

一种基于深度学习的复合材料结构损伤导波监测方法



杨宇^{1,*}, 王彬文¹, 吕帅帅¹, 周雨熙², 王莉¹, 刘国强¹

1. 中国飞机强度研究所, 陕西 西安 710076

2. 北京大学, 北京 100871

摘要:碳纤维增强复合材料层压板已经广泛应用于飞机的主承力结构。然而,层间分层作为一种最常见的损伤形式,严重影响层压板的力学性能和结构安全。人们利用导波在层压板中的传播特性开展结构损伤监测,其核心是对比分析损伤前后导波信号,根据信号变化特征量化计算损伤指数,并将其与损伤阈值进行比较,从而进行损伤判定。该方法对专家经验依赖严重,并且泛化能力较弱。本文利用深度学习理论,提出了一种基于分布式时序卷积神经网络的损伤识别模型。该模型能够较好地解决深度学习方法在处理结构健康监测问题所面临的困难,包括数据样本量不足、数据偏斜严重以及数据长度不一致等。另外,该方法创新性地应用LSTM模块,对监测数据中各个数据片段特征进行关联。该深度学习模型增强了从原始导波信号进行损伤特征提取的能力,从而减轻对专家经验的过度依赖,并通过测试表明具有较高的损伤识别精度。

关键词:复合材料; 损伤识别; 导波; 卷积神经网络

中图分类号: V219

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2020.07.014

由于具有比强度/比刚度高、性能可设计和易于整体成形等诸多优异性能,近年来碳纤维增强复合材料层压板(CFRP)已经被用于飞机主承力结构^[1]。然而,由于缺陷或冲击造成的分层是CFRP最主要的一种损伤形式^[2-3],严重削弱其力学性能,影响结构安全,为了在飞机结构中能够及时发现损伤,人们开发了一种基于导波^[4-6]的结构损伤监测方法。导波是横波和纵波在薄壁结构中经上下表面不断反射相互耦合后形成的一种弹性波^[7-8],基于导波的结构损伤监测原理为:导波在结构中传播时,当其遇到结构边界或损伤(如内部分层、界面脱黏等)时,其会产生边界反射信号或损伤散射信号。通过采用合适的信号分析方法^[9],提取出由疑似损伤引起的损伤散射信号,并对其进行时域、频域等^[10-11]分析处理,最终获得损伤有无、位置和程度等信息,从而达到对结构损伤进行监测的目的。

基于导波的结构损伤监测,目前广泛采用的做法是对比分析损伤前后的导波信号特征,采用相应算法计算损伤指数,并根据损伤阈值判别^[12-13]损伤。例如,现在比较通用的有12种损伤指数计算公式^[10-11],每种公式都是导波信号

部分特征(如幅值、能量等)组合的数学表达式。然而,运用损伤指数来进行损伤识别,通常会遇到如下困难:众多的底层信号特征(如幅值、能量)受各种环境因素(如温度、载荷等)影响大,很难建立起个别底层信号特征与损伤的明确对应关系;由多个底层特征组合起来形成高层的抽象特征(如损伤指数),从而建立与结构损伤的对应关系,对专家经验依赖严重;针对情况A设定的损伤指数阈值(阈值)在情况B下常常不适用,即专家经验的迁移和泛化能力较弱^[14]。

机器学习是解决此类问题一个强有力的工具,很多研究人员利用机器学习手段开展了基于导波的结构损伤识别^[15-17]与定位研究^[18-20]。特别是近年来在神经网络研究领域取得的突破性进展,推动深度学习技术正在成为一种潜力巨大的解决方案而备受关注。但是,在结构健康监测领域使用深度学习方法,会面临诸多的限制和挑战:(1)供神经网络训练的样本数量严重不足。开展健康监测的结构通常都是重要而且昂贵的大型结构,样本数量极其有限。目前的一种解决方式是通过数值仿真产生大量的虚拟数据样本^[14],但是这对模型的仿真程度提出了很高的要求,而且产

收稿日期: 2020-04-17; 退修日期: 2020-06-01; 录用日期: 2020-06-10

*通信作者. Tel.: 029-88268013 E-mail: yangyu@cae.ac.cn

引用格式: 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(07): 102-108. 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(07): 102-108.

