

结合深度信念记忆网络的结构损伤识别

方圣恩^{1,2}, 刘 洋¹

(1. 福州大学土木工程学院, 福建 福州 350108;

2. 福州大学土木工程防震减灾信息化国家地方联合工程研究中心, 福建 福州 350108)

摘要: 从结构响应信号中挖掘敏感损伤特征是基于模式分类的损伤识别方法的关键。为此, 将深度信念网络和长短期记忆网络进行混合组网, 通过混合学习机制有机结合了两种网络在高阶抽象特征提取和考虑数据序列相关性上的优点。将响应信号传递比值输入深度信念网络, 实现初步数据压缩和特征提取, 以减少响应中的冗余信息; 将特征序列依次输入长短期记忆网络, 以考虑响应间的相关性并获取敏感损伤特征; 利用 Softmax 分类层对长短期记忆网络输出的特征进行分类, 实现对不同结构损伤模式的识别。三维试验钢框架的损伤识别结果表明: 混合学习机制能更好地训练网络参数, 整体微调后更有利于后续的损伤特征分类; 混合组网方式在包含数值或实测噪声的情况下仍可以有效进行数据压缩、特征提取和分类, 准确识别了试验框架的多种损伤工况。

关键词: 损伤识别; 框架结构; 深度信念网络; 长短期记忆网络; 混合学习机制

中图分类号: TU312⁺.3; TU391 **文献标志码:** A **文章编号:** 1004-4523(2024)11-1917-08

DOI: 10.16385/j.cnki.issn.1004-4523.2024.11.012

引 言

土木结构长期处于复杂服役环境, 不可避免会产生和累积不同程度的损伤, 导致结构性能不断退化, 若不能及时发现损伤并采取有效措施, 就可能引起灾难性的事故^[1]。利用频率、振型等模态参数构建目标函数, 通过反问题求解进行损伤识别^[2], 或利用模式归类来判断结构是否发生损伤^[3], 是研究中常用的两类方法。反问题求解过程如模型修正容易出现病态灵敏度矩阵或陷入局部最优, 此时可以通过结构损伤特征的归类来实现有效的损伤判断。

通过损伤模式归类能判断土木结构是否发生损伤, 属于模式识别问题的求解过程^[3], 可以采用人工神经网络(Artificial Neural Networks, ANNs)、支持向量机和决策树等方法实现^[4]。其中, ANNs 能够通过参数学习来逼近损伤特征与标签(结构状态)之间复杂的非线性映射关系, 特别适合用于模式识别问题, 过去 20 年来已取得了较多的研究成果^[5]。

ANNs 可分为浅层神经网络和深度神经网络(Deep Neural Networks, DNNs)两大类^[6]。传统浅层网络的拓扑相对简单, 通常只包含一二个隐藏层, 无法挖掘高维响应信号中的敏感特征, 损伤识别应用时常采用模态参数及其衍生参数作为损伤特征,

如模态频率^[7]、振型^[8]和曲率^[9]等, 容易受环境、测试噪声和测点数量等因素的影响, 在搜索空间中的离散性也会限制模式分类的处理能力。DNNs 通过隐藏层堆叠的方式逐层提取原始输入信息的高阶抽象特征, 可将其应用在语音识别、图像识别等领域^[10]。用于结构损伤识别时, DNNs 可以输入包含更多结构信息的振动响应信号, 如频响函数、响应谱^[11]和加速度响应^[12]等, 再利用多个隐藏层自动挖掘输入响应中包含的结构信息, 减少冗余和不相关特征, 得到对结构损伤敏感的特征, 有利于分类层更好地进行特征分类, 进而实现高效的损伤识别。

相较于卷积神经网络和栈式自编码器等层间全连接、层内无连接的 DNNs, 循环神经网络能够较好地考虑输入数据间的序列相关性, 以获取更敏感的数据特征^[13]。但实际运用时, 若输入序列比较长, 网络会存在梯度爆炸或消失问题, 即长程依赖问题。而长短期记忆(Long Short-Term Memory, LSTM)网络通过门控机制对信息的累积速度进行控制, 包括选择性地添加新的信息, 以及选择性地忽略以前积累的信息, 以此有效地解决长程依赖问题, 因此可以更好地考虑输入数据序列间的相关性, 获取数据的敏感特征^[14]。SONY 等^[15]将加速度信号按时间序列输入 LSTM 网络, 实现了一座看台模型的损伤定位, 但仅考虑了加速度信号的时间相关性, 未包含

