

基于应变数据和改进 MHA 模型的囊体缺陷检测*

卢志强¹, 朱海平¹, 陈志鹏¹, 范良志²

(1. 华中科技大学机械科学与工程学院 武汉, 430074)

(2. 武汉纺织大学机械工程与自动化学院 武汉, 430074)

摘要 针对浮空器囊体表面缺陷难以检测等问题,提出一种基于应变时序数据和改进多头注意力(multi-head attention,简称MHA)模型的囊体缺陷检测方法,该方法通过对囊体声波激励后的应变时序数据进行端到端特征提取与检测,实现浮空器囊体缺陷检测。首先,在声波激励下,通过粘贴在囊体表面的应变片收集同位置无裂纹和有裂纹时的应变时序数据;其次,将收集的应变时序数据按照一定的长度划分样本,每个样本划分为多个时序向量的组合并输入到改进 MHA 模型中,提取隐藏于时序数据中的缺陷特征;然后,网络输出各个时序样本相应的缺陷识别结果;最后,在收集到的囊体应变数据上将该方法与其他 4 种传统模型的检测结果进行对比。结果表明,该方法平均检测准确率为 97.7%,优于其他 4 种模型,验证了该方法的有效性。

关键词 浮空器;神经网络;缺陷检测;囊体;注意力机制;时间序列

中图分类号 TP183;TH17;V25

引言

浮空器囊体材料在生产制造、运输搬运以及服役期间会受到各种因素影响而发生空气泄露,影响其稳定性和安全性,因此对囊体进行缺陷检测至关重要^[1]。囊体材料属于纤维增强复合材料,对其检测可采用无损检测技术^[2-4]以及基于视觉的薄膜缺陷检测技术^[5-6]。前者需要技术人员进行操作,后者检测精度较低且需要足够的经验知识。

故障诊断领域常常通过多个振动传感器收集时序数据,并结合卷积神经网络提取隐藏在振动时序数据中的故障特征。Eren 等^[7]使用一维卷积神经网络(convolution neural network,简称 CNN),以原始时间序列作为输入,经过适当训练实现轴承故障诊断的检测。Jin 等^[8]提出一种端到端的自适应抗噪神经网络框架(an adaptive anti-noise neural network,简称 AAnNet),采用具有注意力机制改进的门控循环神经网络对卷积神经网络部分处理特征进行学习 and 分类,在重噪声环境下的故障诊断中取得了良好的检测效果。

Mnih 等^[9]提出一种 Transformer 模型,该方法以多头注意力机制为基础,在不依靠循环模型结构的同时,完成对全局依赖关系的建模,相比于 CNN、循

环神经网络(recurrent neural network,简称 RNN)和长短时记忆网络(long short-term memory network,简称 LSTM),能更好地对时间序列的长程依赖性进行建模。Bahdanau 等^[10]设计了一种能够处理一维时序数据的分词器,并在轴承故障诊断中取得了准确率高达 98.63% 的检测效果。

现有囊体的缺陷检测方法需要技术人员进行操作、精度低,且需要足够的先验知识。采用故障诊断领域基于 CNN, RNN 和 LSTM 的深度学习方法虽然无需大量的先验知识且准确性较高,但对时序数据的长程依赖性建模的能力较弱。

笔者提出了一种基于应变时序数据和改进 MHA 模型的囊体缺陷检测方法。首先,对囊体进行声波激励,收集囊体表面应变时序数据,用于训练改进的多头注意力模型;其次,固定训练后的模型参数,将实时采集的囊体声波激励数据输入训练好的模型中,即可实现囊体缺陷检测;最后,实验验证了所提出方法的优越性,其平均检测准确率达到 97.7%。

1 基于应变数据与改进 MHA 模型的缺陷检测流程


应力波在复合材料圆柱壳中的传播会受到表面

* 国家自然科学基金资助项目(52075202)

收稿日期:2022-10-10;修回日期:2023-02-09

缺陷损伤的影响,而使得前后收集的应力波信号不同,应变信号也会相应的变化^[11]。这间接证明了通过对应变时序数据进行特征提取用于缺陷检测方法的可行性。该方法通过对囊体表面进行声波激励,使囊体表面振动,收集缺陷附近的应变时序信号并训练改进MHA模型,以提取缺陷特征。

囊体应变数据收集平台如图1所示。缺陷位于囊体尾部中间位置且贯穿囊体表面。



1-桁架装置; 2-浮空器囊体; 3-吊索; 4-应变采集仪; 5-应变片;
6-应变片连接线; 7-信号采集终端; 8-音频激励终端;
9-音频连接线; 10-音频设备; 11-信号连接线;
12-输气管; 13-空气压缩机; 14-气压表; 15-通气软管

图1 囊体应变数据采集平台

Fig.1 Capsule strain data acquisition platform

基于应变片测量的囊体应变信号采集方案实施步骤为:

- 1) 记录囊体唯一标识信息,确定测试参数配置等信息;
- 2) 利用桁架和吊索将待测囊体吊起,便于进行应力测量;
- 3) 根据预定参数使用空气压缩机对囊体进行充气至指定压力水平并保持;
- 4) 在囊体表面粘贴应变片,并连接至应变仪,配置数据采集频率、时间和通道等信息;
- 5) 通过音频激励器生成一定频率、强度的音频信号,并通过功放器播放,使囊体产生振动;
- 6) 通过应变仪采集囊体受激振动时产生的应变信号;
- 7) 数据存储终端将应变信号、囊体气压、环境温度、激励信号频率和强度、激励源空间位置、信号采集频率、采集时间等关键信息统一采集并进行存储。