生的样本数量依然有限。例如^[15],通过有限元模型参数化建模的方式,在250mm×350mm的准各向同性复合材料层压板生成了516条虚拟数据。(2)数据偏斜情况严重。结构无损伤状态的数据量通常远大于损伤状态的数据量,使得神经网络容易偏向于对无损伤状态的判定。(3)在实际工程应用中,监测数据采样点数(数据长度)没有统一标准,而卷积神经网络(CNN)等深度学习模型要求输入数据长度一致。目前常用的处理方法包括填充技术和序列缩短技术,但是对深度学习模型的影响较大。例如,填充技术会导致吞吐量降低、训练期间收敛速度减慢^[21]和过长数据导致的梯度消失^[22]等问题;序列缩短技术对离散信号进行裁剪或者降低连续信号中的采样率,可能会导致样本中重要信息的丢失^[22-23];而分组处理技术不改变原始信号,因而不会对其信息造成任何损失或失真,但是,由于记录长度的分布极不均匀,一个组可能只包含一个或两个记录,导致批量大小的变化很大,且深度学习模型在接收到长度未知的记录时,其分类预测存在一定的不确定性^[21]。

针对以上问题,本文以复合材料结构冲击损伤识别为目标,提出了基于偏斜感知的数据增强方法,构建了分布式时序神经网络模型(temporal distributed convolutional neural network, TDCNN)^[24]。其中,数据增强的作用是在考虑数据偏斜影响因素的情况下,增加数据样本数量,并统一数据长度;TDCNN则是针对导波信号的特点,综合考虑监测数据整体趋势特征和其中各个数据片段的局部特征,从而提升结构损伤识别准确率。

1 物理试验

1.1 基于导波的结构损伤监测原理

基于导波的结构损伤监测主要是通过通过对由损伤引起的损伤散射信号识别来实现的。在结构上布置压电片网络,如图1(a)所示。由于其压电效应,压电片既可以作为信号激发器,也可以作为信号接收器。当作为激发器时,在电信号激励下,压电片振动激发导波在结构中传播;当作为接收器时,将接收到的导波信号转换为电信号以供存储分析。任意两个压电片构成一条监测路径。通过轮换每个压电片的信号激发和接收功能,使结构上所有压电片构成一个监测网络,如图1(b)所示。通过对比分析每条路径上的初始基准信号(baseline signal)和过程监测信号(monitored signal),实现损伤识别功能。

1.2 碳纤维增强复合材料加筋板冲击损伤模拟试验

该加筋板采用CCF300/BA9916碳纤维增强复合材料,




图1 压电传感器结构网络布置示意图

Fig.1 Schematic configuration of PZT sensor network

其几何尺寸和压电传感器网络布置如图2所示。根据此网络,共形成28条监测路径。由于此加筋板只有一件,无法满足成千上万的冲击试验要求,因此在试验件表面粘贴M16的钢制螺栓来模拟损伤^[11]的方法。通过在不同位置粘贴螺栓,并且采集粘贴前后的信号分别作为初始基准信号和监测信号。另外,也对未粘贴螺栓的加筋板进行了信号采集,为“无损伤”事件提供监测信号特征。




图2 加筋板尺寸和传感器位置的示意图

Fig.2 Schematic demonstration of stiffen panel and sensor network

在深度学习方法中,需要对每一条监测数据进行损伤状态(有损伤/无损伤)标记,作为深度学习模型训练和测试的依据。这里使用损伤指数阈值(damage index, DI)为数据作标记。目前,比较常用的损伤指数有12种^[10-11]。根据多

