2 个分类器,提取损伤敏感特征和域不变特征,并进行了简支梁桥异质种群的数值和试验验证。Ozdagli 等^[46]也将对抗的思想引入深度域适应网络,并通过异质种群 3 层框架结构损伤分类任务验证了所提方法相对于普通域适应方法的优势。

另一方面,通过对抗训练生成未知领域的数据能够学习跨域的特征不变表达,提高模型的泛化能力。Luleci 等^[48]引入了一种“结构状态转换”(Structure State Translation, SST)的新框架,根据从源域桥梁结构获得的信息来估计目标域桥梁结构的响应数据。Luleci 等^[103]在另外一项研究中,进一步将领域泛化循环生成模型(Domain-generalized Cycle-generative, DGCG)用于 2 座桥梁之间不同状态下的加速度数据生成。

隐式迁移下异质种群问题及其解决方案中,具有多种代表性的模型与理论框架,如表 5 所示。包括物理知情的多源域对抗网络(Physics-informed Multi-source Domain Adversarial Networks, PhyMDAN)、域适应网络(Domain Adversarial Networks, DAN)、基于自适应正则化的迁移学习(Adaptation-regularization Based Transfer Learning,

ARTL)、贝叶斯模型更新(Bayesian Model Updating, MBU)、使用梯度惩罚的一维沃瑟斯坦深度卷积生成对抗网络(1-D Wasserstein Deep Convolutional Generative Adversarial Networks using Gradient Penalty, 1-D WDCGAN-GP),以及带梯度惩罚的周期一致沃瑟斯坦深度卷积生成对抗网络(Cycle-consistent Wasserstein Deep Convolutional GAN with Gradient Penalty, CycleWDCGAN-GP)。

相关的研究工作主要聚焦于提高深度知识迁移模型的精度与泛化能力,例如通过采用子域适应和领域对抗的方法。然而,这些方法也增加了网络训练的难度。尽管对抗生成方式可以缓解数据稀缺的问题,但其训练过程仍需要大量数据。而在 BSHM 领域,依然缺乏适合的、具有完整数据的源域结构。从文献分析来看,异质种群的隐式迁移方法在处理跨结构的损伤分类任务中具有显著优势,且部分研究已在 BSHM 领域进行了初步应用。通过对抗训练生成未知领域的数据,可以有效学习跨域的特征不变表达,从而提高模型的泛化能力。异质种群的隐式迁移方法有望在处理 BSHM 中复杂运营环境、监测数据缺失、数据样本不平衡以及跨桥梁结构执行损伤诊断任务等方面发挥更大的作用。

5 桥梁 PBSHM 的应用挑战

对 PBSHM 框架在各个领域的应用和技术路线进行总结,形成如图 7 所示的 PBSHM 总体框架与思路,包含了从同质种群到异质种群、从源域到目标域、从结构相似性度量到数据分布差异分析的主

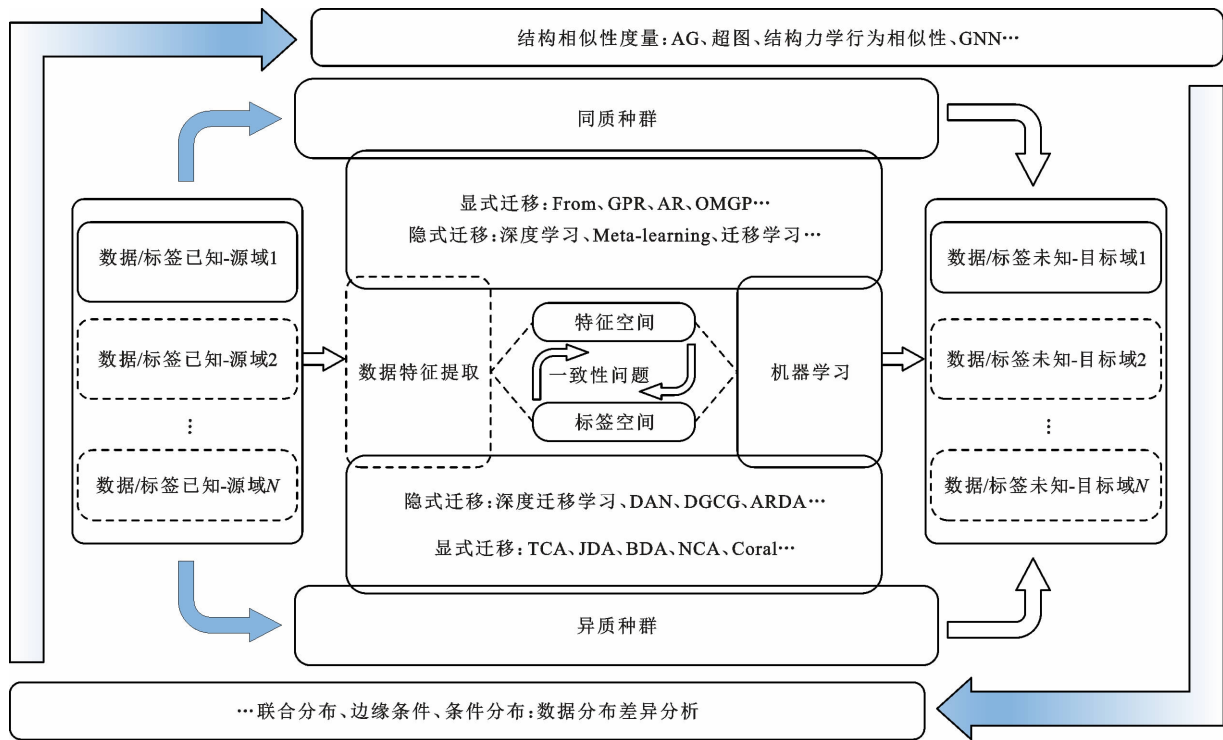


图7 基于种群的结构健康监测总体思路与框架

Fig. 7 General approach and framework of structural health monitoring based on population

要概念,同时包含了不同问题场景下的显式知识迁移和隐式知识迁移方法。

如图7所示,对于源域和目标域,其至少分别包含一个数据域,这意味着在同质种群或异质种群中,种群个体或数据域对象的数量至少为2。框图中交叉重叠的部分表明内容或方法具有较强关联性。在处理同质种群和异质种群问题时,其通常具有显式和隐式两种知识迁移解决方案。针对获取的特征,选择适当的知识迁移方法来解决种群中不同个体之间特征空间与标签空间的一致性问题的,最终实现种群个体之间交换数据、信息和模型的目的。框架的最外围是结构相似性度量和数据分布差异分析,这通常是构建种群的重要步骤,能避免个体差异过大的结构种群,确保结构种群更具实际工程意义。研究人员对PBSHM进行了大量的研究工作,不断丰富了该框架及其方法。尽管PBSHM框架源于机械结构健康监测领域^[22],但其在数据采集与分析、特征提取、状态评估与损伤诊断等^[2]方面的研究成果和技术,在BSHM领域都具有较强的普适性和参考价值。PBSHM的既有研究表明,已有相当数量的研究涉及了桥梁结构健康监测领域,已充分证实了该框架在桥梁领域的适用性与应用潜力。