得到囊体表面的应变时序信息后,将数据用于训练改进MHA模型,同时保存训练好的模型参数,将再次收集的应变时序数据输入训练好的模型中即可得到缺陷检测结果。图2为改进MHA模型囊体缺陷检测流程。

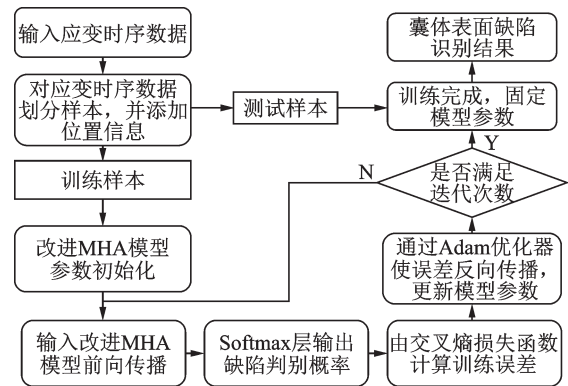


图2 改进MHA模型囊体缺陷检测流程

Fig.2 Capsule defect detection process of the improved MHA model

2 基础MHA模型

Transformer模型最早应用于自然语言处理问题中,包含编码器和解码器2部分。该方法能够较好地对不同位置之间的关联信息进行计算,实现时序数据间远程依赖性建模。由于所提出的囊体缺陷检测方法主要是对原始Transformer模型中编码器部分进行修改,而该部分的重点为多头注意力机制,因此笔者将Transformer的编码器部分称为多头注意力模型,并对其进行简要介绍。原始MHA模型结构如图3所示。

MHA模型首先通过输入嵌入层,将输入的一段长为 n 的句子转换为 n 个词向量的组合,每个词向量的维度为 d ,则输入的句子可表示为 $X_{n \times d}$ 的单词向量矩阵。通过位置编码对每个词向量添加位置信息,并由多头注意力块实现对输入的各个词向量之间的相关性和长程依赖性的特征提取。残差连接让网络浅层特征在深层得以重用,同时梯度也能从深层传回浅层^[12]。层归一化使得每一层神经元输入的均值方差尽量保持一致。

3 改进MHA模型

改进的MHA模型是基于原始的Transformer编码器进行相应修改得到的,改进后的MHA模型如图4所示。

3.1 输入嵌入层

所提出的方法用于收集的应变时序数据,将其拆分为 N 个长度为 L 的训练样本,每一个样本划分为 n 个应变时序向,每个应变时序向量的长度为 $d=L/n$ 。因此, N 个样本可以记为 $[T_1, T_2, \dots, T_N]$, $T_i \in \mathbb{R}^{d \times n}$, 其中,