次采集得到的加筋板“无损伤”事件(即没有黏结螺栓,跟损伤完全无关)的监测信号,计算其SDCC值,求平均值并乘以4,作为损伤指数阈值。在“有损伤”事件(即黏结了螺栓)中,凡是其监测信号SDCC值大于该阈值的,标记为“有损伤”;对于剩下的监测信号和所有“无损伤”事件的监测信号,全部标记为“无损伤”。使用该方法,共收集到对793条监测数据进行了分类,其具体构成形式见表1。监测数据的SDCC值分部如图3所示。可以看见有三个监测数据的SDCC值偏高。如果将其隐藏,则得到如图4所示的监测数据SDCC分布情况。可以看见,“有损伤”与“无损伤”标记的数据之间,有比较清晰的界限。

表1 复合材料加筋板模拟损伤监测数据构成分布
Table 1 Distribution of simulated damage monitoring data of composite stiffened plate

类型	数据长度			合计
	8000	6000	5000	
有损伤	20	35	215	270
无损伤	36	100	387	523
有损伤占比/%	0.36	0.26	0.36	0.34




图3 复合材料加筋板模拟损伤监测数据的SDCC值分布
Fig.3 SDCC value distribution of composite stiffened plate simulation damage monitoring data




图4 隐藏SDCC值偏高的零星数据点后的SDCC分布情况
Fig.4 SDCC distribution after hiding scattered data points with high SDCC value

2 深度学习模型

2.1 基于偏斜感知的数据增强

使用基于人工神经网络的深度学习方法来处理从实际应用中采集的导波监测数据,通常会遇到如下问题。

(1) 样本数量严重不足

在本文中,利用螺栓粘贴的方式模拟损伤,在加筋板上产生监测数据793条。距离深度学习通常所需的样本数量差距甚远。因此,需要通过其他手段来减轻样本数量不足所带来的负面影响。

(2) 数据偏斜情况严重

在真实的工程应用中,与损伤相关的监测数据量远远小于无损伤监测数据量。在本文中,虽然产生的793条监测数据都与损伤相关,但是为了提高损伤识别的准确率,降低监测误报率,也必须定义监测路径与冲击损伤中心点非常靠近的监测数据为含损伤的监测数据。在这种情况下,训练后的深度学习模型容易产生偏向于对无损伤状态的判定。

(3) 数据长度不一致

在实际工程应用中,对监测数据采样点数(数据长度)没有统一标准。由于卷积神经网络(CNN)等深度学习模型要求输入数据长度一致,因此需要设计模块,对监测数据进行预处理。

综合以上问题,本文设计了基于偏斜感知的数据增强模块,其数据处理方式如下:

(1)对于数据长度(采样点个数)少于标准长度(在本文中,标准长度设为3000个采样点)的数据,通过补充一些无意义的量使其采样点数量达到标准值。

(2)对于数据长度大于标准长度的数据,使用式(1)定义滑动窗口步长 stride_{C_i} ,对数据进行截取,如图5所示。

$$\text{stride}_{C_i} = \left\lceil \text{MS} \times \frac{|\text{samples labeled } C_i|}{\max_{j=1}^m |\text{samples labeled } C_j|} \right\rceil \quad (1)$$

式中:MS为最大步长阈值。该参数为超参数,经验取值范围为50~300。在本文中取值为100;C为类别标签集合,




图5 使用滑动窗口步长对原始数据进行截取示意图
Fig.5 Schematic diagram of using sliding window step to intercept the original data

$C = [C_1, C_2, \dots, C_m]$, 表示有 m 个类别。在本文中, 只有无损伤与有损伤两个类别, 因此标签集合为 $C = [C_1, C_2] = [\text{有损伤}, \text{无损伤}]$ 。绝对值表示为具有该标签数据的数量。使用式(1), 即可得到增强后的数据共计 28230 条。其中, 标记为“有损伤”的数据 15240 条, 占比为 54%。