收稿日期: 2023-04-14; 修订日期: 2023-06-17

基金项目: 国家自然科学基金资助项目(52178276); 福建省自然科学基金资助项目(2021J01601); 福州市科技计划项目(2021-Y-084)。

不同响应间的空间相关性。而实践中发现不同位置的响应存在一定关联^[16-19]。闫维明等^[18]证明了加速度响应的相关特性包含了结构的模态信息,与损伤程度和位置相关,可作为结构损伤因子。杨小森等^[19]发现无论是正弦激励还是白噪声激励,结构位移响应信号的统计特征(如相关系数、回归系数和协方差之比)都包含了结构的模态信息,可由此构建损伤指标。

全连接神经网络和循环神经网络的混合组网能有机结合不同类型网络的优点,可以利用全连接神经网络对原始输入信息进行初步数据压缩和特征提取,减少输入中的冗余信息,再通过循环神经网络融合前后输入的序列相关性,实现对输入数据更充分的特征挖掘。比如在图像分析领域,利用卷积神经网络提取视频每帧图像的特征并减少输入表示中的冗余,再按序列依次输入 LSTM 网络,以融合每帧图像特征的序列相关性,实现视频活动识别、图像标题生成和视频描述^[20]。

深度信念网络(Deep Belief Network, DBN)是一种全连接的深度神经网络,其隐藏层能够逐层提取原始输入信息中的高阶抽象特征,以减少输入中的冗余信息^[21]。为此,本文在损伤识别问题上尝试将 DBN 与 LSTM 网络进行混合组网,构建深度信念记忆(DBN-LSTM)网络,采用无监督和有监督学习相结合的混合学习机制进行混合网的训练,快速获取合适的训练参数。损伤识别时,首先将每个响应信号按序列依次输入,利用 DBN 降低输入响应的维度和表示冗余,进行初步数据压缩和损伤特征提取;然后将特征按照响应信号的序列依次输入 LSTM 网络,充分考虑响应间存在的时空相关性(如不同响应间的统计特征),得到包含不同响应相关性的敏感损伤特征;最后利用 Softmax 分类层对 LSTM 网络输出的特征进行分类,准确识别结构的不同损伤工况。文末通过一榀三维框架模型验证了所提方法的可行性。

1 深度信念网络和长短期记忆网络

1.1 深度信念网络

DBN 是由多个受限波尔兹曼机(Restricted Boltzmann Machine, RBM)通过逐层贪婪学习策略得到的 DNN^[21],每个隐藏层都能够基于前一个隐藏层提取的特征信息,进一步提取对于原始输入信息的高阶抽象特征,从而更好地完成对原始输入信息的压缩和特征提取。图 1 展示了由 3 个 RBM 堆栈而成的 DBN 拓扑,每个 RBM 都包含可视层 v 和隐藏层 h , v_1 和 h_1 组成 RBM1,再将 h_1 作为 v_2 ,与 h_2 组

成 RBM2。同样地,将 h_2 作为 v_3 ,与 h_3 组成 RBM3。网络训练时,输入 v_1 的数据依次逐层传递至 h_3 ,实现对原始输入信息的压缩和特征提取。




图 1 DBN 拓扑示意图

Fig. 1 Schematic diagram of a DBN topology

1.2 长短期记忆网络

LSTM 网络是一种循环神经网络,基本单元包含遗忘门、输入门和输出门,通过门控机制来控制信息的累积速度,包括有选择地加入新的信息,并有选择地遗忘之前累积的信息,可以很好地考虑输入数据序列的相关性,如图 2 所示^[22]。

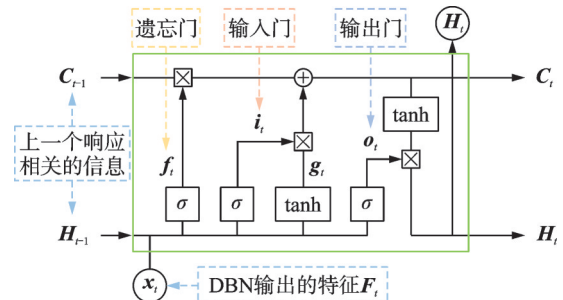


图 2 LSTM 基本单元示意

Fig. 2 Schematic diagram of a LSTM basic unit

遗忘门 f_t 决定上一个记忆 C_{t-1} 要保留的部分,即向量 f_t 内元素为 1 说明 C_{t-1} 全部保留,为 0 则全部遗忘;输入门 i_t 决定 C_{t-1} 要更新的部分,即 i_t 内元素为 1 表示 g_t 全部保留至本单元的内存 C_t 中,为 0 则不保留;输出门 o_t 决定本单元的输出 H_t , o_t 内元素为 1,则说明经过 tanh 函数转换的 C_t 全部作为输出,为 0 时则输出 0。上述参数的表达式如下所示^[22]:

$$\begin{aligned} f_t &= \sigma(\omega_{fx} x_t + \omega_{fh} H_{t-1} + b_f), \\ i_t &= \sigma(\omega_{ix} x_t + \omega_{ih} H_{t-1} + b_i), \\ g_t &= \phi(\omega_{gx} x_t + \omega_{gh} H_{t-1} + b_g), \\ o_t &= \sigma(\omega_{ox} x_t + \omega_{oh} H_{t-1} + b_o), \\ C_t &= g_t \odot i_t + C_{t-1} \odot f_t, \\ H_t &= \phi(C_t) \odot o_t \end{aligned} \quad (1)$$