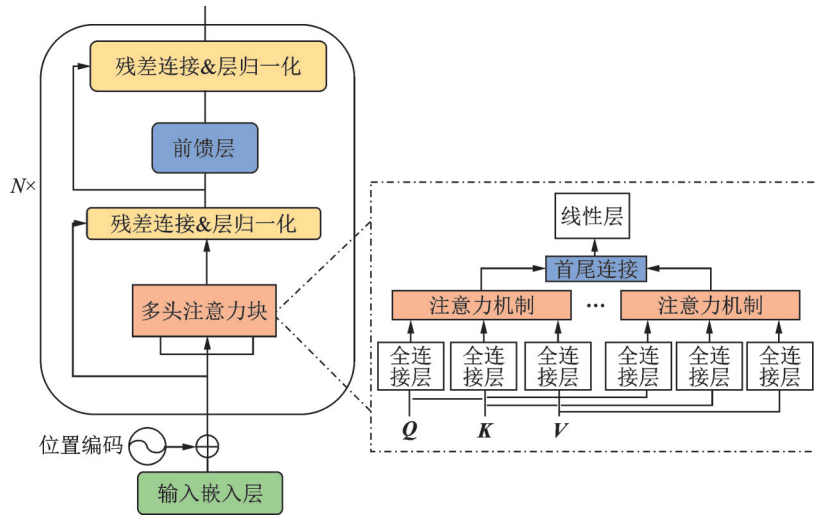


图 3 原始 MHA 模型结构

Fig.3 Structure of MHA model

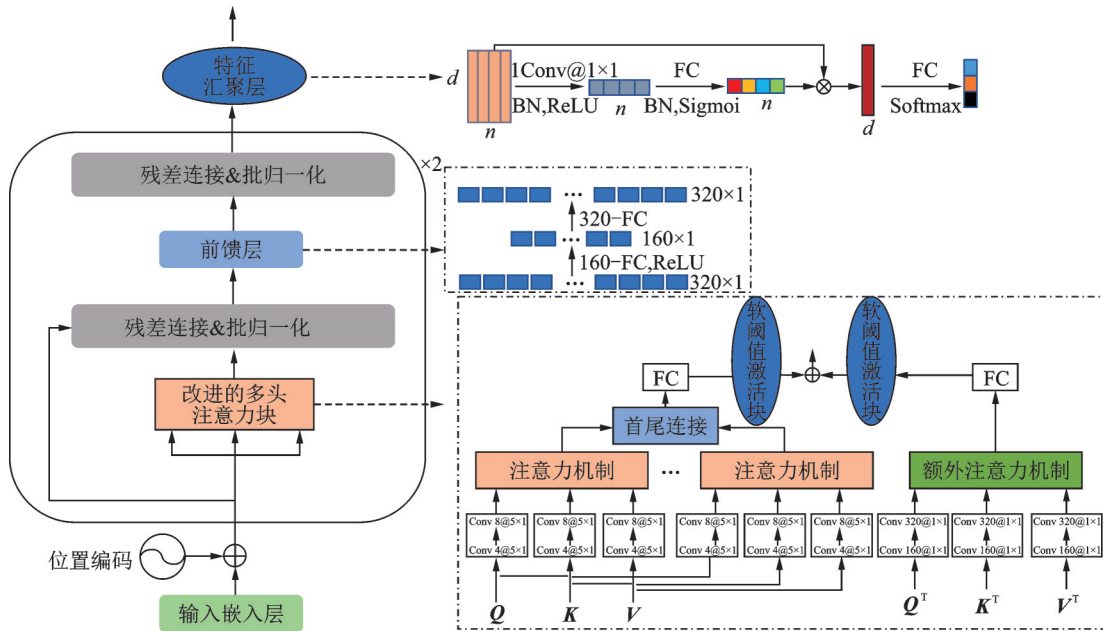


图 4 改进后的 MHA 模型

Fig.4 Improved MHA model

$T_i = [t_1, t_2, \dots, t_n], t_i \in \mathbb{R}^{d \times 1}$ 。单个样本的时序向量划分如图 5 所示。

采用 Dosovitskiy 等^[13]提出的可学习一维位置编码保留应变时序向量的相对位置信息。该方法通过随机初始化一个可学习矩阵来代表不同位置的应

变时序向量间的相对位置关系。其一维位置编码向量 $P_{pose} \in \mathbb{R}^{d \times n}$, 通过式 (1) 对每个应变时序序列 TimeseriesSeq 中的应变时序向量 t_i 添加位置信息, 即

$$\text{TimeseriesSeq} = [t_1, t_2, \dots, t_n] + P_{pose} \quad (1)$$




图 5 单个样本的时序向量划分

Fig.5 Timing vector partitioning for a single sample

3.2 改进的多头注意力块

所提出方法主要将原始模型的全连接层 (full connected layer, 简称 FC) 替换为双卷积层, 并添加一个额外注意力机制和软阈值激活块, 其结构如图 4 所示。

3.2.1 多头注意力机制

自注意力机制常用来建立输入时序序列之间的长距离依赖关系,对于输入的应变时序样本 $T_i = [t_1, t_2, \dots, t_n] \in \mathbb{R}^{d_1 \times n}$, 输出可表示为 $O_i = [o_1, o_2, \dots, o_n] \in \mathbb{R}^{d_2 \times n}$ 。通过全连接层将输入向量映射为3组向量序列

$$Q = W_Q T_i \quad (Q \in \mathbb{R}^{d_2 \times n}) \quad (2)$$

$$K = W_K T_i \quad (K \in \mathbb{R}^{d_2 \times n}) \quad (3)$$

$$V = W_V T_i \quad (V \in \mathbb{R}^{d_2 \times n}) \quad (4)$$

其中: Q, K, V 分别为查询向量序列、键向量序列和值向量序列; $(Q, K, V) = [(q_1, k_1, v_1), \dots, (q_n, k_n, v_n)]$, 可视为与输入样本中 n 组时序向量对应的不同的3份向量; $W_Q \in \mathbb{R}^{d_2 \times d_1}$, $W_K \in \mathbb{R}^{d_2 \times d_1}$, $W_V \in \mathbb{R}^{d_2 \times d_1}$ 分别为可学习的参数矩阵; d_1, d_2 分别为输入时序向量维度和输出向量维度。

输出序列中单个向量 o_k 可通过式(5)~(7)计算得到,其中, $k \in [1, 2, \dots, n]$, 即

$$o_k = \text{Attention}((K, V), q_k) = \sum_{j=1}^n \alpha_{kj} v_j = \sum_{j=1}^n \text{Softmax}(s(k_j, q_k)) v_j \quad (5)$$

$$\text{Softmax}(s(k_j, q_k)) = \frac{s(k_j, q_k)}{\sum_{c=1}^n s(k_c, q_k)} \quad (6)$$

$$s(k_j, q_k) = \frac{k_j^T q_k}{\sqrt{d_2}} \quad (7)$$

通过注意力打分函数 $s(k_j, q_k)$ 与 Softmax 函数, 得到值向量序列 V 中值向量 $v_j, j \in [1, 2, \dots, n]$ 对应的注意力权重 α_{kj} , 并对 V 中 n 个值向量做加权融合, 即可得到与查询向量 q_k 相对应的注意力输出向量 o_k 。通过自注意力机制以及可学习参数矩阵 W_Q, W_K, W_V , 使输出向量 o_k 能够动态地从应变时序样本 T_i 的 n 组时序向量中汇聚与当前位置 k 相关的重要信息, 从而实现输入序列之间的长距离依赖关系。

d_2 为输出向量的维度, $\sqrt{d_2}$ 具有稳定梯度的作用, MHA 模型使用多头注意力机制, 能够提取不同子空间的相似信息。多头注意力机制原理如式(8)、式(9)所示, 其主要过程为并行进行多个注意力机制的计算, 并将每个注意力机制的输出向量首尾连接。

$$O_i = W_o \text{Concat}(H_1, H_2, \dots, H_h) \quad (8)$$

$$H_l = \text{Attention}(W_Q^l T_i, W_K^l T_i, W_V^l T_i) \quad (9)$$

其中: $W_Q^l \in \mathbb{R}^{d_2 \times d_1}$; $W_K^l \in \mathbb{R}^{d_2 \times d_1}$; $W_V^l \in \mathbb{R}^{d_2 \times d_1}$; $l \in [1, 2, \dots, h]$; $W_o \in \mathbb{R}^{d_1 \times h d_2}$, 为注意力机制的输出变换矩阵; h 为注意力机制的数量; H_l 为进行第 l 头的注意力计算结