5.1 桥梁PBSHM面临的挑战

和其他工程结构相比,桥梁结构通常具有更大

的尺度,复杂的几何形状和结构特征将大大增加结构健康监测的难度^[2],这意味着需要更大范围的监测和更长期的数据收集^[3],以确保对结构健康状态的准确评估。同时,桥梁结构是基础设施的重要组成部分,其安全性与可靠性也对桥梁结构健康监测提出了高要求。此外,桥梁结构运营环境的多样性和动力荷载的变化也使得对桥梁结构的健康监测异常困难^[107]。比如,对于中小跨径桥梁结构的损伤检测,受限于传感器数量、长期性能以及损伤检测算法的局限性,在实际桥梁中存在相当大的阻力^[108]。

Worden等^[22]从迁移学习的角度讨论了结构种群所面临的主要挑战,即迁移什么、何时迁移与如何迁移的问题。PBSHM技术的开发与应用有望对桥梁结构健康监测提供一种新的解决思路,但桥梁结构有其自身的特点和独特性,所以应先根据桥梁结构健康监测的特点明确其可能存在的挑战,并针对具体问题给予潜在的解决思路与方法,以为基于种群的桥梁结构健康监测研究提供帮助。本文结合BSHM领域的实际问题,从PBSHM框架与方法匹配的应用场景出发,对其可能存在的挑战与解决思路进行了总结。

5.1.1 挑战1:桥梁结构相似性度量

桥梁结构相似性度量是确保知识能够在不同桥梁个体之间迁移和传播的重要前提,也是判断桥梁

种群构建是否合理的重要基础。已有研究主要基于 AG 度量^[20,24]和结构力学行为相似性度量^[40,76],但在该领域尚未形成成熟、完善的技术路线。桥梁工程中依据结构受力体系的差异对不同桥梁类型进行分类,例如,大量在役的中小跨径桥梁基本上属于简支梁或连续梁,这些桥梁具有标准截面与跨径,结构力学行为相近^[109]。从桥梁结构力学行为出发开展相似性度量,如桥梁结构模态频率分布差异、模态振型保证准则等方面^[38-40],以构建具有现实工程意义的桥梁结构种群,可确保桥梁结构状态信息能在不同桥梁个体之间传播和利用,为实现基于种群的 BSHM 奠定基础。

5.1.2 挑战 2:桥梁健康监测数据可迁移性

实际桥梁结构健康监测数据类型众多^[6],实现不同桥梁结构之间的不同类型数据相互传播利用,可进一步提升 PBSHM 手段在 BSHM 领域的适用范围。在桥梁健康监测领域,桥梁的静力响应数据和动力响应数据常用于分析评估桥梁结构的健康状况^[7],这些数据包括位移、应变、加速度等多种类型。然而,对于不同桥梁结构,健康监测数据是极不平衡的^[110]。在考虑数据不平衡的情况下,如何开展不同类型数据的融合交叉使用,以实现不同桥梁结构之间的知识迁移与传播,是一个亟待解决的问题。目前,针对该方面的研究鲜有,但将迁移学习方法^[59]与桥梁健康监测数据融合的手段^[111]相结合,可能是解决这一问题的潜在思路。

5.1.3 挑战 3:桥梁健康监测数据特征空间与标签空间一致性

具有一致特征空间和标签空间的源域与目标域桥梁结构,可大大简化知识迁移的难度^[21]。然而,在实际桥梁结构从源域到目标域的跨域健康监测任务中,不同桥梁结构往往具有不一致的特征空间。例如,源域桥梁结构具有前三阶的固有频率特征空间,而目标域桥梁结构只包含前两阶固有频率特征空间。与此同时,跨域桥梁结构健康监测任务还面临状态标签数量与类型不一致的困难^[14,24],这种不一致或不平衡性将直接影响跨域执行 BSHM 任务的精度,严重时可能出现负迁移^[71]。目前已有研究通过衡量源域和目标域数据边缘概率分布差异的方式,来移除冗余标签^[21],或者采用降维的方法强制保证特征数量一致^[24]。然而,针对桥梁结构监测数据特征空间和标签空间的具体情况,确保它们在知识迁移时的一致性还需进一步深入研究。

5.1.4 挑战 4:桥梁健康监测数据增强与生成

为构建泛化能力更强的预测模型以便更好地执行桥梁 PBSHM 任务,需继续扩充源域桥梁结构的健康监测数据量^[79,86]。目前,大量在役桥梁的长期健康监测数据与状态标签依旧严重缺乏,这将影响高精度预测模型的训练过程^[6-7]。采用数值仿真数据来扩充源域数据集、利用对抗生成网络生成目标域数据和捕获不同结构之间的域不变表示、以及采用集成学习策略等领域泛化方法构建具有强泛化能力的模型,是目前主流的技术手段^[79,86]。针对桥梁 PBSHM 任务,如何灵活采用已有领域泛化方法和开发新的计算框架,有待进一步研究与讨论。

5.1.5 挑战 5:桥梁结构损伤特征选取

特征工程一直是桥梁健康监测领域的重要组成部分,选择合适的桥梁损伤特征有助于提升计算效率和结果精度^[112]。在跨域的桥梁 SHM 任务中,绝大部分研究采用固有频率作为特征空间^[64-66],以及在隐式迁移方法中采用神经网络深度特征^[82,95]。传统的桥梁结构模态参数受限于传感器数量,对结构损伤并不敏感^[113]。对桥梁结构健康监测数据进行挖掘与萃取,提取与桥梁结构损伤高关联的敏感参数,是桥梁 PBSHM 问题中一个亟待解决的问题。此外,针对不同特征计算效率与精度的研究是必要的,但这方面的工作依旧缺乏。基于神经网络的深度特征能够实现端到端的工程应用,但是其物理含义可解释性不明确。因此,对于深度特征的可解释性与可视化分析也是桥梁 PBSHM 中的主要挑战。