式中 $\omega_{ix}, \omega_{ox}, \omega_{ix}$ 和 ω_{gx} 分别为从输入向量 x_i 到输入门、输出门、遗忘门和记忆 C_i 的权重矩阵; $\omega_{ih}, \omega_{oh}, \omega_{ih}$ 和 ω_{gh} 分别为从中间输出 H_{i-1} 到输入门、输出门、遗忘门和记忆 C_i 的权重矩阵; b_i, b_o, b_f 和 b_g 分别为输入门、输出门、遗忘门和记忆 C_i 的偏置项; \odot 表示向量中元素按位相乘; σ 表示 Sigmoid 函数; ϕ 表示 tanh 函数。

2 深度信念记忆网络

2.1 DBN 和 LSTM 混合组网

针对结构损伤模式识别问题,为实现更有效的数据压缩和特征提取,同时充分考虑不同测点响应间的相关性,进而实现更有效的损伤模式分类,本文采用 DBN 与 LSTM 混合组网的方式,构建了 DBN-LSTM 网络,其拓扑由输入层、特征提取层、分类层和输出层组成,如图 3 所示。输入层是整个网络的入口,为更好地考虑不同响应间的相关性,参考循环神经网络处理自然语言中“词向量”的表示方法,将响应信号(图 3 中 $S_1 \sim S_n$)按序列依次输入;特征提取层由 DBN 隐藏层和 LSTM 网络组合而成,是整个 DBN-LSTM 网络的核心,其中 DBN 对响应信号进行逐层提取,得到与输入相关的高阶抽象特征(图 3 中 $F_1 \sim F_n$),减少输入中表示的冗余信息,再将特征依次输入 LSTM 网络,进行充分融合,形成新的包含响应间相关特性的敏感特征,并输出到后续分类层;分类层以具有多类别分类功能的 Softmax 函数作为激活函数,能够映射损伤特征与结构状态之间的非线性关系;分类结果由输出层输出。

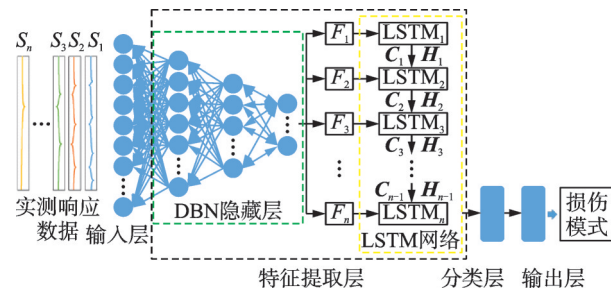


图 3 用于损伤识别的 DBN-LSTM 网络拓扑

Fig. 3 A DBN-LSTM network topology for damage identification

2.2 样本集生成

结构损伤识别往往依赖于激励-响应信号分析所获取的动力特征,但对处于环境激励下的实际土木工程结构而言,由于激励力未知,因此无法获取频响函数。而传递比函数反映的是系统输出-输出(响应-响应)间的关系,更适合于仅能测量响应时的土

木结构动力分析以及损伤识别问题的求解^[23],其不涉及激励的测量,可采用响应谱计算,且对加速度、速度和位移响应都适用,因此应用上更加方便^[24-25]:

$$T_{ij}^k(\omega) = \frac{X_i^k(\omega) X_j^{k*}(\omega)}{X_j^k(\omega) X_j^{k*}(\omega)},$$

$$T_{ij}^p(\omega) = \frac{X_i(\omega) X_p^*(\omega)}{X_j(\omega) X_p^*(\omega)} \quad (2)$$

式中 $T_{ij}^k(\omega)$ 表示在 k 点激励系统时响应点 i 和 j 之间的传递比函数; $X_i^k(\omega)$ 表示 i 点的响应谱, $X_j^k(\omega)$ 表示 j 点的响应谱; $X_j^{k*}(\omega)$ 为 $X_j^k(\omega)$ 的共轭复数。