果; $\text{Concat}(\ast)$ 为进行输出向量首尾拼接的操作; $\text{Attention}(\ast)$ 为注意力机制的计算。

改进模型的 Q, K, V 每一列代表的是一个时序片段, 相邻列为相邻的时序片段。多头注意力机制通过计算 Q 与 K 之间的相关性, 通过一个注意力打分函数 $s(k_j, q_k)$ 与 Softmax 函数, 得到不同位置的时序片段间的注意力权重, 并根据注意力权重融合不同时序片段之间的信息。另外, 所改进模型使用双卷积层替换原始模型的全连接层, 式(9)被替换为

$$H_l = \text{Attention}(\text{Conv}(T_i), \text{Conv}(T_i), \text{Conv}(T_i)) \quad (10)$$

其中: Conv 代表双卷积。

3.2.2 双卷积层

对于原始的多头注意力机制, 分别通过3个全连接层对输入的应变时序向量样本 T_i 线性变换, 而改进的多头注意力机制采用3个卷积块对 T_i 进行线性变换。受自编码器的启发, 每个卷积块包含2层卷积层, 一层对原始数据压缩, 另一层对原始数据复建, 以强迫网络关注重要特征, 卷积层在一定程度上起到了滤波器的作用, 对于数据中的噪声具有一定的抑制作用, 也减轻了原始多头注意力机制的计算量。

3.2.3 额外注意力块

考虑到所提出方法的数据划分处理方式, 以及原始多头注意力机制对相关性的计算方式, 发现原始多头注意力机制对划分的时序向量间的相关性计算方式实际上是延时了一定长度的横向相关性计算, 如图6所示, 而缺少对相邻时刻纵向相关性计算, 如图7所示。

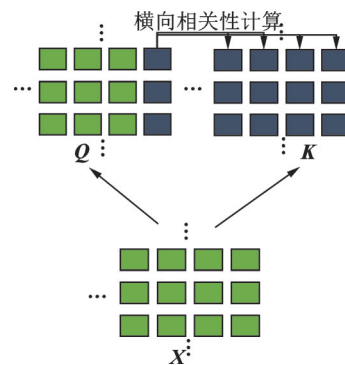


图6 横向相关性计算

Fig.6 Calculation of transverse correlation

因此, 在原始多头注意力的注意力块中额外添加一个局部注意力块, 用于提取相邻时刻之间的相关性, 其主要操作是将 Q, K, V 转置为 Q^T, K^T, V^T 并输入注意力机制中。额外注意力块主要关注同一

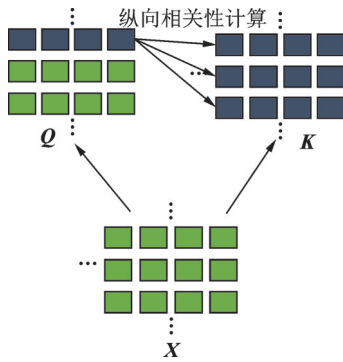


图 7 纵向相关性计算

Fig.7 Calculation of longitudinal correlation

时序向量中相邻时序数据点之间的相关性,并为每个时序数据点分配注意力权重。

3.2.4 可学习的软阈值激活块

实际情况中,输入网络中的数据通常带有噪声,网络虽然能从数据中学习到低层次特征信息,但也会受到数据中噪声的干扰,并在提取特征的同时放大隐含在数据中的噪声。为抑制噪声,可通过软阈值函数将经过网络映射后处于一定范围内的噪声置为 0,但软阈值函数中的阈值参数不易确定。Zhao 等^[14]提出一种可学习的软阈值方法,通过在神经网络中添加软阈值参数的学习分支网络,自动确定软阈值参数,同时保留正负向特征并将噪声信息减弱至 0。可学习的软阈值激活块结构如图 8 所示。




图 8 可学习的软阈值激活块结构

Fig.8 Learnable soft threshold activation block

受该文献的启发,将相应的分支网络集成到所提出模型中作为软阈值激活块,其软阈值可表示为

$$y = \begin{cases} x - \tau & (x > \tau) \\ 0 & (-\tau \leq x \leq \tau) \\ x + \tau & (x < -\tau) \end{cases} \quad (11)$$

其中: τ 为阈值参数。

在软阈值激活块中, n 个应变时序向量通过全局平均后,被压缩为一个 $1 \times n$ 的平均值向量,通过 2 层全连接层与 Sigmoid 层得到被限制在 $(0, 1)$ 范围内的尺度参数向量 $\beta \in \mathbb{R}^{1 \times n}$,即

$$\beta = \frac{1}{1 + e^{-\kappa}} \quad (12)$$

其中: K 为 2 层全连接层的输出。

将尺度参数向量 β 乘 n 个应变时序向量全局平均后的平均值向量,得到阈值向量为

$$\tau = \beta \cdot \text{average}_j |x_{i,j}| \quad (\tau \in \mathbb{R}^{1 \times n}) \quad (13)$$

