

基于导波和知识迁移的结构损伤识别方法研究



李嘉欣¹, 吕帅帅¹, 杨宇¹, 张腾飞², 张桂刚², 李泊言³

1. 中国飞机强度研究所 强度与结构完整性全国重点实验室, 陕西 西安 710065

2. 中国科学院自动化研究所, 北京 100190

3. 北京理工大学, 北京 100089

摘要: 基于导波的损伤诊断方法在航空结构健康监测领域具有较好的工程应用前景, 但由于使用环境和结构形式复杂、结构损伤识别阈值依靠先验知识确定, 在提高损伤诊断准确性和可靠性方面还面临巨大挑战。人工智能方法可以降低对先验知识的依赖, 但是需要大量的试验数据, 实际工程中无法承受。因此, 本文提出一种利用模拟物理损伤产生大量数据, 再结合少量真实损伤数据进行结构损伤识别的研究思路, 并以迁移学习算法为基础架构, 设计了适用于实际工程应用的结构损伤识别模型 PRED_RF。试验结果分析表明, 在有限数据的情况下, PRED_RF 模型的损伤识别效果明显优于其他传统机器学习 and 深度学习模型, 结构损伤识别准确率达到 94.48%。

关键词: 导波; 损伤识别; 迁移学习; 小样本

中图分类号: V219

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2023.05.007

航空结构中的裂纹、腐蚀、脱层以及其他损伤会造成航空结构完整性和安全性的下降, 对航空结构健康状态进行监测是确保航空结构性能安全可靠的必要手段。结构健康监测 (SHM) 技术^[1-3] 利用集成在结构中的先进传感器网络, 能够实时监测结构健康状态, 提高航空结构的安全性, 降低维护成本。导波因其传播距离长、对小损伤敏感和区域监测等特点, 作为结构健康监测的一种手段已经存在很长一段时间。为了能够及时准确地发现结构中的损伤, 国内外对基于导波的结构损伤识别方法都开展了大量的研究^[4-7]。

目前, 最常见的基于导波的损伤识别分析方法是根据结构损伤出现前后的导波信号特征, 计算损伤指数 (damage index, DI), 并与损伤阈值比较来判断结构是否出现损伤。然而, 由于受结构构型、边界条件和环境温度等因素的影响, 由专家经验确定的损伤阈值的可靠性较差。

人工智能^[8] 算法可以很好地解决上述基于导波的损伤识别方法对专家经验严重依赖的问题。在缺乏准确的物理模型或出现复杂非线性现象的情况下, 人工智能算法通过构建合适的模型能够自动地从导波数据中学习得到与结构

损伤相关的信息, 并对结构是否存在损伤做出判断。Lamorte 等^[9] 提出了基于隐马尔可夫模型的结构损伤评估方法, 通过使用基于 HMM 的未加权移动平均趋势估计方法来实现结构损伤的概率估计。Xu 等^[10] 利用卷积神经网络从导波数据的多个损伤指数中再次提取高级特征, 并进行特征融合从而实现了对结构裂纹的评估。Chen 等^[11] 提出了一种基于卷积神经网络和微分小波谱图的结构疲劳裂纹评估框架。对基线导波信号和监测导波信号之间的差分时频谱图进行高斯小波变换, 并将处理后的数据作为卷积神经网络的输入来进行网络训练, 从而实现了对结构裂纹长度的评估。Zhang 等^[12] 提出了一种基于深度迁移学习的多任务集成健康监测方法, 实现了板结构中损伤监测任务的迁移。

虽然以上研究都取得了很好的效果, 但在工程应用中存在两个关键性障碍: (1) 数据量不足, 在实际工程中很难获得大量真实的损伤数据; (2) 材料、结构分散性较强, 直接训练的模型在新试验件上的泛化效果较差。

针对以上问题, 本文提出了一种符合工程实际情况和

收稿日期: 2023-01-04; 退修日期: 2023-03-12; 录用日期: 2023-04-10

引用格式: Li Jiaxin, Lyu Shuashuai, Yang Yu, et al. Research on structure damage identification method based on guided wave and knowledge transfer[J]. Aeronautical Science & Technology, 2023, 34(05): 54-60. 李嘉欣, 吕帅帅, 杨宇, 等. 基于导波和知识迁移的结构损伤识别方法研究[J]. 航空科学技术, 2023, 34(05): 54-60.