激励力未知时,可采用 $T_{ij}^p(\omega)$ 进行计算,即以响应测点 p 为参考点,计算响应点 i 和 j 之间的传递比函数。此时 $X_i(\omega)$ 表示 i 点的响应谱, $X_j(\omega)$ 表示 j 点的响应谱; $X_p(\omega)$ 表示 p 点的响应谱, $X_p^*(\omega)$ 为 $X_p(\omega)$ 共轭复数。

采用 DNNs 进行分析时往往需要大量的样本,对实际土木结构来说通常难以实现。此时 $T_{ij}^k(\omega)$ 可通过有限元模拟获取,转换为结构的频响函数 $H(\omega)$ 进行计算^[23]:

$$T_{ij}^k(\omega) = \frac{X_i^k(\omega)}{X_j^k(\omega)} = \frac{H_i^k(\omega)}{H_j^k(\omega)} \quad (3)$$

式中 $H_i^k(\omega)$ 表示在 k 点激励系统时响应点 i 的频响函数; $H_j^k(\omega)$ 表示在 k 点激励系统时响应点 j 的频响函数。

DBN-LSTM 网络训练样本中的 $T_{ij}^k(\omega)$ 值也通过有限元分析获取。样本集包含训练集、验证集和测试集三种,常用占比为 3:1:1^[26],其中训练集用于训练网络中的权重和偏置参数,验证集用于训练学习率、训练次数、训练批次、隐藏层数及相应的神经元数等超参数和检验模型性能,测试集用于检验网络的泛化能力^[27]。

为了尽可能涵盖结构可能的损伤工况,神经网络样本集需要综合考虑各种损伤模式和程度,使得样本数目变得庞大,增加了网络的训练时间和计算成本。为此,本文利用均匀设计^[28]来减少样本量,将损伤位置作为试验因素,损伤程度作为试验水平。具体到框架结构的损伤识别上,单层损伤工况可采用单因素、多水平设计,多损伤工况则采用多因素、多水平的均匀设计。另外,实测 $T_{ij}^k(\omega)$ 中通常包含环境及测试噪声,为了增强 DBN-LSTM 网络对噪声的鲁棒性,在数值样本中加入了高斯白噪声,使得训练与测试用的 $T_{ij}^k(\omega)$ 值均含有噪声。

要说明的是,在频响数据样本处理上,网络训练时将 DBN 提取的传递比函数的高阶抽象特征(图 3 中 $F_1 \sim F_n$)依次输入 LSTM 网络,利用其可以很好地考虑序列相关性的优势得到损伤敏感特征,响应

间相关性的信息都包含在相应 LSTM 单元的内存 C_t 和输出 H_t 中。

3 基于 DBN-LSTM 网络的损伤识别流程

以框架结构为例,基于 DBN-LSTM 网络的损伤识别流程如图 4 所示。首先,建立试验框架的有限元模型,通过有限元分析获取包含不同工况传递比数值的训练集、验证集和测试集样本;其次,搭建 DBN-LSTM 网络拓扑,设置输入层和输出层神经元的数目、LSTM 单元数,并初设 DBN 隐藏层数及相应神经元个数、分类层神经元个数,同时设置学习率和训练批次数目等参数;接着,通过训练和验证过程优化调整 DBN-LSTM 网络的拓扑和权重等参数,其中训练集用于确定网络权重、偏置等参数,验证集用于确定网络的学习率、训练次数、训练批次、隐藏层数及相应的神经元数等超参数;随后,利用测试集来评价 DBN-LSTM 网络对未知样本的预测准确度;最后,将试验框架的实测传递比值代入 DBN-LSTM 网络,实现对框架的损伤识别。

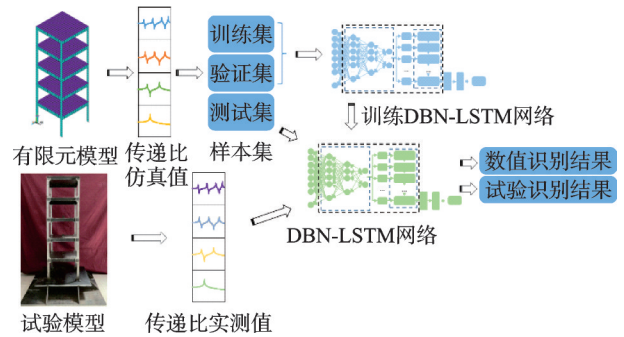


图 4 基于 DBN-LSTM 网络的框架损伤识别流程

Fig. 4 Damage identification procedure of a frame using the DBN-LSTM network

具体地,网络训练过程包括预训练和网络微调两个步骤,其中预训练是对所有 RBM 进行逐个训练,属于无监督学习过程,能够得到与训练集相关的隐藏层参数(权重和偏置)初始值,加速网络的收敛;微调则是将 DBN 隐藏层、LSTM 网络和分类层进行同时训练,进一步调整预训练后的网络参数初始值,使整个 DBN-LSTM 网络对训练样本有更好的拟合,对未知样本也有更好的预测效果。网络验证过程则是将验证集代入前述训练后的 DBN-LSTM 网络,通过计算损失和准确率来判断网络是否符合要求。此处准确率指所有预测结果中正确预测数量的样本占比,微调训练损失则采用交叉熵损失函数计算^[13]:

$$cost = - \sum_n r_n \ln(p_n) \quad (4)$$

式中 r_n 表示真实值; p_n 表示预测值; n 为类别数。

若损失和准确率满足要求,则保存当前网络的各项参数(权重、偏置和超参数);反之,则对网络超参数(隐藏层个数、神经元个数、训练批次数目和学习率等)进行调整,然后重新预训练和微调,直到代入验证集后,DBN-LSTM 网络的输出损失和预测准确率符合要求,此时认为网络训练完成。

4 试验钢框架算例

采用一榀三维 5 层试验钢框架模型验证所提出方法的可行性,如图 5 所示。框架全高 1250 mm,每层高 250 mm。梁、板、柱钢材的实测弹性模量均值为 184.7 GPa,密度为 7850 kg/m³。采用锤击法激励框架,激励点位于第五层梁的中心,加速度传感器布设于每层楼板的中心,通过动态测试系统采集各测点的加速度时程数据,采样频率为 100 Hz,谱线数为 1600,每个传递比函数 $T_{ij}^k(\omega)$ 有 1600 个数值。




图 5 试验钢框架测试系统

Fig. 5 Test system of the experimental steel frame

试验中通过减少整层 4 根柱的截面宽度(由初始 30 mm 减至 25 mm,换算为刚度降低 16.7%)来模拟损伤,共测试了单层损伤(L2,L4)和双层损伤(L2+L4)3 种工况。为生成 DBN-LSTM 网络所需的训练样本,建立了框架的有限元模型(见图 4),几何尺寸与试验模型相同,材料特性采用实测数据。梁、板、柱均采用壳单元模拟,网格划分后共包含 1684 个壳单元。

4.1 DBN-LSTM 网络初设置

如前所述,框架损伤识别所用的 DBN-LSTM 网络包含输入层、特征提取层、分类层和输出层。对框架前 2 阶频率的传递比数据(0~11.1 Hz 频段,包含 453 个传递比值)进行压缩和特征提取,故网络输入层有 453 个神经元;LSTM 网络部分有 4 个 LSTM 单元,与输入的响应数目相同;分类层和输

出层神经元个数均为 9,与预设的损伤模拟工况数目相同;初设训练批次数目、学习率、每个 RBM 的预训练次数、微调训练次数、DBN 隐藏层个数及相应的神经元个数等超参数。

4.2 生成样本集

如前所述,DBN-LSTM 网络的训练集、验证集和测试集由框架有限元模型计算得到,包含各种不同损伤位置和程度的工况。损伤通过减小柱的弹性模量来模拟,样本集包含单层和双层损伤工况:单层损伤有 L1~L5 层分别损伤,共 5 个模拟工况,损伤程度在 2%~50% 范围内均匀分布,步长 2%;双层损伤以间隔为主,有 L1+L3,L2+L4,L3+L5 损伤 3 种模拟工况,损伤程度根据均匀设计表 $U_{25}^*(25^{11})$ 进行取值,损伤程度也为 2%~50%。未损伤框架作为独立工况加入样本集,因此一共 9 个模拟工况,对应输出层 9 个神经元。此外,为模拟实际情况,增加 DBN-LSTM 网络的鲁棒性,本文利用信号与标准正态分布的随机矩阵叠加的方式,给各工况的传递比函数值添加 1%~10% 的高斯白噪声,如图 6 所示。