其中: i 为时序向量的个数; j 为时序向量的长度。

3.3 残差连接和批归一化层与前馈层

由于 NLP 中常涉及到不同的句子长度,使每次处理的词向量个数可能存在不同,因此原始 MHA 模型中使用层归一化。由于囊体时序数据样本的时序向量长度和个数均固定,故采用批量归一化(batch normalization, 简称 BN)减少内部数据特征分布的不确定性,提高模型的泛化能力和收敛速度。

如图 4 所示,前馈层由 2 层全连接层构成:第 1 层激活函数为线性整流函数(linear rectification function, 简称 ReLU),第 2 层不使用激活函数。第 1 层神经元的个数为第 1 层神经元个数的一半,其思想类似于自编码器强迫网络关注重要特征,并根据重要特征重建信息。

3.4 特征汇聚分类块

如图 4 所示,构建的特征汇聚分类块用于综合考虑模型输出的 n 个时序向量的信息,并将特征汇聚为一个向量用于特征分类。

受卷积注意力方式的启发,首先,对于输入的 n 个时序向量,将时序向量的长度维视为通道维,时序向量的位置维视为特征维,通过 1×1 卷积将 n 个时序向量压缩为一个长度为 n 的向量;其次,将其输入全连接层,得到一个长度为 n 的权重向量,此权重向量可视为通过网络自适应学习的 n 个时序向量各自对应的权重;最后,将此权重向量与原始输入的 n 个时序向量相乘,得到长度为 d 的特征融合向量,将此特征融合向量输入全连接层并经过 Softmax 层,即可得到样本属于各个类的概率。

3.5 损失函数

改进的 MHA 模型使用的损失函数为交叉熵损失函数,其损失函数值越小,表明模型的缺陷检测准确率越高,鲁棒性越好。交叉熵损失函数的表达式为

$$L(\theta) = -\frac{1}{B} \sum_{i=1}^B \sum_{j=1}^k I_{c_i=j} \cdot \log(P(c_i=j | x_1, x_2, \dots, x_k; \theta)) \quad (14)$$

其中: I 为指示函数; $P(c_i=j | x_1, x_2, \dots, x_k; \theta)$ 为网

络输出的属于第 j 类的概率。

4 囊体缺陷检测的实验验证

为验证该方法在浮空器囊体缺陷检测中的有效性,收集囊体在2种缺陷和无缺陷下、在一定频率的声波激励下的应变时序数据。基于改进的MHA模型,对所收集的应变时序数据进行特征提取,用于缺陷类别的判定。另外,将所提出的方法与其他几种常见的深度学习诊断方法进行比较,实验结果验证了所提出的方法具有更精确的分类精度,其平均准确度可达97.7%。

4.1 实验

实验使用的囊体是一个长为2.5 m、直径为1.5 m的圆柱形体,两端各有高为0.3 m的球冠,囊体膜的厚度为0.2 mm,抗拉强度超过20 MPa,浮空器囊体表面应变数据收集平台处于安静且环境温度控制在 $25^{\circ}\text{C}\pm 5^{\circ}\text{C}$ 的室内环境中。数据采集实验场地如图9所示。在数据收集过程中,维持囊体内部气压为5 kPa。采用BF120-3AA(11)-P150-D型号的应变片,将其粘贴在囊体表面,同时使用东华测试型号为DH3823的分布式信号测试应变仪,与应变片通过抗干扰RS485总线连接。应变仪与一台作为信号采集终端的Win10系统的华硕笔记本电脑网口通讯。笔者依据扫频法分析囊体频响分布,在幅值较大区域选取定频声波激励频率,并从中选取200 Hz频率作为囊体正弦声波激励信号,通过软件Matlab生成音频函数,并将其导入Presonus厂家生产的型号为E5XT的功放音箱,该功放音箱的频响范围为48 Hz~20 kHz,低频功放功率为45 W,最大声压级为102 dB。功放音箱产生的声波作用在囊体某一个圆柱面上直径大约为150~200 mm的区域,使囊体表面振动。通过粘贴在囊体表面的应变片收集囊体的应变数据,采集频率为2 kHz。




图9 数据采集实验场地

Fig.9 Data acquisition experiment site diagram

首先,实验在无缺陷情况下收集数据;其次,在相同位置切割长为5 mm、宽度为0.1 mm的纵向缺陷,并收集数据;最后,在相同位置添加与纵向缺陷垂直、长为5 mm、宽度为0.1 mm的横向缺陷,并收集数据。

4.2 实验数据

实验收集的数据包括3类:①无缺陷时的囊体表面应变数据;②纵向5 mm切缝时的囊体表面应变数据;③横向5 mm切缝时的囊体表面应变数据。其中,第1类数据的采集时间为500 s,每个应变片共采集近 1×10^6 个数据点,按2 560个数据点划分数据样本集合,则每个应变片能提供390个样本,8个应变片能提供3 120个样本,随机取其中3 000个样本作为第1类数据的样本集合。第2和第3类数据的采集时间均为200 s,每个应变片共采集 4×10^5 个数据点。为使样本平衡,通过重叠采样的技术扩充样本数据,如图10所示。该方法获取的2个样本之间的间隔小于2 560个点,即相邻2个样本之间具有一定的重叠,重叠率为37.5%,从扩充的样本中随机抽取3 000个样本分别作为各自的样本集合。最后将每一类数据按照7:3的比例划分数据集和测试集。实验数据集如表1所示。




图10 重叠采样技术

Fig.10 Overlapping sampling technique

表1 实验数据集

Tab.1 Experimental data set				
故障 标号	缺陷 长度/mm	声波激励 频率/Hz	样本 长度	训练集/ 测试集
N	0	200	2 560	2 100/900
F_1	纵向5	200	2 560	2 100/900
F_2	横纵向5	200	2 560	2 100/900