应用需求的损伤识别模型 PRED_RF, 即利用迁移学习将在模拟损伤数据上学习到的损伤特征知识应用于真实结构的损伤识别。本文以典型航空金属结构为研究对象开展试验, 通过与传统机器学习和深度学习模型的损伤识别结果进行比较, 证明了 PRED_RF 模型在模型结构和参数相对简单的情况下, 仍可以达到优于其他模型的准确率, 验证了其可靠性和工程适用性。

1 损伤识别模型设计

迁移学习 (transfer learning, TL)^[13-14] 是数据科学界一种强大的研究方法, 通过迁移已学到相关任务的知识来改进新任务的学习过程, 特别适用于克服实际工程应用中小样本数据集的局限性。

对基于导波数据的结构损伤识别任务来说, 由于模拟损伤数据和真实损伤数据服从相似但不相同的分布, 直接利用模拟损伤数据训练人工智能模型会导致模型学习到的损伤知识与真实损伤之间有一些差别, 使模型在结构的真实损伤识别上表现较差。因此, 本文设计了一种适用于小样本导波数据的基于迁移学习的结构损伤识别模型 PRED_RF, 具体模型框架如图 1 所示。

PRED_RF 模型由迁移学习模块、特征增强模块和损伤识别模块三部分组成。首先利用专家知识对模拟损伤数据和真实损伤数据提取常用的损伤指数特征^[15-16], 将其作为迁移学习模块的输入数据。

迁移学习模块的主要作用是对真实损伤特征进行二次提取, 即先利用大量的模拟损伤特征训练迁移学习模块, 确定其参数, 然后再利用该参数对真实损伤特征进行预测, 获取真实损伤的二次特征。

特征增强模块主要是利用真实损伤的二次特征对真实损伤指数特征进行增强。最后利用增强后的真实损伤特征训练损伤识别模块, 使损伤识别模型具有对真实结构损伤进行识别的能力。

1.1 可迁移性分析

首先, 本文对模型损伤数据和真实损伤数据的可迁移性进行分析, 从理论上对模型的可行性进行验证, 也为后续模型的选择和设计提供依据。最大均值差异 (maximum mean discrepancy, MMD)^[17] 是一种对两个服从不同分布的数据集进行定量分析的方法。其通常在迁移学习中被用来进行源域数据和目标域数据的可迁移性分析, MMD 距离越小, 说明两个数据集之间的分布相似性和可迁移性越高。MMD 的计算公式如式 (1) 所示

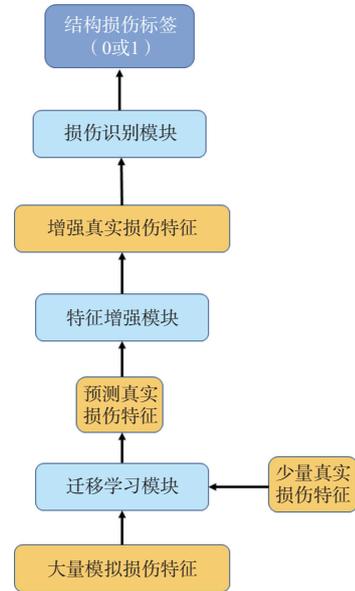


图 1 基于迁移学习的损伤识别模型 PRED_RF
Fig.1 Transfer learning based damage detection model PRED_RF

$$\text{MMD}(X_s, X_t) = \left\| \frac{1}{|X_s|} \sum_{x_s \in X_s} \varnothing(x_s) - \frac{1}{|X_t|} \sum_{x_t \in X_t} \varnothing(x_t) \right\| \quad (1)$$

式中, X_s 为源域数据集, X_t 为目标域数据集, $\varnothing(\cdot)$ 表示对数据进行操作。

为了评估模拟损伤数据与真实损伤数据之间的迁移难度, 本文将模拟损伤数据作为源域数据, 真实损伤数据作为目标域数据, 分别计算出原始导波信号的 MMD 距离为 4.6, 利用专家知识提取的损伤指数特征的 MMD 距离为 1.5。从 MMD 距离计算结果可以看出, 模拟损伤特征和真实损伤特征之间的可迁移性更强。图 2 为模拟损伤数据和真实损伤数据的损伤指数特征可视化图, 图中蓝色代表真实无损伤数据, 红色代表真实有损伤数据, 绿色代表模拟无损伤数据, 紫色代表模拟有损伤数据。从图 2 可以看出, 模拟有损伤特征和模拟无损伤特征以及真实有损伤特征和真实无损伤特征在特征空间可以区分开, 说明模拟损伤和真实损伤存在可以迁移的共性特征。因此, 本文选择模拟损伤数据的损伤指数特征作为 PRED_RF 模型的源域数据, 真实损伤数据的损伤指数特征作为 PRED_RF 模型的目标域数据。