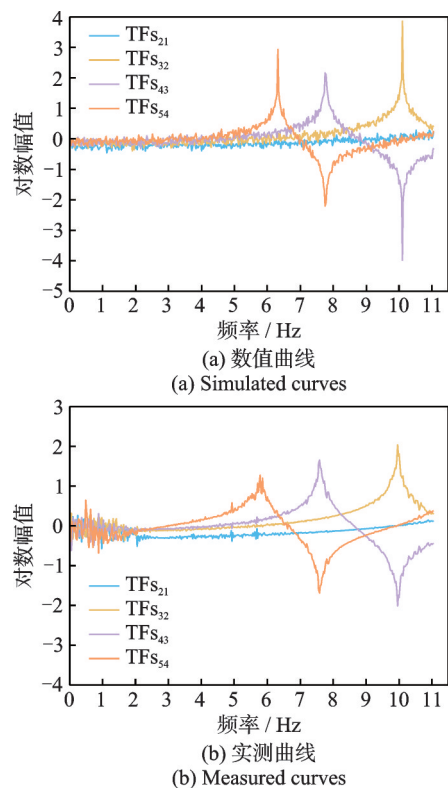


图 6 钢框架数值和实测传递比函数

Fig. 6 Simulated and measured transmissibility functions of the steel frame

如 2.2 节所述,训练集、验证集、测试集的样本数比例为 3:1:1。对于未损伤工况,均匀抽取 40% 样本,验证集和测试集各占一半,剩余 60% 的样本

作为训练集;对于单层损伤工况,均匀选取损伤程度为 4%,14%,24%,34%,44% 的样本作为测试集,损伤程度为 8%,18%,28%,38%,48% 的样本作为验证集,剩余的样本作为训练集;对于双层损伤工况,取均匀设计表 $U_{25}^*(25^{11})$ 中水平为 2,7,12,17,22 的样本作为测试集,水平为 4,9,14,19,24 的样本作为验证集,其他的样本作为训练集。样本集的总数为 105000 个,各样本集的分配如表 1 所示,1 个样本包含由 5 个响应测试点计算的 4 个传递比函数。

表 1 训练集、验证集和测试集样本配比

Tab. 1 Sample divisions of the training set, validation set and testing set

损伤工况	训练集	验证集	测试集	合计
未损伤	3000	1000	1000	5000
单层损伤	37500	12500	12500	62500
双层损伤	22500	7500	7500	37500

4.3 DBN-LSTM 网络训练、验证和测试

本文基于 TensorFlow 平台搭建 DBN-LSTM 网络,预训练采用对比散度学习算法,微调训练采用 Adam 优化算法^[13]。经过预训练、微调和验证,确定网络的训练批次数目为 100、学习率为 0.0001,每个 RBM 隐藏层的预训练次数为 500,微调训练次数为 200,DBN 隐藏层个数为 3,各层神经元个数分别依次为 300,150,50;最后一个 LSTM 单元的输出 H_4 为 3 个神经元。

3 个 RBM 训练的损失曲线如图 7 所示。每个 RBM 的训练损失在开始阶段即大幅下降,第 100 轮后基本趋于稳定,说明 RBM 训练的参数(权重和偏置)学习主要在前期完成。





图 7 RBM 训练损失曲线


Fig. 7 Training loss curves of the RBM

DBN-LSTM 网络的整体微调结果如图 8 所示。训练集的损失值随着训练次数的增加逐渐趋近于 0,准确率则逐渐稳定至 99.98%,说明网络很好地学习了如何对训练集数据进行初步数据压缩并融合响应间相关性,以得到敏感损伤特征和分类。此外,训练集、验证集的损失曲线和准确率曲线在整个微调过程中基本保持一致,说明网络能对训练集以外的样本进行准确分类,不存在过拟合问题,可以保


存此时的隐藏层个数、神经元个数、训练批次数目和学习率等超参数。图 8(b),(c)分别为训练集和验证集的损伤特征在三维空间中的分布,特征由 LSTM 的最后 1 个单元输出,3 个神经元数值依次对应 X, Y, Z 的坐标值,可见 9 种工况的特征可以被很好地区分,有利于 Softmax 分类层进行更有效的分类。



(a) 训练损失曲线和准确率曲线
(a) Training loss curve and accuracy curve



(b) 训练集损伤特征分布
(b) Distribution of damage features in the training set




(c) 验证集损伤特征分布
(c) Distribution of damage features in the validation set

图 8 DBN-LSTM 网络的微调结果


Fig. 8 Fine-tuning results of DBN-LSTM network

最后,将测试集代入经验证的 DBN-LSTM 网络中,得到的损伤识别准确率为 99.97%,如图 9 所示。图 9(a)为分类结果的混淆矩阵,可见 9 种工况中只有未损伤、单层损伤 L3 和 L5 出现了极个别的误判(比如未损伤 1000 个样本中,2 个样本误判),其他工况都达到了 100% 的识别准确率。图 9(b)为未损伤、单层损伤、双层损伤在不同噪声程度下的识别准确率,可见噪声程度无论是 0%~3%,3%~7% 还是 7%~10%,DBN-LSTM 网络都能够进行准确的识别,表现出良好的抗噪性。



(a) 混淆矩阵

(a) Confusion matrix




(b) 不同工况在不同噪声程度下的损伤识别准确率
(b) Accuracy of damage identification under different noise levels for different scenarios