2.2 分布时序卷积神经网络

在本文中, 构建了分布时序卷积神经网络, 其网络基本架构如图 6 中虚线框所示。“分布”指的是将一条数据段分割成 10 个数据片段, 然后分别使用 CNN 模型通过共享权值的方式来提取局部特征; “时序”指的是在基于“分布”式特征提取之后, 创新性地使用 RNN 中的 LSTM 模块, 将这 10 个片段上提取到的局部特征进行拼接成特征矢量, 从而进行时序趋势特征的提取。

具体来讲, 该网络包含一个 6 层卷积神经网络, 它以每个数据的短片段作为输入。每个卷积层有 128 个长度为 32 的过滤器。另外, 在每个卷积层之前采用批量化预激活模块来设计和修正线性激活函数, 并在卷积层之间使用 Dropout 技术^[25]和 Adam 技术^[26]分别用来避免过度拟合以及优化神经网络, 从而提高模型的泛化能力。然后, 使用双向的长短期记忆网络 (BI-LSTM) 来将每个数据短片段中提取出的局部特征整合成整体趋势特征, 并连接一个全连接层和 Softmax 层作为神经网络的预测输出。

最后, 在经过 TDCNN 模型得到针对每个数据段的损伤识别结果后, 通过投票的方式, 来得到这一条完整数据的损伤识别结果。在本文中, 投票方式采用了简单的票数计票方式, 而没有对票赋予不同的权值。




图6 基于TDCNN的结构损伤识别模型工作流程

Fig.6 Work flow of TDCNN based structural damage identification model

3 测试结果分析

在原有信号的基础上叠加模拟信号, 其叠加幅值不超过原有信号幅值的 30%, 从而产生用于测试的信号。本文一共产生了 330 条测试数据。模型效果的评估方面采用机器学习领域常用的三个模型性能评价指标 (准确率、召回率和 $F1$ 值) 进行评估, 如图 7 所示。

A 表示模型将实际标签为无损伤的数据识别为无损伤的实例, B 表示模型将实际标签为无损伤的数据识别为有损伤的实例, C 表示模型将实际标签为有损伤的数据识别为无损伤的实例, D 表示模型将实际标签为有损伤的数据识别为有损伤的实例, 所以对实际标签为无损伤的数据实例来说准确率 (查准率) 为 $A/(A+B)$, 召回率 (查全率) 为 $A/(A+C)$, $F1$ 值为准确率和召回率的加权平均值。准确率和召回率是相互影响的, 一般情况下模型准确率高了召回率就会变低, 召回率高准确率就低。但是通常希望模型不仅能识别准确, 还应该每类的所有实例都不要有识别遗漏 (即查全率高), 所以用 $F1$ 值来衡量模型的性能。其值越高, 性能越好。

本文同时采用了多种基于特征工程的机器学习方法和深度学习方法来进行对比分析。它们分别是最近邻 (k-nearest neighbor, KNN)^[27]、支撑向量机 (support vector machine, SVM)^[28]、高斯处理过程 (gaussian process, GP)、决策树 (decision tree, CvDTree)^[29]、神经网络 (neural networks, NN)^[14]、高斯朴素贝叶斯 (gaussian naive bayes, GNB)^[18]、二次判别分析 (quadratic discriminant analysis, QDA)^[30]、卷积神经网络 (convolutional neural network, CNN)^[31]、循环神经网络 (recurrent neural network, RNN)^[32], 采用分布式时序卷积神经网络方法的召回率、准确率、 $F1$ 值三方面评价指标




图7 模型性能评价指标示意图

Fig.7 Schematic of model performance evaluation index

均有大幅提升。该算法能够正确识别出测试集中所有有损伤的数据,召回率提高到 100%,识别准确率为 90.12%,总体 $F1$ 指标达到 86.21%(见表 2)。