5.1.6 挑战 6:桥梁特征对齐与归一化

一方面,在役桥梁地域分布广泛,桥梁结构响应受局部温度与可变荷载作用的影响较大,这导致了桥梁结构健康监测数据存在巨大的分布差异^[51]。另一方面,桥梁结构维修与加固也会导致结构响应数据偏离初始分布,既有监测数据与标签需要更新^[57]。基于显式迁移与隐式迁移的特征对齐与归一化手段已初步应用于机械结构健康监测领域^[64,82],而 BSHM 领域的研究还相对较少,特别是利用深度神经网络执行跨域的结构特征对齐与数据归一化方面。剔除桥梁种群个体之间运营条件差异对数据分布带来的影响,以及更新已有桥梁监测数据与标签的现实需求,都迫切需要高效执行桥梁结构跨域特征对齐与数据归一化。

5.1.7 挑战 7:基于无监督的桥梁 PBSHM

桥梁监测数据缺乏完整的标签是限制 BSHM

技术智能化发展的主要因素之一。在跨领域桥梁结构健康监测的研究中,开发异常检测与特征聚类等无监督方法可加快 PBSHM 技术在实际桥梁群中的部署^[114]。实际桥梁 PBSHM 任务中,源域桥梁结构可能依旧缺乏健康监测数据以及缺失与之对应的标签信息^[115-116],开发跨领域的桥梁结构状态主动学习技术^[117]与半监督学习技术^[118]能够在一定程度上解决这一问题。此外,从目前的 PBSHM 研究中可以发现,不同的预测回归模型在检测精度上存在差异^[50]。因此,开发基于无监督的高精度、快速(改进)回归算法、聚/分类算法以及神经网络算法等预测算法将是一个重要的研究方向。

5.1.8 挑战 8:迁移学习方法的选择

合适的跨领域/任务知识迁移算法是实现桥梁 PBSHM 的关键和主要挑战。在选择知识迁移算法时,需要综合考虑源域与目标域的相似性、数据体量与质量、以及迁移策略等多方面因素^[119]。如果源域和目标域非常相似,可以使用简单的迁移方法,如 Form 迁移与预训练微调^[19,81]。如果相似性较低,则需要更复杂的方法,如领域自适应或多任务学习^[78]。如果目标域的数据量稀缺或者质量较低,则需要使用更加鲁棒的迁移方法来避免过拟合或欠拟合,包括在目标域上进行数据增强、半监督学习或者基于生成对抗网络的方法^[79,101,114]。根据具体的任务和数据特性,需要充分考虑实例迁移^[120]、特征迁移^[121]、模型迁移^[122]和关系迁移^[123]等不同迁移学习策略^[10]。

5.1.9 挑战 9:引入桥梁结构物理信息

考虑将工程先验和桥梁物理信息引入迁移学习策略,构建通用的损伤诊断预测模型,提升模型在桥梁结构种群中的泛化能力^[124]。端到端的模型训练与部署过程受源域与目标域数据质量的影响较

大^[59],而桥梁工程具有严谨的力学基础,通过将结构静/动力相关的物理方程引入深度方法,可进一步减小模型构建过程中对数据的依赖性,并提升预测模型的泛化能力^[125]。同时,桥梁结构物理先验信息的引入还可提升网络模型的物理可解释性^[126]。目前已有相关研究采用元学习策略来构建结构行为预测模型^[87],以及结合物理先验来调整损失函数的权重等方法^[96],但是基于物理驱动的桥梁 PBSHM 研究仍处于起步阶段。

5.2 公开的桥梁健康监测数据集

BSHM 领域的新方法与新手段层出不穷^[6],但多数研究依旧停留在数值仿真数据与试验模型数据层面,只有少量的研究基于实际工程开展^[127]。对于桥梁结构状态评估与损伤检测,获取真实桥梁结构在损伤状态下的数据是一个难题,这也是桥梁健康监测领域面临的客观障碍^[7,113]。此外,虽然部分重要桥梁结构安装了长期健康监测系统并积累了大量数据,但由于各监测系统相互独立且封闭,相关数据并没有得到充分的利用与分析^[128]。

公开数据集可以使研究人员共享、验证和改进彼此的算法和模型,并在真实的数据集上验证模型的性能。同时,公开的数据集还能增加研究的透明度,使研究结果更容易被其他人验证与复现。表 6 汇总了部分实际桥梁结构与试验模型结构的公开数据集,以供研究人员更好的开展相关研究,促进桥梁结构健康监测领域的发展与实际工程应用。

6 结 语

(1)结构种群是 PBSHM 框架的基础,从描述结构的几何、材料与拓扑 3 个方面可对同质种群与异质种群加以界定。在实际桥梁工程中,因材料变异、施工误差、复杂边界等的影响,桥梁结构种群趋

表 6 桥梁健康监测公开数据集

Table 6 Public datasets for bridge health monitoring

桥梁结构类型	数据地址链接
KW51 Bridge-钢桁架桥 ^[129]	https://zenodo.org/record/3745914
Z24 Bridge-预应力混凝土箱梁 ^[130]	https://bwk.kuleuven.be/bwm/z24
Vänersborg Bridge-钢桁架桥 ^[131]	https://zenodo.org/records/8300495
Bergsöysund Bridge-钢桁连续浮桥 ^[132]	https://zenodo.org/records/8051201
Gjemnessund Bridge-悬索桥 ^[133]	https://zenodo.org/records/5979695
Hell Bridge-钢桁架桥 ^[134]	https://zenodo.org/records/10507957
Dowling Hall Footbridge-钢桁人行天桥 ^[135]	https://engineering.tufts.edu/cee/shm/research/continuous-monitoring-dowling-hall-footbridge
矩形薄板结构-试验模型 ^[136]	https://github.com/Smart-Objects/Impact-Events-Dataset

向于一般同质种群,当桥梁结构个体在前述3个方面存在显著差异时,该种群为异质种群。此外,考虑到桥梁结构所处的复杂运营环境,监测数据层面的异质也是一个不可忽视的情况。

(2)结构相似性度量是实现有效PBSHM的关键。基于AG、超图以及GNN的方法虽然得到了初步验证,但是由于实际桥梁结构体量大且边界条件复杂,在实际桥梁中的应用表现出了计算效率低下和异常的复杂性,且计算结果缺乏工程依据。利用桥梁结构力学行为相似度指标和数据分布相似度指标能避免复杂的结构抽象表示,可在实际应用中轻松部署并判断种群成员之间的知识可迁移性。