4.3 模型参数设置

将每个样本划分为8个连续的长度为320的时序向量,作为改进MHA模型的输入,采用2层改进MHA层,每层改进MHA包含4个注意力机制块和1个额外注意力机制块,其余参数见图4。学习率设置为0.000 1,损失函数采用交叉熵损失函数,优化器采用Adam。所改进MHA模型是基于Python 3.8语言以及Pytorch深度学习框架搭建,并在带有RTX2060显卡和AMD Ryzen 7 4800H @2.90 GHz处理器的windows 11平台运行。

4.4 实验结果分析

4.4.1 实验结果精确度分析

将每类数据各2 100个样本作为改进模型的训

练数据集,每类数据各 900 个样本作为模型的测试数据集,验证模型的缺陷检测准确度。模型训练过程可视化图如图 11 所示。随着模型的训练损失下降,模型的训练精确度和测试精确度迅速达到 80% 左右,之后随着迭代次数的增加,模型精确度逐渐达到最高值。在测试集上的平均准确率高达 97.7%。




图 11 模型训练过程可视化图

Fig.11 Visualization of the model training process

改进 MHA 模型在测试集上的混淆矩阵如图 12 所示,网格中的数字代表模型在每一类样本的预测正确数以及所占的比例。可见,对于正常类的区分,模型的预测准确度达到 100%;对于纵向 5 mm 缺陷的预测,模型成功识别了其中 98.2% 的缺陷,剩下 1.8% 被错误预测为横纵向 5 mm 缺陷;对横纵向 5 mm 缺陷,模型成功识别了其中 96.9% 的缺陷,剩下部分基本被错误预测为纵向 5 mm 缺陷。

4.4.2 模型特征提取可视化分析

t 分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, 简称 t-SNE) 方法是一种非线性无监督维度压缩方法,可用于在二维空间中可视化输出每一层的高维特征,通过二维可视化的方法

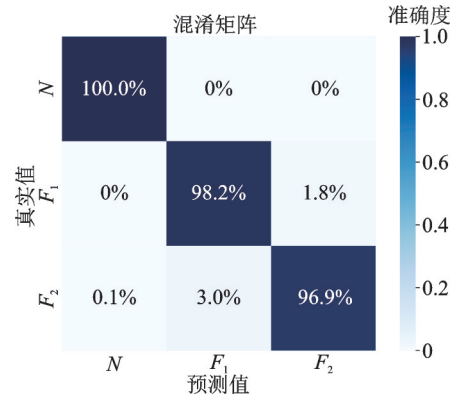


图 12 混淆矩阵

Fig.12 Confusion matrix

能够比较直观地判断高维特征是否被很好的区分^[15]。图 13 为改进 MHA 模型各层 t-SNE 可视化结果。如图 13(a) 所示,改进 MHA 模型中的第 1 层便可较好地地区分囊体表面是否具有缺陷。随着模型的加深,如图 13(b)(c) 所示,2 类缺陷的特征逐渐分离,但 2 类缺陷的聚类拟合效果不明显。在最后的 Softmax 层,如图 13(d) 所示,2 类缺陷的聚类拟合效果较明显,能大致区分,但区分程度不能判断囊体是否具有缺陷明显,且有少量样本分类错误。造成此结果的原因是缺陷集中在同一个位置,一个是纵向 5 mm 缺陷,一个是在相同位置横向和纵向 5 mm 缺陷,且 2 种缺陷本身较小,对囊体材料应力分布的影响不明显。即便如此,改进的 MHA 模型依然能对 2 种缺陷大致区分,同时能很好判定囊体表面是否具有缺陷,而后者的作用在实际中更重要。因此,所提出方法具有很好的特征挖掘以及缺陷检测能力。

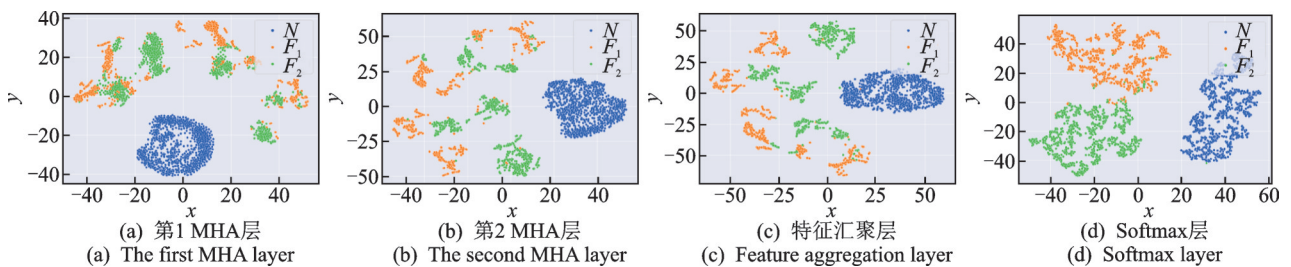


图 13 改进 MHA 模型各层 t-SNE 可视化结果

Fig.13 Improved MHA model t-SNE visualization results for each layer

4.4.3 对比实验结果分析

为了更好地验证改进的 MHA 模型在基于囊体应变时序数据上缺陷检测的有效性,将该模型同原始 MHA 模型、4 层 CNN 与 3 层 LSTM 结合的 CNN_LSTM、9 层 CNN、18 层残差连接网络 (residual network, 简称 Resnet),以及多层感知机 (multi-layer perceptron, 简称 MLP) 模型在相同数据集上