1.2 基于迁移学习的损伤识别模型

基于特征的迁移学习算法的核心是通过构建新的编码特征空间来纠正模拟损伤特征 (源域) 分布和真实损伤特征 (目标域) 分布之间的差异, 然后在这个编码特征空间中

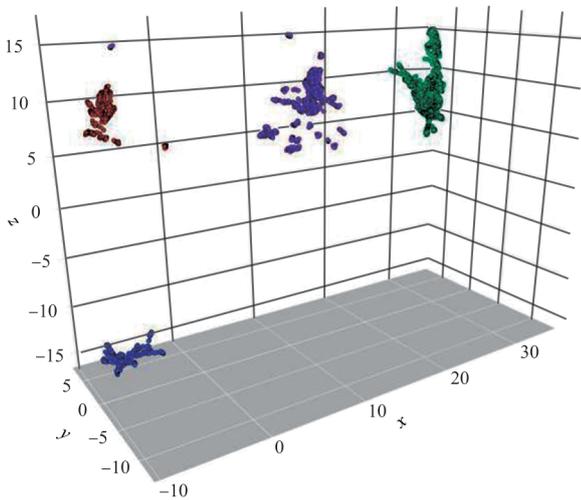


图2 模拟损伤特征和真实损伤特征可视化

Fig.2 Visualization of simulated damage features and real damage features

习结构损伤的相关知识。通常需要利用神经网络进行多次迭代才能构建出有效的编码特征空间。为了满足实际工程对结构损伤识别模型简单、高效和可靠的要求,避免大量运算带来的时间成本和硬件成本,本文利用 PRED (feature augmentation with sronly prediction)^[18]算法的基本原理,将复杂的域自适应问题转化成简单的监督学习,通过模拟损伤特征训练的迁移学习模型对真实损伤特征的特征空间进行增强,并将增强后的真实损伤特征作为损伤识别模型的输入进行模型训练。

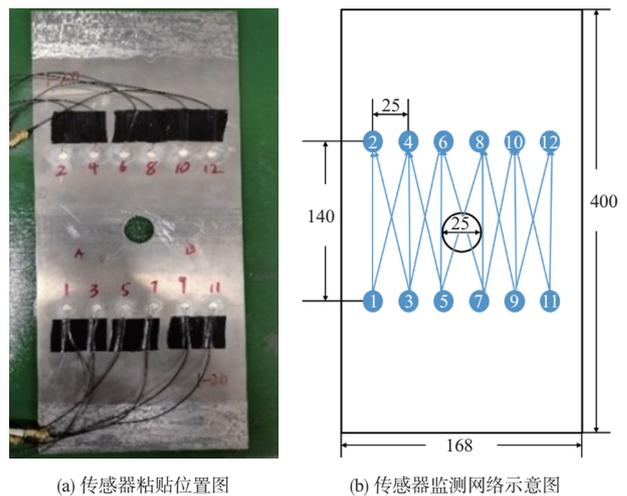
本文以 PRED 算法为基本架构,使用随机森林 (random forest, RF)^[19]模型同时作为迁移学习模型和损伤识别模型的模型结构,引入特征增强方法,设计了基于知识迁移的 PRED_RF 模型。模型具体计算流程为:在迁移学习阶段,首先利用模拟损伤特征训练一个随机森林模型作为迁移学习模型,然后将真实损伤特征输入迁移学习模型中进行预测。在特征增强阶段,将迁移学习阶段得到的预测损伤特征变换成与真实损伤特征一致的数据格式,利用特征增强方法在特征空间对真实损伤特征和预测损伤特征进行拼接。在损伤识别阶段,将增强后的真实损伤特征作为一个新的随机森林模型的输入进行模型训练,训练好的随机森林模型作为最终的损伤识别模型并用于真实结构的损伤识别。