(3)在基于显式迁移的同质种群问题中,采用Form建模的方式构建通用的损伤判别预测模型。Form定义了同质种群中所有个体遵循的一般行为,通常通过对结构响应数据或模态特征进行统计学非参数化建模来实现。这种无监督的方法可以为桥梁结构群的异常监测和数据预测建模提供便利。然而,目前涉及桥梁结构健康监测的研究较少,研究基础薄弱。

(4)针对显式迁移的异质种群问题,由于种群个体间的差异较大,基于概率推论的显式迁移模型难以建立,因此需采用显式求解特征变换函数的知识迁移方法来处理。特征变换迁移法已初步应用于桥梁结构健康监测任务中,并在数据预处理、特征对齐与归一化、损伤识别等方面表现出良好的效果。然而,该方法对数据质量依赖性较强,并且受数据不平衡的影响较大。

(5)隐式迁移方法在处理同质种群和异质种群问题中遵循相同的技术路线。基于深度神经网络模型,隐式迁移方法有效解决了显式迁移方法中的特征提取、跨域特征分布对齐及标签重利用等问题。它具有更强的适应性,能够自动提取更具表征力的特征,满足实际应用中的端到端需求。

(6)在隐式迁移的结构种群问题中,对桥梁结构健康监测的研究仍处于起步阶段。基于子域适应和领域对抗生成等方法,可有效实现特征对齐、跨域损伤分类和跨域数据生成,并通过捕获跨域特征不变表达来提高模型的泛化能力。实际桥梁结构健康监测正面临复杂运营环境与结构损伤条件、监测数据缺失、数据样本不平衡等跨域执行SHM的难点,PBSHM框架及方法可为上述问题地解决提供启发。

(7)PBSHM提供了一种将功能需求和种群信

息结合的思考方式,而不是传统的只针对单一结构或单一数据领域的方式。基于知识迁移和匹配技术,PBSHM框架在应对桥梁结构损伤识别任务中的复杂运营条件差异与数据不平衡的影响、数据预测与生成、特征对齐与归一化等方面具有巨大潜力。此外,PBSHM框架有望融合基于模型和基于数据的桥梁结构健康监测,但目前相关研究仍处于起步阶段。

参考文献:

References:

- [1] AN Y H, CHATZI E, SIM S H, et al. Recent progress and future trends on damage identification methods for bridge structures[J]. *Structural Control and Health Monitoring*, 2019, 26(10): e2416.
- [2] FIGUEIREDO E, BROWNJOHN J. Three decades of statistical pattern recognition paradigm for SHM of bridges[J]. *Structural Health Monitoring*, 2022, 21(6): 3018-3054.
- [3] SONY S, DUNPHY K, SADHU A, et al. A systematic review of convolutional neural network-based structural condition assessment techniques[J]. *Engineering Structures*, 2021, 226: 111347.
- [4] AZIMI M, ESLAMLOU A D, PEKCAN G. Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review [J]. *Sensors*, 2020, 20(10): 2778.
- [5] FLAH M, NUNEZ I, BEN CHAABENE W, et al. Machine learning algorithms in civil structural health monitoring: A systematic review[J]. *Archives of Computational Methods in Engineering*, 2021, 28(4): 2621-2643.
- [6] MORAVVEJ M, EL-BADRY M. Reference-free vibration-based damage identification techniques for bridge structural health monitoring: A critical review and perspective [J]. *Sensors*, 2024, 24(3): 876.
- [7] SUN L M, SHANG Z Q, XIA Y, et al. Review of bridge structural health monitoring aided by big data and artificial intelligence: From condition assessment to damage detection [J]. *Journal of Structural Engineering*, 2020, 146(5): 04020073.
- [8] ZHANG Y, YUEN K V. Review of artificial intelligence-based bridge damage detection [J]. *Advances in Mechanical Engineering*, 2022, 14(9): 16878132221122770.
- [9] PAN S J, YANG Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 22(10): 1345-1359.
- [10] ZHUANG F Z, QI Z Y, DUAN K Y, et al. A comprehensive survey on transfer learning [J]. *Proceedings of the IEEE*, 2020, 109(1): 43-76.
- [11] WANG J D, LAN C L, LIU C, et al. Generalizing to unseen domains: A survey on domain generalization[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(8):