图 9 DBN-LSTM 网络数值验证结果

Fig. 9 Numerical verification of DBN-LSTM network


4.4 试验数据验证

针对单层损伤 L2, L4 和双层损伤 L2+L4 三种工况,进行了实测效果验证。将实测传递比数据输入 DBN-LSTM 网络中,预测结果如图 10 所示。图中横坐标表示工况,纵坐标表示识别结果属于某工况的概率。由图可见,所提方法准确识别了单层损伤 L2、单层损伤 L4 及双层损伤 L2+L4 工况。



(a) 单层损伤 L2

(a) Single-layer damage L2



(b) 单层损伤 L4

(b) Single-layer damage L4




图 10 DBN-LSTM 网络试验验证

Fig. 10 Text verification of DBN-LSTM network

5 结 论

为提高复杂结构损伤模式分类的准确率,本文提出一种基于深度信念记忆(DBN-LSTM)网络的损伤识别方法,有机结合了DBN在减少输入表示中的冗余和LSTM在考虑输入表示的序列相关性上的优点,实现对传递比函数数据的充分挖掘,得到敏感特征。三维试验框架研究结果表明:

(1)DBN和LSTM混合网络良好融合了全连接神经网络提取输入高阶抽象特征和循环神经网络考虑数据序列相关性的优点,有效实现了对框架结构敏感损伤特征的准确分类。

(2)DBN-LSTM网络采用的无监督和有监督的混合学习机制能更好地获取合适的权重和偏置等参数,同时经过整体微调的网络更有利于后续的损伤特征分类。

(3)DBN-LSTM网络在传递比函数值包含噪声的情况下仍可以有效进行数据压缩、特征提取和分类,准确识别了框架的多种损伤工况,体现出良好的抗噪性。实测的试验传递比数据作为输入时,网络仍保持了优异的损伤分类和识别性能。

参考文献:

- [1] 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.
- [2] FANG S E, PERERA R, DE ROECK G. Damage identification of a reinforced concrete frame by finite element model updating using damage parameterization [J]. Journal of Sound and Vibration, 2008, 313(3-5): 544-559.
- [3] REN W X, LIN Y Q, FANG S E. Structural damage detection based on stochastic subspace identification and statistical pattern recognition: I. theory[J]. Smart Ma-

terials and Structures, 2011, 20(11): 115009.

- [4] 孙利民, 尚志强, 夏烨. 大数据背景下的桥梁结构健康监测研究现状与展望[J]. 中国公路学报, 2019, 32(11): 1-20.
SUN Limin, SHANG Zhiqiang, XIA Ye. Development and prospect of bridge structural health monitoring in the context of big data[J]. China Journal of Highway and Transport, 2019, 32(11): 1-20.
- [5] GOMES G F, MENDÉZ Y A D, ALEXANDRINO P D S L, et al. The use of intelligent computational tools for damage detection and identification with an emphasis on composites-a review[J]. Composite Structures, 2018, 196: 44-54.
- [6] 焦李成, 杨淑媛, 刘芳, 等. 神经网络七十年: 回顾与展望[J]. 计算机学报, 2016, 39(8): 1697-1716.
JIAO Licheng, YANG Shuyuan, LIU Fang, et al. Seventy years beyond neural networks: retrospect and prospect [J]. Chinese Journal of Computers, 2016, 39(8): 1697-1716.
- [7] HAKIM S J S, RAZAK H A. Structural damage detection of steel bridge girder using artificial neural networks and finite element models[J]. Steel & Composite Structures, 2013, 14(4): 367-377.
- [8] VAFAEI M, ALIH S C. Adequacy of first mode shape differences for damage identification of cantilever structures using neural networks[J]. Neural Computing and Applications, 2018, 30(8): 2509-2518.
- [9] ZHANG X D, ZHANG Z G, LI X F, et al. Damage identification in cable-stayed bridge based on modal analysis and neural networks [C]//AIP Conference Proceedings. Golden, 2007: 1435-1442.
- [10] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [11] DUAN Y F, CHEN Q Y, ZHANG H M, et al. CNN-based damage identification method of tied-arch bridge using spatial-spectral information [J]. Smart Structures and Systems, 2019, 23(5): 507-520.
- [12] PURUNCAJAS B, VIDAL Y, TUTIVÉN C. Vibration-response-only structural health monitoring for offshore wind turbine jacket foundations via convolutional neural networks[J]. Sensors, 2020, 20(12): 3429.
- [13] 邱锡鹏. 神经网络与深度学习[M]. 北京: 机械工业出版社, 2020.
QIU Xipeng. Neural Networks and Deep Learning[M]. Beijing: China Machine Press, 2020.
- [14] YU Y, SI X S, HU C H, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. Neural Computation, 2019, 31(7): 1235-1270.
- [15] SONY S, GAMAGE S, SADHU A, et al. Vibration-based multiclass damage detection and localization using long short-term memory networks[J]. Structures, 2022, 35: 436-451.