2 试验设计

2.1 导波数据采集

本文开展基于导波数据的开孔板结构损伤识别的多种

方法对比研究试验。试验件为铝合金开孔板,长为 400mm,宽为 168mm,孔直径为 25mm,在试验件表面一共粘贴 12 个压电传感器。开孔板尺寸和压电传感器粘贴位置及传感器编号示意图如图 3 所示。奇数编号的传感器作为信号激励器,偶数编号的传感器作为信号接收器,每个激励传感器与它相邻的接收传感器组成监测路径,一共形成 16 条监测路径。采用压电多通道监测系统对导波数据的采集,导波激励信号为频率范围为 150kHz 到 270kHz 的五波峰正弦信号,增益为 15dB,采样频率为 24MHz,采样点长度为 4000。



(a) 传感器粘贴位置图

(b) 传感器监测网络示意图

图3 开孔板结构(单位:mm)

Fig.3 Perforated plate structure (unit:mm)

在实际工程应用中,导波监测方法主要面临两个方面的困难:(1)由于材料分散性,即使在构型相同的试验件上存在大小、位置均相同的损伤,其导波信号也存在较大差异,即试验件信号的个体差异强;(2)实际工程中,很难获取待监测对象的真实损伤信号。因此,针对以上问题,本文采用疲劳试验和粘贴质量块两种方式采集了多个试验件的真实损伤数据和模拟损伤数据。利用质量块模拟损伤是由于其在一定程度上可以反映导波信号在单个试验件上的信号特点,并且在工程中容易实施,为本文方法的工程应用提供基础;采用多个试验件的目的是增加数据数量,在考虑材料分散性的情况下,提高数据对损伤识别函数分布描述的准确性。

真实导波数据采集的具体方法为:对开孔板进行疲劳拉伸试验。试验开始时,设定试验载荷大小为 4.5~45kN,频率为 10Hz,在 3 万次循环后,将试验载荷大小改为 4~40kN,频率改为 8Hz,直至开孔板断裂,每次测量真实导波数据时的载荷大小为 3kN。一共采集 9 个开孔板的真实导波数据。

模拟损伤数据采集的具体方法为:在开孔板表面未粘

贴质量块时,采集无损伤的模拟数据。由于裂纹从开孔板孔边两侧开始萌生扩展,所以采取在开孔板孔边两侧粘贴质量块的方式来采集模拟损伤数据。通过改变质量块的面积大小和在孔边的粘贴位置,来采集不同长度裂纹的模拟损伤数据。一共采集4个开孔板的模拟损伤数据。

2.2 导波信号特征提取

基于导波的结构损伤监测主要是通过对由损伤引起的损伤散射信号进行识别来实现的。通过将每条监测路径上的初始基准信号和过程监测信号相减得到散射信号,根据散射信号就可以判断结构有无损伤。通过对不同频率下的原始导波信号的稳定性进行分析,选择频率170kHz和190kHz下采集的导波信号。通常导波信号会受到直达波和串扰信号的干扰,本文针对每条导波信号选择第500~2500的采样点数据作为后续分析的导波信号。由于裂纹是从开孔板孔边开始出现的,为了解决单一监测路径对结构损伤识别可靠性不高的问题,本文选择开孔板孔边的4条监测路径(5-6,5-8,7-6,7-8)组成一个样本数据来进行损伤识别。

针对每一条导波信号,本文提取了20个损伤指数特征。最终,一条样本数据为由开孔板孔边4条监测路径组成的监测网络在频率170kHz和190kHz下采集得到的导波信号求取20个DI特征后合并在一起的数据。一条样本数据为长度为160的一维数据。真实导波特征和模拟导波特征的无损数据和有损数据分布见表1。

表1 真实导波特征和模拟导波特征的数据分布

Table 1 Data distribution of real guided wave features and simulated guided wave features

导波特征	无损	有损	合计
真实导波特征	38	170	208
模拟导波特征	278	750	1028
合计	316	920	1236

3 结果分析

本文选择了6种常用的机器学习模型,两种适合处理时序数据的深度学习模型,以及PRED_RF模型,利用模拟导波特征和真实导波特征进行开孔板的结构损伤识别,通过准确率、模型训练测试时间和硬件要求多个维度对各个模型进行综合评价。