表2 分布式时序卷积神经网络与各传统方法的试验效果对比
Table 2 Comparison of experimental results between TDCNN and other traditional methods

类型	方法	准确率	召回率	$F1$
机器学习方法	KNN	64.29%	57.69%	63.11%
	SVM	65.97%	50.00%	52.44%
	GP	39.50%	54.14%	28.11%
	CvDTree	74.50%	78.30%	73.89%
	NN	34.03%	50.00%	17.28%
	GNB	68.07%	53.09%	57.07%
	QDA	67.65%	52.47%	56.18%
深度学习方法	CNN	88.00%	76.54%	59.84%
	RNN	68.00%	62.50%	52.31%
	TDCNN	90.12%	100.00%	86.21%

试验验证结果表明,基于深度学习的模型性能普遍优于基于特征工程的机器学习模型,这主要是由于压电数据中噪声的存在与损伤指数计算提取中的若干限制,使得在利用传统的损伤指数分析方法对损伤特征进行提取时,不可避免地存在损伤特征维度缺失的现象。深度学习方法能够避免基于特征工程的机器学习方法所需的人工特征提取过程所带来的上述诸多弊端。

与其他多种深度学习方法相比,TDCNN 的召回率、准确率、 $F1$ 值三方面评价指标均有大幅提升。这主要得益于 TDCNN 能够自动集成和提取多视角的局部频域特征和整体时序趋势特征,从而对压电波形数据的频域特征和时域特征进行有效建模处理。这种组合型架构不仅可以对源源不断产生的超长时序数据进行学习,而且对数据的长度也不会进行限制,能够有效处理变长的压电数据。

但是,由于目前提供的数据量还不能满足深度学习模型的数据量要求,因此,虽然目前模型的准确率较高,但模型过拟合程度也同样较高,模型的泛化能力较差。需要进一步获取更多的训练数据,为工程化应用提供可靠的决策支持。

4 结论

通过分析,可以得出以下结论:

(1) 基于导波的复合材料结构损伤识别,本文提出了一种 TDCNN 模型。该模型能够较好地解决深度学习方法在处理结构健康监测问题所面临的困难,包括数据样本量不足、数据偏斜严重以及数据长度不一致等。另外,该模型

创新性的应用 LSTM 模块,对监测数据中各个数据片段特征进行关联。

(2) TDCNN 能够自动集成和提取导波监测信号的局部频域特征和反映整体趋势的时序特征,从而有效地对变长的流式数据进行建模处理并能有效预测其长期趋势,增强了从原始导波信号进行损伤特征提取的能力,从而减轻对专家经验的过度依赖。

(3) 通过在复合材料结构进行了损伤监测的验证试验,验证结果表明,TDCNN 能够正确识别出测试集中所有“有损伤”的数据,召回率提高到 100%,识别准确率为 90.12%,总体 $F1$ 指标达到 86.21%。但是,由于样本数量有限,存在过拟合现象,泛化能力较差。需要进一步获取更多的训练数据,来提高模型的工程化应用价值。

AST

参考文献

[1] 杜善义. 先进复合材料与航空航天 [J]. 复合材料学报, 2007, 24(1): 1-12.
Du Shanyi. Advanced composite materials and aerospace engineering[J]. Acta Materiae Compositae Sinica, 2007, 24(1): 1-12.(in Chinese)

[2] Talreja R, Singh C V. Damage and failure of composite materials [M]. Cambridge: Cambridge University Press, 2012.

[3] Ip K H, Mai Y W. Delamination detection in smart composite beams using Lamb waves [J]. Smart Materials & Structures, 2004, 13(3): 544.

[4] Osmont D L, Dupont M, Lemistre M B, et al. Damage and damaging impact monitoring by PZT sensor-based HUMS[C]// Proceedings of Spie the International Society for Optical, 2000.