- [16] AN Y H, OU J P. Experimental and numerical studies on model updating method of damage severity identification utilizing four cost functions[J]. Structural Control and Health Monitoring, 2013, 20(1): 107-120.
- [17] ZHANG Y F, ZHU J S. Damage identification for bridge structures based on correlation of the bridge dynamic responses under vehicle load[J]. Structures, 2021, 33: 68-76.
- [18] 闫维明, 顾大鹏, 陈彦江, 等. 基于加速度响应相关性的结构损伤识别方法[J]. 振动与冲击, 2013, 32(14): 82-86.
YAN Weiming, GU Dapeng, CHEN Yanjiang, et al. A method for structural damage detection based on correlation characteristic of acceleration response[J]. Journal of Vibration and Shock, 2013, 32(14): 82-86.
- [19] 杨小森, 闫维明, 陈彦江, 等. 基于振动信号统计特征的损伤识别方法[J]. 公路交通科技, 2013, 30(12): 99-106.
YANG Xiaosen, YAN Weiming, CHEN Yanjiang, et al. Damage detection method based on statistics characteristics of vibration signal[J]. Journal of Highway and Transportation Research and Development, 2013, 30(12): 99-106.
- [20] DONAHUE J, HENDRICKS L A, GUADARRAMA S, et al. Long-term recurrent convolutional networks for visual recognition and description[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Washington, 2015: 2625-2634.
- [21] LEI Y G, YANG B, JIANG X W, et al. Applications of machine learning to machine fault diagnosis: a review and roadmap[J]. Mechanical Systems and Signal Processing, 2020, 138: 106587.
- [22] HOUDT G V, MOSQUERA C, NÁPOLES G. A review on the long short-term memory model[J]. Artificial Intelligence Review, 2020, 53(8): 5929-5955.
- [23] YAN W J, ZHAO M Y, SUN Q, et al. Transmissibility-based system identification for structural health monitoring: fundamentals, approaches, and applications[J]. Mechanical Systems and Signal Processing, 2019, 117: 453-482.
- [24] MERUANE V. Model updating using antiresonant frequencies identified from transmissibility functions[J]. Journal of Sound and Vibration, 2013, 332(4): 807-820.
- [25] YAN W J, REN W X. Operational modal parameter identification from power spectrum density transmissibility[J]. Computer-Aided Civil and Infrastructure Engineering, 2012, 27(3): 202-217.
- [26] JU H Y, MA T, LI W, et al. Pixelwise asphalt concrete pavement crack detection via deep learning-based semantic segmentation method[J]. Structural Control and Health Monitoring, 2022, 29(8): e2974.
- [27] 伊恩·古德费洛, 约书亚·本吉奥, 亚伦·库维尔. 深度学习[M]. 赵申剑, 黎或君, 符天凡, 等译. 北京: 人民邮电出版社, 2021.
- [28] 方开泰, 刘民千, 覃红, 等. 均匀试验设计的理论和应用[M]. 北京: 科学出版社, 2018.

Structural damage identification via a deep belief memory network

FANG Sheng-En^{1,2}, LIU Yang¹

(1.College of Civil Engineering, Fuzhou University, Fuzhou 350108, China;

2.National & Local Joint Engineering Research Center for Seismic and Disaster Informatization of Civil Engineering, Fuzhou University, Fuzhou 350108, China)

Abstract: Extracting sensitive damage features from structural response signals is crucial for damage identification methods based on pattern classification. To this end, a hybrid network that combines a deep belief networks (DBN) and a long-short term memory (LSTM) network is proposed through a hybrid learning mechanism to utilize the merits of both networks in the aspects of extracting high-order abstract features and considering data sequence correlations. First, transmissibility data from response signals are sequentially input into the DBN to achieve the initial data compression and feature extraction, reducing the redundant information in the responses. Then, the extracted feature sequences are input into the LSTM network to consider the correlation between the different responses for acquiring the relevant sensitive damage features. Finally, a classification layer with the Softmax function is used to classify the features output by the LSTM network. Thereby, different structural damage patterns can be identified. The damage identification results on a three-dimensional experimental steel frame demonstrate that the hybrid learning mechanism can better train the network parameters, and the fine-tuning on the whole hybrid network contributes to the subsequent damage feature classification. Under the pollution of numerical or measured noises, the hybrid network can still effectively perform the data compression, feature extraction and classification. The various damage scenarios of the experimental frame are well identified.

Key words: damage identification; frame structure; deep belief network; long short-term memory network; hybrid learning mechanism

作者简介: 方圣恩(1980—),男,博士,教授,博士生导师。E-mail:shengen.fang@fzu.edu.cn。