如表2所示,机器学习模型和深度学习模型都以全部模拟导波特征作为训练集来训练模型,全部真实导波特征作为测试集测试模型性能。迁移学习模型则是以全部模拟

导波特征作为源域数据,一个开孔板的真实导波特征作为目标域数据对模型进行训练,剩余开孔板的真实导波特征作为测试集测试模型性能。机器学习模型和迁移学习模型都是在CPU(Intel i7-10700K)上进行模型训练和测试,深度学习模型则是使用GPU(NVIDIA GeForce RTX 3070)进行模型训练和测试。分别计算每个模型在测试集上的f1分数和准确率。通常,一般使用准确率来评价模型的性能效果。但由于导波特征数据集中无损伤数据要明显少于有损伤数据,数据类别存在偏斜,而f1分数是召回率和精确度的加权平均,也适用于评价模型的效果。

表2 导波特征的模型训练集和模型测试集划分

Table 2 Model training dataset and model test dataset division of guided wave features

模型	训练集	测试集
机器学习	4个开孔板的模拟导波特征	9个开孔板的真实导波特征
深度学习	4个开孔板的模拟导波特征	9个开孔板的真实导波特征
迁移学习	4个开孔板的模拟导波特征+ 1个开孔板的真实导波特征	8个开孔板的真实导波特征

如表3所示,在所有模型中,迁移学习模型PRED_RF在测试集上的效果最好,准确率达到了94.48%,f1分数达到了94.35%。在机器学习模型中,模型测试准确率最高的是K近邻模型,达到了87.02%。模型测试f1分数最高的是逻辑回归,达到了71.14%。在深度学习模型中,模型测试准确率和f1分数最高的均为门控循环单元网络,准确率为92.79%,f1分数为92.59%。对机器学习模型和深度学习模型的试验结果进行分析,可以看出,在只使用模拟导波特征训练模型的情况下,机器学习模型和深度学习模型在真实导波特征上都可以达到一定的测试准确率,其证明了模拟损伤数据和真实损伤数据之间存在一定的相关性和可迁移性,为使用迁移学习进行结构损伤识别提供了依据和模型基础。

同时值得注意的是,在不使用迁移学习模型的情况下,随机森林模型在测试集上的准确率为69.71%。引入PRED迁移模块后,测试集的准确率提高了25%左右,说明利用大量模拟损伤数据和少量真实损伤数据训练得到的模型在真实损伤数据测试集上具有较高的准确率,证明了迁移学习模型能够有效提取出模拟损伤数据和真实损伤数据有关损伤的共性特征,降低环境噪声和结构分散性的影响。

为了验证PRED_RF模型的泛化能力,本文通过分别选择不同开孔板的真实导波特征作为目标域数据进行模型训练,再在其他开孔板的真实导波特征上进行测试,具体测试

表3 模型在测试集上的测试结果

Table 3 Result of machine learning models on test dataset

模型分类	模型名称	f1分数	准确率
机器学习模型	K近邻	0.6983	0.8702
	随机森林	0.5569	0.6971
	逻辑回归	0.7114	0.8173
	决策树	0.4922	0.5673
	梯度提升树	0.4196	0.4712
	极致梯度提升	0.6836	0.8269
深度学习模型	长短期记忆网络	0.9099	0.9183
	门控循环单元	0.9259	0.9279
迁移学习模型	PRED_RF	0.9435	0.9448

结果见表4。经过交叉验证,PRED_RF模型的准确率和f1分数均接近90%,具有较好的泛化能力。试验证明了利用迁移学习使用模拟损伤数据训练模型并应用于真实损伤数据的损伤识别能够达到较高的准确率和可靠性,既可以解决模型训练需要大量真实损伤数据的问题,也可以解决由不同材料和结构件之间的差异造成模型泛化能力差的问题,是一种非常具有工程应用前景的方法。

表4 PRED_RF模型交叉验证测试结果

Table 4 Cross validation result of PRED_RF model

目标域真实导波特征	f1分数	准确率
1号开孔板导波特征	0.9292	0.9305
2号开孔板导波特征	0.8016	0.8462
3号开孔板导波特征	0.9299	0.9319
4号开孔板导波特征	0.9448	0.9448
5号开孔板导波特征	0.9214	0.9243
6号开孔板导波特征	0.9302	0.929
7号开孔板导波特征	0.9085	0.9037
8号开孔板导波特征	0.8471	0.8305
9号开孔板导波特征	0.8493	0.8325
平均值	0.8896	0.8911