- 8052-8072 .
- [12] ZHU Y C, ZHUANG F Z, WANG J D, et al. Deep subdomain adaptation network for image classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(4): 1713-1722.
- [13] GUO L, LEI Y G, XING S B, et al. Deep convolutional transfer learning network: A new method for intelligent fault diagnosis of machines with unlabeled data[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(9): 7316-7325.
- [14] GARDNER P, LIU X, WORDEN K. On the application of domain adaptation in structural health monitoring[J]. *Mechanical Systems and Signal Processing*, 2020, 138: 106550.
- [15] HAN T, LIU C, YANG W G, et al. Deep transfer network with joint distribution adaptation: A new intelligent fault diagnosis framework for industry application[J]. *ISA Transactions*, 2020, 97: 269-281.
- [16] VAMVOUDAKIS-STEFANOOU K, SAKELLARIOU J, FASSOIS S. On the use of unsupervised response-only vibration-based damage detection methods for a population of composite structures[C]//EWSHM. *Proceedings of the 8th European Workshop on Structural Health Monitoring*. Berlin: EWSHM, 2016: 2822-2831.
- [17] VAMVOUDAKIS-STEFANOOU K J, FASSOIS S D. Vibration-based damage detection for a population of nominally identical structures via Random Coefficient Gaussian Mixture AR model based methodology [J]. *Procedia Engineering*, 2017, 199: 1888-1893.
- [18] VAMVOUDAKIS-STEFANOOU K J, SAKELLARIOU J S, FASSOIS S D. Vibration-based damage detection for a population of nominally identical structures: Unsupervised multiple model(MM) statistical time series type methods[J]. *Mechanical Systems and Signal Processing*, 2018, 111: 149-171.
- [19] BULL L A, GARDNER P A, GOSLIGA J, et al. Foundations of population-based SHM, part I: Homogeneous populations and forms[J]. *Mechanical Systems and Signal Processing*, 2021, 148: 107141.
- [20] GOSLIGA J, GARDNER P A, BULL L A, et al. Foundations of population-based SHM, part II: Heterogeneous populations—graphs, networks, and communities [J]. *Mechanical Systems and Signal Processing*, 2021, 148: 107144.
- [21] GARDNER P, BULL L A, GOSLIGA J, et al. Foundations of population-based SHM, part III: Heterogeneous populations—mapping and transfer[J]. *Mechanical Systems and Signal Processing*, 2021, 149: 107142.
- [22] WORDEN K, BULL L A, GARDNER P, et al. A brief introduction to recent developments in population-based structural health monitoring[J]. *Frontiers in Built Environment*, 2020, 6: 146.
- [23] GUO Y, ZHANG J D, SUN B, et al. Adversarial deep transfer learning in fault diagnosis: Progress, challenges, and future prospects[J]. *Sensors*, 2023, 23(16): 7263.
- [24] GARDNER P, BULL L A, GOSLIGA J, et al. A population-based SHM methodology for heterogeneous structures: Transferring damage localisation knowledge between different aircraft wings[J]. *Mechanical Systems and Signal Processing*, 2022, 172: 108918.
- [25] TSIALIAMANIS G, MYLONAS C, CHATZI E, et al. Foundations of population-based SHM, part IV: The geometry of spaces of structures and their feature spaces[J]. *Mechanical Systems and Signal Processing*, 2021, 157: 107692.
- [26] BULL L A, GARDNER P A, GOSLIGA J, et al. Towards population-based structural health monitoring, part I: Homogeneous populations and forms[M]. Berlin: Springer, 2021.
- [27] GARDNER P, BULL L A, GOSLIGA J, et al. Towards population-based structural health monitoring, part IV: Heterogeneous populations, transfer and mapping [M]. Berlin: Springer, 2021.
- [28] YAO S Y, KANG Q, ZHOU M C, et al. A survey of transfer learning for machinery diagnostics and prognostics[J]. *Artificial Intelligence Review*, 2023, 56(4): 2871-2922.
- [29] WICKRAMARACHCHI C T, POOLE J, CROSS E J, et al. On aspects of geometry in SHM and population-based SHM [M]. Berlin: Springer, 2022.
- [30] WANG Z R, DAI Z H, PÓCZOS B, et al. Characterizing and avoiding negative transfer [C] // *IEEE. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. New York: IEEE, 2019: 11285-11294.
- [31] HUGHES A J, POOLE J, DERVLIS N, et al. A decision framework for selecting information-transfer strategies in population-based SHM[J/OL]. *arXiv*, 2023, <https://doi.org/10.48550/arXiv.2307.06978>.
- [32] BUNCE A, HESTER D, WORDEN K, et al. PBSHM- guidance for ensuring quality when creating an IE model for a bridge[C]//CUNHA Á, CAETANO E. *Proceedings of the 10th International Conference on Structural Health Monitoring of Intelligent Infrastructure*. Porto: ISHMII, 2021: 1789-1795.
- [33] GOSLIGA J, GARDNER P, BULL L A, et al. Towards population-based structural health monitoring, part II: Heterogeneous populations and structures as graphs[M]. Berlin: Springer, 2021.
- [34] GOSLIGA J, GARDNER P, BULL L A, et al. Towards population-based structural health monitoring, part III: Graphs, networks and communities[M]. Berlin: Springer, 2021.
- [35] DELO G, BUNCE A, CROSS E J, et al. When is a bridge not an aeroplane? Part II: A population of real structures[C] // *Springer. European Workshop on Structural Health Monitoring*. Berlin: Springer, 2022: 965-974.
- [36] BRENNAN D S, GOSLIGA J, GARDNER P, et al. On the application of population-based structural health monitoring in aerospace engineering[J]. *Frontiers in Robotics and AI*, 2022, 9: 840058.

- [37] GOSLIGA J, HESTER D, WORDEN K, et al. On population-based structural health monitoring for bridges [J]. *Mechanical Systems and Signal Processing*, 2022, 173: 108919.
- [38] POOLE J, GARDNER P, HUGHES A J, et al. Physics-informed transfer learning in PBSHM: A case study on experimental helicopter blades[C]// FARHANGDOUST S, GUEMES A, CHANG F K. *Proceedings of the 14th International Workshop on Structural Health Monitoring*. Lancaster: DEStech Publications, Inc., 2023: 236-267.
- [39] POOLE J, GARDNER P, DERVILIS N, et al. Towards physics-based metrics for transfer learning in dynamics [C] // MADARSHAHIAN R, HEMEZ F. *Conference Proceedings of the Society for Experimental Mechanics Series*. Berlin: Springer, 2023: 73-82.
- [40] GIGLIONI V, POOLE J, VENANZI I, et al. A domain adaptation approach to damage classification with an application to bridge monitoring[J]. *Mechanical Systems and Signal Processing*, 2024, 209: 111135.
- [41] WICKRAMARACHCHI C T, LEAHY W, WORDEN K, et al. On metrics assessing the information content of datasets for population-based structural health monitoring [C] // RIZZO P, MILAZZO A. *European Workshop on Structural Health Monitoring*. Berlin: Springer, 2021: 494-504.
- [42] WICKRAMARACHCHI C T, MAGUIRE E, CROSS E J, et al. Measuring data similarity in population-based structural health monitoring using distance metrics[J]. *Structural Health Monitoring*, 2024, 23(4): 2609-2635.
- [43] BRENNAN D S, ROGERS T J, CROSS E J, et al. Calculating structure similarity via a graph neural network in population-based structural health monitoring: Part II [C] // NOH H Y, WHELAN M, HARVEY P S. *Proceedings of the 41st IMAC, A Conference and Exposition on Structural Dynamics 2023*. Berlin: Springer, 2023: 151-158.
- [44] TSIALIAMANIS G, MYLONAS C, CHATZI E N, et al. On an application of graph neural networks in population-based SHM [C] // MADARSHAHIAN R, HEMEZ F. *Proceedings of the 39th IMAC, A Conference and Exposition on Structural Dynamics 2021*. Berlin: Springer, 2021: 47-63.
- [45] DELO G, SURACE C, WORDEN K, et al. On the influence of structural attributes for assessing similarity in population-based structural health monitoring[C]// FARHANGDOUST S, GUEMES A, CHANG F K. *Proceedings of the 14th International Workshop on Structural Health Monitoring*. Lancaster: DEStech Publications, Inc., 2023: 1553-1562.
- [46] OZDAGLI A, KOUTSOUKOS X. Domain adaptation for structural fault detection under model uncertainty [J]. *International Journal of Prognostics and Health Management*, 2021, 12(2): 29-48.
- [47] BULL L, ROGERS T, DERVILIS N, et al. A Gaussian process form for population-based structural health monitoring[C]// WAHAB M A. *Proceedings of the 13th International Conference on Damage Assessment of Structures*. Berlin: Springer, 2019: 47-63.
- [48] LULECI F, CATBAS F N. Structural state translation: Condition transfer between civil structures using domain-generalization for structural health monitoring [J/OL]. arXiv, 2022, <http://arxiv.org/abs/2212.14048>.
- [49] DARDENO T A, BULL L A, DERVILIS N, et al. A generalised form for a homogeneous population of structures using an overlapping mixture of Gaussian processes[J/OL]. arXiv, 2022, <http://arxiv.org/abs/2206.11683>.
- [50] DARDENO T A, BULL L A, MILLS R S, et al. Modelling variability in vibration-based PBSHM via a generalised population form[J]. *Journal of Sound and Vibration*, 2022, 538: 117227.
- [51] DA SILVA S, FIGUEIREDO E, MOLDOVAN I. Damage detection approach for bridges under temperature effects using Gaussian process regression trained with hybrid data [J]. *Journal of Bridge Engineering*, 2022, 27(11): 04022107.
- [52] BUCKLEY T, PAKRASHI V, GHOSH B. A dynamic harmonic regression approach for bridge structural health monitoring[J]. *Structural Health Monitoring*, 2021, 20(6): 3150-3181.
- [53] LIN W J, WORDEN K, MAGUIRE A E, et al. A mapping method for anomaly detection in a localized population of structures[J]. *Data-centric Engineering*, 2022, 3: e25.
- [54] LIN W, WORDEN K, EOGHAN MAGUIRE A, et al. Towards population-based structural health monitoring, Part VIII: EOVS Fields-Environmental Mapping[C]// DILWORTH B, MAINS M. *Proceedings of the 38th IMAC, A Conference and Exposition on Structural Dynamics 2020*. Berlin: Springer, 2021: 297-304.
- [55] BULL L A, DI FRANCESCO D, DHADA M, et al. Hierarchical Bayesian modeling for knowledge transfer across engineering fleets via multitask learning[J]. *Computer-aided Civil and Infrastructure Engineering*, 2023, 38(7): 821-848.
- [56] DA SILVA S, YANO M O, GONSALEZ-BUENO C G. Transfer component analysis for compensation of temperature effects on the impedance-based structural health monitoring [J]. *Journal of Nondestructive Evaluation*, 2021, 40(3): 64.
- [57] GARDNER P, BULL L A, DERVILIS N, et al. Overcoming the problem of repair in structural health monitoring: Metric-informed transfer learning[J]. *Journal of Sound and Vibration*, 2021, 510: 116245.
- [58] LIN Q G, CI T Y, WANG L B, et al. Transfer learning for improving seismic building damage assessment[J]. *Remote Sensing*, 2022, 14(1): 201.
- [59] PAN Q Y, BAO Y Q, LI H. Transfer learning-based data anomaly detection for structural health monitoring[J]. *Structural Health Monitoring*, 2023, 22(5): 3077-3091.
- [60] RITTO T G, WORDEN K, WAGG D J, et al. A transfer