[5] 郭永跃. 基于压电晶片阵列的复合材料层合板损伤检测研究 [D]. 哈尔滨: 哈尔滨工业大学, 2016.
Guo Yongyue. Research on damage identification for composite laminates with piezoelectric wafer active sensors array[D]. Harbin: Harbin Institute of Technology, 2016.(in Chinese)

[6] 王利恒. 复合材料飞机结构健康监测系统的若干问题探讨 [J]. 航空科学技术, 2011(5): 63-66.
Wang Liheng. Discussion on composite structural health monitoring system[J]. Aeronautical Science & Technology, 2011(5): 63-66.(in Chinese)

[7] 袁慎芳. 结构健康监测 [M]. 北京: 国防工业出版社, 2007.
Yuan Shenfang. Structural health monitoring[M]. Beijing: National Defense Industry Press, 2007.(in Chinese)

- [8] Maierhofer C, Reinhardt H W, Dobmann G. Non-destructive testing methods Volume 2: Non-Destructive Evaluation of Reinforced Concrete Structures[M]. Woodhead Publishing Series in Civil and Structural Engineering, 2010.
- [9] 王强. Lamb波时间反转方法及其在结构健康监测中的应用研究[D]. 南京: 南京航空航天大学, 2009.
- Wang Qiang. Research on lamb wave time reversal technique and its applications in structural health monitoring[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2009.(in Chinese)
- [10] 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 & Structures, 2014, 23(9): 95015.
- [11] Zhanjun W, Kehai L, Yishou W, 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.
- [12] Yao P, Zheng B, Dawood M, et al. Real time monitoring of spot-welded joints under service load using lead zirconate titanate (PZT) transducers [J]. Smart Materials & Structures, 2017, 26(3): 35-59.
- [13] 刘国强, 孙侠生, 肖迎春. 基于Lamb波和Hilbert变换的复合材料T型加筋损伤监测 [J]. 复合材料学报, 2014, 31(3): 818-823.
- Liu Guoqiang, Sun Xiasheng, Xiao Yingchun. Damage monitoring of composite T-joint using lamb wave and Hilbert transform[J]. Acta Materiae Compositae Sinica, 2014, 31(3): 818-823.(in Chinese)
- [14] Dworakowski Z, Ambrozinski L, Packo P, et al. Application of artificial neural networks for compounding multiple damage indices in Lamb-wave-based damage detection [J]. Structural Control & Health Monitoring, 2015, 22(1): 50-61.
- [15] Sbarufatti C, Manson G, Worden K. A numerically-enhanced machine learning approach to damage diagnosis using a Lamb wave sensing network [J]. Journal of Sound & Vibration, 2014, 333(19): 4499-4525.
- [16] Worden K, Manson G. The application of machine learning to structural health monitoring [J]. Philosophical Transactions, 2007, 365(1851): 515-537.
- [17] Atashipour S A, Mirdamadi H R, Hemasian M H, et al. An effective damage identification approach in thick steel beams based on guided ultrasonic waves for structural health monitoring applications [J]. Journal of Intelligent Material Systems and Structures, SACE, 2012.
- [18] Yan G. A Bayesian approach for damage localization in plate-like structure using Lamb waves [J]. Smart Materials & Structures, 2013, 22(3): 035012.
- [19] Su Z, Lin Y. Lamb wave-based quantitative identification of delamination in CF/EP composite structures using artificial neural algorithm [J]. Composite Structures, 2004, 66(1-4): 627-637.
- [20] Agarwal S, Mitra M. Lamb wave based automatic damage detection using matching pursuit and machine learning [J]. Smart Materials & Structures, 2014, 23(8): 085012.
- [21] Liu Y, He R, Wang K. Automatic detection of ECG abnormalities by using an ensemble of deep residual networks with attention [M]. Springer, 2019.
- [22] Yan J, Qi Y, Rao Q. LSTM-Based Hierarchical denoising network for android malware detection [Z]. Security & Communication Networks, 2018.
- [23] Ratadiya P, Mishra D. An attention ensemble based approach for multilabel profanity detection[C]//2019 International Conference on Data Mining Workshops (ICDMW). IEEE, 2019: 544-550.
- [24] Kant N A, Dar M R, Khanday F, et al. Analog implementation of TDCNN single-cell architecture using sinh-domain companding technique[C]// IEEE International Conference on Recent Trends in Electronics Information Communication Technology. IEEE, 2016.
- [25] 任沙. 基于深度学习的手写数字集特征提取算法 [D]. 长沙: 湖南师范大学, 2016.
- Ren Sha. A feature extraction algorithm for handwritten digits based on deep learning[D]. Changsha: Hunan Normal University, 2016.(in Chinese)
- [26] Kingma D, Adam B J. A method for stochastic optimization [C]// Computer Science, 2014.
- [27] Yunjun G, Baihua Z. Continuous obstructed nearest neighbor queries in spatial databases[C]//Acm Sigmod International