迭代 80 次的检测准确度进行对比。原始 MHA 模型的架构与图 3 相似,采用的是 2 层原始 MHA 层,每层 MHA 包含 4 个注意力机制块。其余 4 个不同模型的架构如图 14 所示。采用的损失函数均为交叉熵损失函数,通过 Adam 优化器迭代训练更新模型参数。表 2 为不同模型缺陷检测对比结果。

由表 2 可知,原始 MHA 模型平均准确率能达到

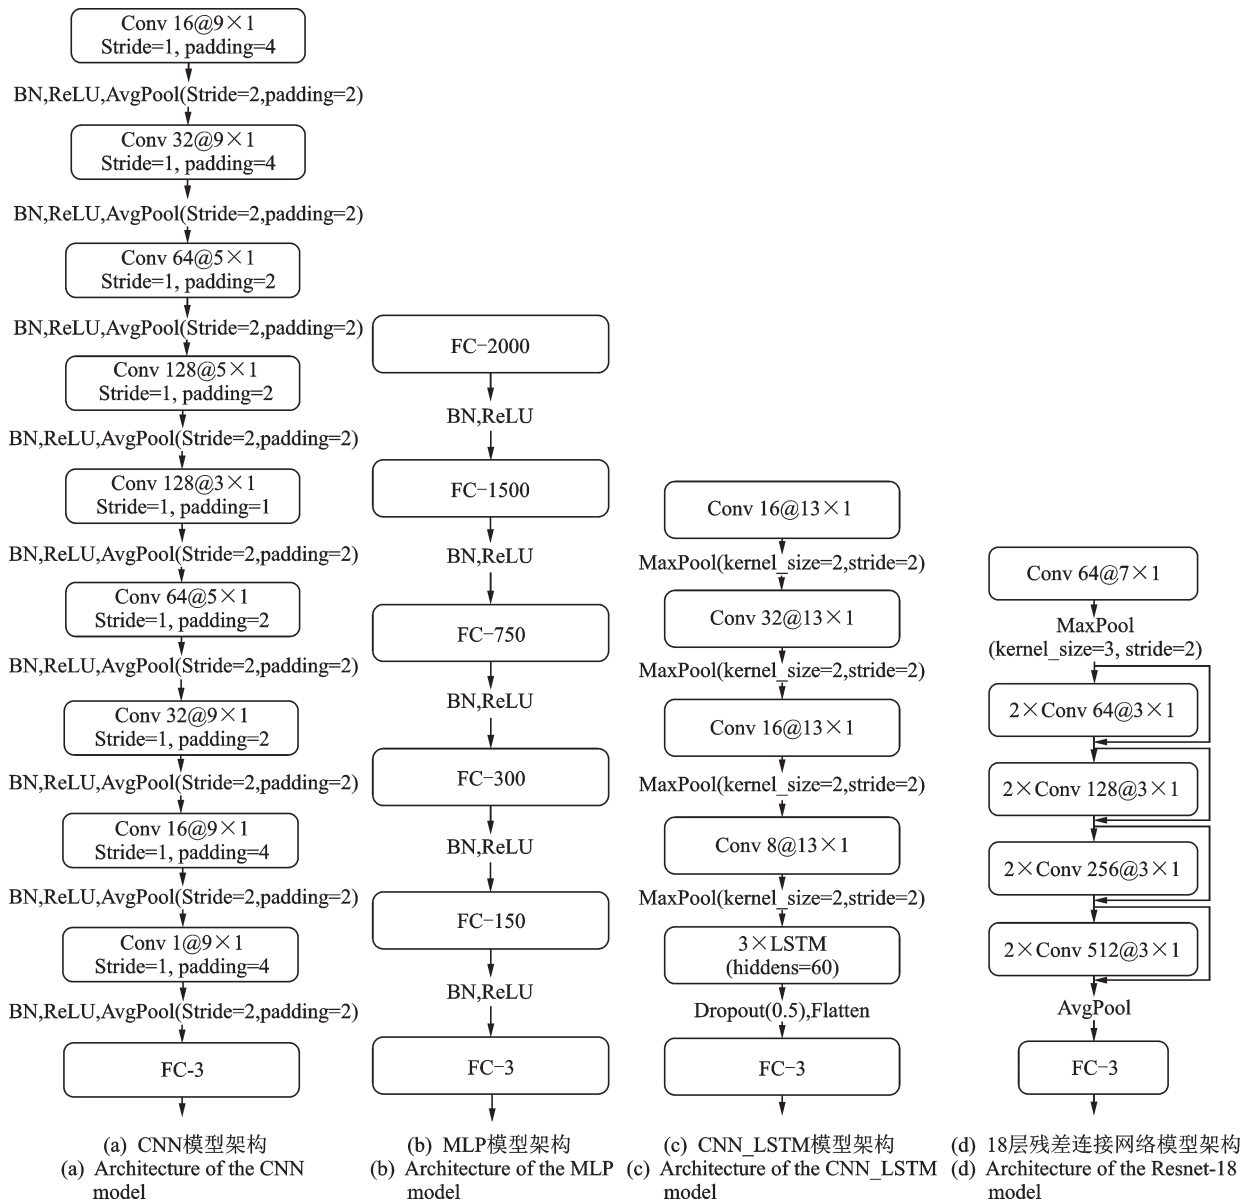


图14 4个不同模型的架构

Fig.14 The architectures of four different models

表2 不同模型缺陷检测对比结果

Tab.2 Comparison results of defect detection for different models

模型	准确率/%
改进的MHA模型	97.7 ± 0.54
18层残差连接网络模型	95.4 ± 0.29
MLP模型	85.4 ± 1.05
CNN_LSTM模型	94.1 ± 1.15
CNN模型	94.8 ± 0.76
原始MHA模型	96.3 ± 0.79