- learning-based digital twin for detecting localised torsional friction in deviated wells[J]. *Mechanical Systems and Signal Processing*, 2022, 173: 109000.
- [61] ZHOU X, SBARUFATTI C, GIGLIO M, et al. A fuzzy-set-based joint distribution adaptation method for regression and its application to online damage quantification for structural digital twin[J]. *Mechanical Systems and Signal Processing*, 2023, 191: 110164.
- [62] HU Q, SI X S, QIN A S, et al. Balanced adaptation regularization based transfer learning for unsupervised cross-domain fault diagnosis[J]. *IEEE Sensors Journal*, 2022, 22(12): 12139-12151.
- [63] ZHANG Z W, CHEN H H, LI S M, et al. A novel geodesic flow kernel based domain adaptation approach for intelligent fault diagnosis under varying working condition[J]. *Neurocomputing*, 2020, 376: 54-64.
- [64] POOLE J, GARDNER P, DERVILIS N, et al. On statistic alignment for domain adaptation in structural health monitoring[J]. *Structural Health Monitoring*, 2023, 22(3): 1581-1600.
- [65] OMORI YANO M, FIGUEIREDO E, DA SILVA S, et al. Foundations and applicability of transfer learning for structural health monitoring of bridges[J]. *Mechanical Systems and Signal Processing*, 2023, 204: 110766.
- [66] FIGUEIREDO E, OMORI YANO M, DA SILVA S, et al. Transfer learning to enhance the damage detection performance in bridges when using numerical models[J]. *Journal of Bridge Engineering*, 2023, 28: 04022134.
- [67] ARDANI S, EFTEKHAR AZAM S, LINZELL D G. Bridge health monitoring using proper orthogonal decomposition and transfer learning[J]. *Applied Sciences*, 2023, 13(3): 1935.
- [68] GARDNER P, BULL L A, DERVILIS N, et al. Domain-adapted Gaussian mixture models for population-based structural health monitoring[J]. *Journal of Civil Structural Health Monitoring*, 2022, 12(6): 1343-1353.
- [69] BULL L A, GARDNER P A, DERVILIS N, et al. Transferring damage detectors between tailplane experiments[C]//MADARSHAHIAN R, HEMEZ F. *Conference Proceedings of the Society for Experimental Mechanics Series*. Berlin: Springer, 2021: 199-211.
- [70] GARDNER P A, BULL L A, DERVILIS N, et al. On the application of heterogeneous transfer learning to population-based structural health monitoring[C]//MADARSHAHIAN R, HEMEZ F. *Proceedings of the 39th IMAC, A Conference and Exposition on Structural Dynamics 2021*. Berlin: Springer, 2021: 87-98.
- [71] GARDNER P, BULL L A, DERVILIS N, et al. On the application of kernelised Bayesian transfer learning to population-based structural health monitoring[J]. *Mechanical Systems and Signal Processing*, 2022, 167: 108519.
- [72] WICKRAMARACHCHI C T, GARDNER P, POOLE J, et al. Damage localisation using disparate damage states via domain adaptation[J]. *Data-centric Engineering*, 2024, 5: e3.
- [73] BULL L A, GARDNER P A, DERVILIS N, et al. On the transfer of damage detectors between structures: An experimental case study[J]. *Journal of Sound and Vibration*, 2021, 501: 116072.
- [74] BULL L A, GARDNER P, DERVILIS N, et al. Automated Feature Extraction for Damage Detection: A Pseudo-fault Framework for Population-based SHM[C]//CUNHA A, CAETANO E. *Proceedings of the 10th International Conference on Structural Health Monitoring of Intelligent Infrastructure (SHM II-10)*. Belfast: Queen's University Belfast, 2021: 655-662.
- [75] OMORI YANO M, DA SILVA S, FIGUEIREDO E, et al. Damage quantification using transfer component analysis combined with Gaussian process regression[J]. *Structural Health Monitoring*, 2023, 22(2): 1290-1307.
- [76] GIGLIONI V, POOLE J, VENANZI I, et al. On the use of domain adaptation techniques for bridge damage detection in a changing environment[J]. *CE/Papers*, 2023, 6(5): 975-980.
- [77] LI W H, HUANG R Y, LI J P, et al. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios: Theories, applications and challenges[J]. *Mechanical Systems and Signal Processing*, 2022, 167: 108487.
- [78] YU F C, XIU X C, LI Y H. A survey on deep transfer learning and beyond[J]. *Mathematics*, 2022, 10(19): 3619.
- [79] TENG S, CHEN X D, CHEN G F, et al. Structural damage detection based on transfer learning strategy using digital twins of bridges[J]. *Mechanical Systems and Signal Processing*, 2023, 191: 110160.
- [80] CAO N, JIANG Z N, GAO J J, et al. Bearing state recognition method based on transfer learning under different working conditions[J]. *Sensors*, 2020, 20(1): 234.
- [81] ZHANG R, TAO H Y, WU L F, et al. Transfer learning with neural networks for bearing fault diagnosis in changing working conditions[J]. *IEEE Access*, 2017, 5: 14347-14357.
- [82] WEN L, GAO L, LI X Y. A new deep transfer learning based on sparse auto-encoder for fault diagnosis[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2019, 49(1): 136-144.
- [83] LULECI F, CATBAS F N, AVCI O. Generative adversarial networks for labeled acceleration data augmentation for structural damage detection[J]. *Journal of Civil Structural Health Monitoring*, 2023, 13(1): 181-198.
- [84] LI X, ZHANG W, MA H, et al. Domain generalization in rotating machinery fault diagnostics using deep neural networks[J]. *Neurocomputing*, 2020, 403: 409-420.
- [85] ZHANG B, LI W, LI X L, et al. Intelligent fault diagnosis under varying working conditions based on domain adaptive convolutional neural networks[J]. *IEEE Access*, 2018, 6: 66367-66384.
- [86] TENG S, CHEN X D, CHEN G F, et al. Structural damage