- Conference on Management of Data.ACM, 2009.
- [28] Bornn L, Farrar C R, Park G, et al. Structural health monitoring with autoregressive support vector machines [J]. Journal of Vibration and Acoustics, 2009, 131(2): 40-48.
- [29] Kilundu B, Dehombreux P, Letot C. Early detection of bearing damage by means of decision trees [J]. Journal of Automation, Mobile Robotics & Intelligent Systems, 2009, 3(3): 70-74.
- [30] Tharwat A. Linear vs quadratic discriminant analysis classifier: a tutorial [J]. International Journal of Applied Pattern Recognition, 2016, 3(2): 145.
- [31] Schmidhuber J. Deep learning in neural networks: an overview [J]. Neural Networks, 2015, 61: 85-117.
- [32] Srivastava N, Mansimov E, Salakhutdinov R. Unsupervised

learning of video representations using lstms[C]// International Conference on Machine Learning, 2015.

(责任编辑 王为)

作者简介

杨宇(1980-)男,博士,高级工程师。主要研究方向:智能结构及损伤健康监测。

Tel: 029-88268013 E-mail: yangyu@cae.ac.cn

王彬文(1974-)男,博士,研究员。主要研究方向:飞机强度研究。

Tel: 029-88268868 E-mail: asriwbw@sina.com

吕帅帅(1987-)女,硕士,工程师。主要研究方向:结构健康监测。

Tel: 029-88268713 E-mail: 647817545@qq.com

A Deep-Learning-Based Method For Damage Identification of Composite Laminates

Yang Yu¹, Wang Binwen¹, Lyu Shuaishuai¹, Zhou Yuxi², Wang Li¹, Liu Guoqiang¹

1. Aircraft Strength Research Institute of China, Xi'an 710065, China

2. Peking University, Beijing 100871, China

Abstract: Carbon fiber reinforced Plastic (CFRP) laminates have been widely used in aircraft primary structures. However, delamination, one most common damaging pattern in CFRP, could deteriorate its mechanical properties considerably. Guided wave is employed for damage detection, and the core challenge is to quantify the damage index through comparing baseline and monitoring signals. This process is highly expertise-dependent, and the threshold of damage index varies from case to case. Therefore, a deep learning method called temporal distributed convolutional neural network (TDCNN) is proposed, which partly addresses the issue of deep-learning application in structural health monitoring, such as inadequate data samples, severe class skewness, and non-uniform data length. Moreover, LSTM module is innovatively used in this model to relate signal features over a chain of data fragments. TDCNN could dig damage features more effectively from original signals, and is less expertise-dependent. Through validation, this method proves to be efficient with a high accuracy.

Key Words: composite laminate; damage detection; guided waves; convolutional neural network

Received: 2020-04-17; Revised: 2020-06-01; Accepted: 2020-06-10

*Corresponding author. Tel.: 029-88268013 E-mail: yangyu@cae.ac.cn