96.3%，已经优于其他4种传统模型的检测准确率，而改进的MHA模型的平均准确率达到97.7%，相比于其他模型具有更高的准确率。因此，改进的

MHA模型在基于囊体应变时序数据上的缺陷检测具有较高的准确率，验证了该方法的有效性。

5 结论

1) 基于MHA模型能更好地对时序数据的长程依赖性建模，使模型能够更好地提取缺陷特征。

2) 在原始MHA层中添加可学习的软阈值激活块，能更好地抑制数据中的干扰噪声，提升模型的稳健性。

3) 在原始的多头注意力的基础上，额外添加一个自注意块，并以查询向量、键向量以及值向量的转置作为输入，能更好地关注相邻时序点之间的相关性。

4) 改进的MHA模型在囊体缺陷检测上平均达

到97.7%的准确率,相比于传统的卷积网络模型具有更高的检测准确率。

参 考 文 献

- [1] 张云浩,阿力木·安外尔,米翔,等.短期老化与折皱损伤对飞艇囊体材料空气泄漏性能的影响[J].上海交通大学学报,2020,54(11):1189-1199.
ZHANG Yunhao, ANWAIER Alimu, MI Xiang, et al. Effects of short-term aging and creasing damage on air leakage properties of airship envelope materials[J]. Journal of Shanghai Jiaotong University, 2020, 54(11): 1189-1199. (in Chinese)
- [2] 冯琪智.基于红外热成像的复合材料无损检测研究[D].成都:电子科技大学,2018.
- [3] 凡丽梅,董方旭,段剑,等.快速无损检测技术在复合材料构件中应用与发展[J].南昌航空大学学报(自然科学版),2021,35(4):32-38.
FAN Limei, DONG Fangxu, DUAN Jian, et al. Application and development of faster non-destructive testing technology in composite materials [J]. Journal of Nanchang Hangkong University (Natural Sciences), 2021, 35(4): 32-38. (in Chinese)
- [4] 张全利,曾加恒,杨振,等.碳纤维复合材料缺陷的超声检测及材料力学性能仿真研究[J].机械制造与自动化,2022,51(1):136-141.
ZHANG Quanli, ZENG Jiaheng, YANG Zhen, et al. Ultrasonic detection of defects and simulation of mechanical properties for carbon fiber composites[J]. Machine Building & Automation, 2022, 51(1): 136-141. (in Chinese)
- [5] 李浩然,陆金桂.基于分块阈值LBP算法的光学薄膜表面缺陷分割[J].南京工业大学学报(自然科学版),2020,42(5):594-599.
LI Haoran, LU Jingui. Segmentation of optical thin film surface defects based on LBP algorithm with block threshold values [J]. Journal of Nanjing University of Technology (Natural Science Edition), 2020, 42(5): 594-599. (in Chinese)
- [6] 王宏硕,杨永跃.基于改进显著性模型的TFT-LCD面板缺陷检测[J].电子测量与仪器学报,2018,32(7):29-35.
WANG Hongshuo, YANG Yongyue. Surface defect inspection of TFT-LCD panels based on improved saliency model[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(7): 29-35. (in Chinese)
- [7] EREN L, INCE T, KIRANYAZ S. A generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier [J]. Journal of Signal Processing Systems, 2019, 91(2): 179-189.
- [8] JIN G Q, ZHU T Y, AKRAM M W, et al. An adaptive anti-noise neural network for bearing fault diagnosis under noise and varying load conditions [J]. IEEE Access, 2020, 8: 74793-74807.
- [9] MNIH V, HEESS N, GRAVES A, et al. Recurrent models of visual attention [C] // Proceedings of the 27th International Conference on Neural Information Processing Systems: Volume 2. Montreal, Canada: MIT Press, 2014: 2204-2212.
- [10] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate [DB/OL]. (2014-09-01) [2022-10-05]. <https://arxiv.org/abs/1409.0473>.
- [11] 刘相,严刚,汤剑飞.基于应力波的复合材料圆柱壳结构损伤概率成像研究[J].复合材料科学与工程,2021(9):5-11.
LIU Xiang, YAN Gang, TANG Jianfei. Stress wave-based damage probability imaging for composite cylindrical shell structures [J]. Composites Science and Engineering, 2021(9): 5-11. (in Chinese)
- [12] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [13] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: transformers for image recognition at scale [DB/OL]. (2020-10-22) [2022-10-05]. <https://arxiv.org/abs/2010.11929>.
- [14] ZHAO M H, ZHONG S S, FU X Y, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4681-4690.
- [15] WEN L, LI X Y, GAO L. A transfer convolutional neural network for fault diagnosis based on ResNet-50 [J]. Neural Computing and Applications, 2020, 32(10): 6111-6124.



第一作者简介:卢志强,男,1999年12月生,硕士生。主要研究方向为机械故障诊断和寿命预测。

E-mail: m202170599@hust.edu.cn

通信作者简介:朱海平,男,1975年9月生,博士、教授。主要研究方向为制造系统建模与优化。

E-mail: haipzhu@hust.edu.cn