- detection based on convolutional neural networks and population of bridges[J]. *Measurement*, 2022, 202: 111747.
- [87] CHENG M H, DANG C, FRANGOPOL D M, et al. Transfer prior knowledge from surrogate modelling: A meta-learning approach [J]. *Computers & Structures*, 2022, 260: 106719.
- [88] TSIALIAMANIS G, DERVILIS N, WAGG D J, et al. A Meta-learning approach to population-based modelling of structures[J/OL]. *arXiv*, 2023, <http://arxiv.org/abs/2302.07980>.
- [89] TSIALIAMANIS G, SBARUFATTI C, DERVILIS N, et al. On a meta-learning population-based approach to damage prognosis[J]. *Mechanical Systems and Signal Processing*, 2024, 209: 111119.
- [90] SAIDA T, NISHIO M. Transfer learning Gaussian process regression surrogate model with explainability for structural reliability analysis under variation in uncertainties[J]. *Computers & Structures*, 2023, 281: 107014.
- [91] ZHANG W, PENG G L, LI C H, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals [J]. *Sensors*, 2017, 17(2): 425.
- [92] TIAN K, LI Z C, ZHANG J X, et al. Transfer learning based variable-fidelity surrogate model for shell buckling prediction [J]. *Composite Structures*, 2021, 273: 114285.
- [93] LI X, ZHANG W, DING Q, et al. Multi-layer domain adaptation method for rolling bearing fault diagnosis [J]. *Signal Processing*, 2019, 157: 180-197.
- [94] YU K, HAN H Z, FU Q, et al. Symmetric co-training based unsupervised domain adaptation approach for intelligent fault diagnosis of rolling bearing [J]. *Measurement Science and Technology*, 2020, 31(11): 115008.
- [95] XIAO H T, DONG L M, WANG W J, et al. Distribution sub-domain adaptation deep transfer learning method for bridge structure damage diagnosis using unlabeled data[J]. *IEEE Sensors Journal*, 2022, 22(15): 15258-15272.
- [96] XU S S, NOH H Y. PhyMDAN: Physics-informed knowledge transfer between buildings for seismic damage diagnosis through adversarial learning[J]. *Mechanical Systems and Signal Processing*, 2021, 151: 107374.
- [97] TRONCI E M, BEIGI H, BETTI R, et al. A damage assessment methodology for structural systems using transfer learning from the audio domain[J]. *Mechanical Systems and Signal Processing*, 2023, 195: 110286.
- [98] XIAO H T, OGAI H, WANG W J. Multi-channel domain adaptation deep transfer learning for bridge structure damage diagnosis[J]. *IEEE Transactions on Electrical and Electronic Engineering*, 2022, 17(11): 1637-1647.
- [99] XIAO H T, OGAI H, WANG W J. A new deep transfer learning method for intelligent bridge damage diagnosis based on Multi-channel sub-domain adaptation [J]. *Structure and Infrastructure Engineering*, 2024, 20(12): 1994-2009.
- [100] LIN Y Z, NIE Z H, MA H W. Dynamics-based cross-domain structural damage detection through deep transfer learning [J]. *Computer-aided Civil and Infrastructure Engineering*, 2022, 37(1): 24-54.
- [101] LULECI F, CATBAS F N, AVCI O. A literature review: Generative adversarial networks for civil structural health monitoring[J]. *Frontiers in Built Environment*, 2022, 8: 1027379.
- [102] WANG X Y, XIA Y. Knowledge transfer for structural damage detection through re-weighted adversarial domain adaptation[J]. *Mechanical Systems and Signal Processing*, 2022, 172: 108991.
- [103] LULECI F, NECATI CATBAS F. Condition transfer between prestressed bridges using structural state translation for structural health monitoring [J]. *AI in Civil Engineering*, 2023, 2(1): 7.
- [104] ZHANG Z M, SUN C, GUO B B. Transfer-learning guided Bayesian model updating for damage identification considering modeling uncertainty[J]. *Mechanical Systems and Signal Processing*, 2022, 166: 108426.
- [105] LULECI F, CATBAS F N, AVCI O. CycleGAN for Undamaged-to-damaged Domain Translation for Structural Health Monitoring and Damage Detection [J/OL]. *arXiv*, 2022, <http://arxiv.org/abs/2202.07831>.
- [106] LULECI F, AVCI O, CATBAS F N. Improved undamaged-to-damaged acceleration response translation for Structural Health Monitoring[J]. *Engineering Applications of Artificial Intelligence*, 2023, 122: 106146.
- [107] REULAND Y, GARCIA-RAMONDA L, MARTAKIS P, et al. A full-scale case study of vibration-based structural health monitoring of bridges: Prospects and open challenges [J]. *CE/Papers*, 2023, 6(5): 329-336.
- [108] BROWNJOHN J M W, KRIPAKARAN P, HARVEY B, et al. Structural health monitoring of short to medium span bridges in the United Kingdom[J]. *Structural Monitoring and Maintenance*, 2016, 3(3): 259-276.
- [109] MIYAMOTO A, KIVILUOMA R, YABE A. Frontier of continuous structural health monitoring system for short & medium span bridges and condition assessment[J]. *Frontiers of Structural and Civil Engineering*, 2019, 13(3): 569-604.
- [110] ENTEZAMI A, SARMADI H, BEHKAMAL B, et al. Big data analytics and structural health monitoring: A statistical pattern recognition-based approach [J]. *Sensors*, 2020, 20(8): 2328.
- [111] WU R T, JAHANSHAHI M R. Data fusion approaches for structural health monitoring and system identification: Past, present, and future[J]. *Structural Health Monitoring*, 2020, 19(2): 552-586.
- [112] BUCKLEY T, GHOSH B, PAKRASHI V. A feature extraction & selection benchmark for structural health monitoring [J]. *Structural Health Monitoring*, 2023, 22(3): 2082-2127.