在实际的工程应用中,运行效率也是考核模型性能的一个重要指标。表5为随机森林模型、门控循环单元网络和PRED_RF模型分别进行模型训练和模型测试所花费的时间,其中PRED_RF模型的训练时间和测试时间为交叉验证后的平均时间。由表5可以看出,随机森林模型的训练时间和测试时间均是最短的。这是由于随机森林模型相较于其他模型,模型结构最为简单且模型参数最少。PRED_RF模型结构由两个随机森林模型加一个特征增强模块构成,模型训练时间与单个随机森林模型训练时间处于同一量级,模型测试时间大约为单个随机森林模型的两倍。但相较于门控循环单元网络,PRED_RF模型的训练和测试所需时间明显较短,符合实际工程对结构损伤识别模

表5 随机森林模型、门控循环单元网络和PRED_RF模型的模型训练和模型测试时间

Table 5 Model training time and test time of random forest, GRU network and PRED_RF model

模型	硬件要求	模型训练时间/s	模型测试时间/s
随机森林	CPU	0.2074	0.008
门控循环单元	GPU	13.8536	0.4269
PRED_RF	CPU	0.2953	0.0153

型快速高效的要求。

4 结论

通过研究,可以得出以下结论:

(1)本文针对实际航空结构健康监测中结构损伤识别所面临的真实损伤数据量不足,以及由于材料和结构之间的分散性强导致的模型泛化能力差等问题,提出了使用迁移学习方法实现利用大量模拟损伤数据训练模型学习得到损伤相关知识,并将学习到的知识迁移到真实损伤数据上来进行结构损伤识别的思路,设计了适用于实际工程和小样本导波数据的损伤识别模型PRED_RF。在本文试验中,利用质量块模拟损伤数据和少量真实损伤数据对PRED_RF模型进行训练,再对模型在真实损伤数据上的测试效果进行验证,模型的准确率达到94.48%,证明了迁移学习在结构损伤识别应用中的可靠性和可行性。

(2)本文针对基于导波的结构损伤识别开展了多种人工智能模型的对比评估研究。从模型测试准确率、模型训练和测试时间以及对硬件的要求三个方面,对各个模型进行了综合评价。从准确率来看,PRED_RF模型在测试集的效果最好,达到了94.48%。从模型训练和测试时间来看,机器学习模型和PRED_RF模型所需的时间都比较短。从硬件要求来看,机器学习模型和PRED_RF模型都只需要CPU。

(3)本文提出的结构损伤识别模型PRED_RF的算法逻辑和模型结构都比较简单,在开孔板结构的损伤识别试验中的准确率也优于传统的机器学习和深度学习模型,通过交叉验证试验对模型的泛化能力也进行了验证。PRED_RF模型满足实际工程对损伤识别模型高效、可靠和简单的要求,具有良好的工程应用前景。

AST

参考文献

[1] 卿新林,王奕首,赵琳. 结构健康监测技术及其在航空航天领域中的应用[J]. 实验力学, 2012, 27(5): 517-526.

Qing Xinlin, Wang Yishou, Zhao Lin. Structural health monitoring technology and its application in aeronautics and

- astronautics[J]. Journal of Experimental Mechanicals, 2012, 27(5): 517-526. (in Chinese)
- [2] 袁慎芳. 结构健康监控[M]. 北京:国防工业出版社,2007.
Yuan Shenfang. Structural health monitoring and damage control[M]. Beijing: National Defense Industry Press, 2007. (in Chinese)
- [3] 王彬文,肖迎春,白生宝,等. 飞机结构健康监测与管理技术研究进展和展望[J]. 航空制造技术,2022,65(3): 30-41.
Wang Binwen, Xiao Yingchun, Bai Shengbao, et al. Research progress and prospect of aircraft structural health monitoring and management technology[J]. Aeronautical Manufacturing Technology, 2022, 65(3): 30-41. (in Chinese)
- [4] Ihn J B, Chang F K. Detection and monitoring of hidden fatigue crack growth using a built-in piezoelectric sensor/actuator network: Diagnostics[J]. Smart Material Structures, 2004, 13(3): 609-620.
- [5] 邱雷. 基于压电阵列的飞机结构监测与管理系统研究[D]. 南京:南京航空航天大学,2011.
Qiu Lei. Research on the piezoelectric sensors array based aircraft structural health monitoring and management system [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2011. (in Chinese)
- [6] 杨宇,王彬文,吕帅帅,等. 一种基于深度学习的复合材料结构损伤导波监测方法[J]. 航空科学技术, 2020, 31(7): 102-108.
Yang Yu, Wang Binwen, Lyu Shuaishuai, et al. A deep-learning-based method for damage identification of composite laminates [J]. Aeronautical Science & Technology, 2020, 31(7): 102-108. (in Chinese)
- [7] 邢博邯,蔡建,周智权,等. 航空结构中Lamb波小损伤监测能力研究[J]. 航空科学技术,2021,32(3): 40-48.
Xing Bohan, Cai Jian, Zhou Zhiquan, et al. Research on small-damage monitoring abilities of Lamb waves in aircraft structures [J]. Aeronautical Science & Technology, 2021, 32(3): 40-48. (in Chinese)
- [8] Stuart J R, Peter N. 人工智能:一种现代的方法[M].3版.北京:清华大学出版社,2013.
Stuart J R, Peter N. Artificial intelligence: a modern approach [M].3rd. Beijing: Tsinghua University Press, 2013. (in Chinese)
- [9] Mei H, Yuan S, Qiu L, et al. Damage evaluation by a guided wave-hidden Markov model based method[J]. Smart Materials and Structures, 2016, 25(2): 25021.
- [10] Xu L, Yuan S, Chen J, et al. Guided wave-convolutional neural network based fatigue crack diagnosis of aircraft structures[J]. Sensors, 2019, 19(16): 3567.
- [11] Chen J, Wu W, Ren Y, et al. Fatigue crack evaluation with the guided wave-convolutional neural network ensemble and differential wavelet spectrogram[J]. Sensors, 2021, 22(1): 307.
- [12] Zhang B, Hong X, Liu Y. Multi-task deep transfer learning method for guided wave-based integrated health monitoring using piezoelectric transducers[J]. IEEE Sensors Journal, 2020, 20(23): 14391-14400.
- [13] Pan S J, Qiang Y. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [14] Li W, Huang R, Li J, 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.
- [15] Torkamani S, Roy S, Barkey M E, et al. A novel damage index for damage identification using guided waves with application in laminated composites[J]. Smart Materials and Structures, 2014, 23(9): 95015.
- [16] Wu Z, Liu K, Wang Y, et al. Validation and evaluation of damage identification using probability-based diagnostic imaging on a stiffened composite panel[J]. Journal of Intelligent Material Systems and Structures, 2015, 26(16): 2181-2195.
- [17] Uguroglu S, Carbonell J. Feature selection for transfer learning [C].Machine Learning and Knowledge Discovery in Databases: European Conference, ECML PKDD 2011, 2011: 430-442.
- [18] Daumé H. Frustratingly easy domain adaptation[C]//Proceedings of the 45th Annual Meeting of the Association of Computational Linguistics, 2007: 256-263.
- [19] Breiman L. Random forests[J]. Machine Learning, 2001, 45: 5-32.

Research on Structure Damage Identification Method Based on Guided Wave and Knowledge Transfer

Li Jiaxin¹, Lyu Shuaishuai¹, Yang Yu¹, Zhang Tengfei², Zhang Guigang², Li Boyan³

1. *National Key Laboratory of Strength and Structural Integrity, Aircraft Strength Research Institute, Xi'an 710065, China*

2. *Institute of Automation Chinese Academy of Sciences, Beijing 100190, China*

3. *Beijing Institute of Technology, Beijing 100089, China*

Abstract: The damage diagnosis method based on guided wave has a good engineering application prospect in the field of aeronautical structural health monitoring. However, due to the complexity of structure form and the determination of the structural damage identification threshold based on expert knowledge, it still faces great challenges in improving the accuracy and reliability of damage diagnosis. Artificial intelligence method can reduce the dependence on prior knowledge, but it requires a lot of data, which cannot be borne in practical engineering. Therefore, this paper proposes an approach of using simulated physical damage to generate a large amount of data, and then combining a small amount of real damage data for structural damage identification. Based on the transfer learning algorithm, this paper design a structural damage identification model PRED_RF which is suitable for practical engineering application. The experimental result shows that, with limited amount of data, the PRED_RF model is significantly better than other traditional machine learning and deep learning models in terms of structural damage identification accuracy, and accuracy reaches 94.48% on test dataset.

Key Words: guided wave; damage identification; transfer learning; small sample