- [113] AVCI O, ABDELJABER O, KIRANYAZ S, et al. A review of vibration-based damage detection in civil structures: From traditional methods to machine learning and deep learning applications[J]. *Mechanical Systems and Signal Processing*, 2021, 147: 107077.
- [114] WILSON G, COOK D J. A survey of unsupervised deep domain adaptation[J]. *ACM Transactions on Intelligent Systems and Technology*, 2020, 11(5): 1-46.
- [115] TOH G, PARK J. Review of vibration-based structural health monitoring using deep learning [J]. *Applied Sciences*, 2020, 10(5): 1680.
- [116] MALEKLOO A, OZER E, ALHAMAYDEH M, et al. Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights[J]. *Structural Health Monitoring*, 2022, 21(4): 1906-1955.
- [117] BULL L A, ROGERS T J, WICKRAMARACHCHI C, et al. Probabilistic active learning: an online framework for structural health monitoring[J]. *Mechanical Systems and Signal Processing*, 2019, 134: 106294.
- [118] BULL L A, WORDEN K, DERVILIS N. Towards semi-supervised and probabilistic classification in structural health monitoring[J]. *Mechanical Systems and Signal Processing*, 2020, 140: 106653.
- [119] DAY O, KHOSHGOFTAAR T M. A survey on heterogeneous transfer learning[J]. *Journal of Big Data*, 2017, 4(1): 29.
- [120] WANG T Y, HUAN J, ZHU M. Instance-based deep transfer learning[C]//IEEE. 2019 IEEE Winter Conference on Applications of Computer Vision (WACV). New York: IEEE, 2019: 367-375.
- [121] REN H, LIU W Y, SHAN M C, et al. A new wind turbine health condition monitoring method based on VMD-MPE and feature-based transfer learning [J]. *Measurement*, 2019, 148: 106906.
- [122] SHAN X X, LU Y, LI Q L, et al. Model-based transfer learning and sparse coding for partial face recognition[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 31(11): 4347-4356.
- [123] NIU S T, LIU Y X, WANG J, et al. A decade survey of transfer learning (2010—2020) [J]. *IEEE Transactions on Artificial Intelligence*, 2020, 1(2): 151-166.
- [124] RIZVI S H M, ABBAS M. From data to insight, enhancing structural health monitoring using physics-informed machine learning and advanced data collection methods [J]. *Engineering Research Express*, 2023, 5(3): 032003.
- [125] ZHANG M T, GUO T, ZHANG G D, et al. Physics-informed deep learning for structural vibration identification and its application on a benchmark structure[J]. *Philosophical Transactions Series A: Mathematical, Physical, and Engineering Sciences*, 2024, 382(2264): 20220400.
- [126] DI LORENZO D, CHAMPANEY V, MARZIN J Y, et al. Physics informed and data-based augmented learning in structural health diagnosis[J]. *Computer Methods in Applied Mechanics and Engineering*, 2023, 414: 116186.
- [127] ZINNO R, HAGHSHEENAS S S, GUIDO G, et al. Artificial intelligence and structural health monitoring of bridges: A review of the state-of-the-art[J]. *IEEE Access*, 2022, 10: 88058-88078.
- [128] WANG X P, ZHAO Q Z, XI R J, et al. Review of bridge structural health monitoring based on GNSS: From displacement monitoring to dynamic characteristic identification[J]. *IEEE Access*, 2021, 9: 80043-80065.
- [129] MAES K, LOMBAERT G. Monitoring railway bridge KW51 before, during, and after retrofitting[J]. *Journal of Bridge Engineering*, 2021, 26(3): 04721001.
- [130] REYNDERS E, ROECK G. Continuous vibration monitoring and progressive damage testing on the Z24 bridge [M]. *Encyclopedia of Structural Health Monitoring*. New York: Wiley, 2008.
- [131] MENGHINI A, LEANDER J, CASTIGLIONI C A. A local response function approach for the stress investigation of a centenarian steel railway bridge[J]. *Engineering Structures*, 2023, 286: 116116.
- [132] KVÅLE K A, FENERCI A, PETERSEN Ø W, et al. Data set from long-term wave, wind, and response monitoring of the Bergsøysund Bridge[J]. *Journal of Structural Engineering*, 2023, 149(9): 04723002.
- [133] FENERCI A, KVÅLE K A, PETERSEN Ø W, et al. Data set from long-term wind and acceleration monitoring of the hardanger bridge [J]. *Journal of Structural Engineering*, 2021, 147(5): 04721003.
- [134] SVENDSEN B T, FRØSETH G T, ØISETH O, et al. A data-based structural health monitoring approach for damage detection in steel bridges using experimental data[J]. *Journal of Civil Structural Health Monitoring*, 2022, 12(1): 101-115.
- [135] KODY A, LI X, MOAVENI B. Identification of physically simulated damage on a footbridge based on ambient vibration data[C]//ASCE. Structures Congress 2013. New York: ASCE, 2013: 352-362.
- [136] KATSIDIMAS I, KOTZAKOLIOS T, NIKOLETSEAS S, et al. Impact events for structural health monitoring of a plastic thin plate: Dataset[C]//ACM. Proceedings of the 20th ACM Conference on Embedded Networked Sensor Systems. New York: ACM, 2022: 1020-1025.