

# 基于机器学习的汽车吸能结构耐撞性智能预测方法

贺宏伟<sup>1</sup>, 余海燕<sup>1</sup>, 高 泽<sup>1</sup>, 饶卫雄<sup>2</sup>

(1. 同济大学汽车学院, 上海 201804; 2. 同济大学软件学院, 上海 201804)

**摘要:** 汽车零部件正向设计中, 为快速预测所设计的吸能结构的碰撞吸能特性, 以吸能盒为研究对象, 通过有限元压溃变形仿真生成数据集, 训练得到一种新的可识别几何结构和记忆时序特征的预测模型。模型通过基于图的编码器进行几何结构识别, 采用长短期记忆网络和图卷积神经网络处理时序数据, 并输出预测结果。对比表明: 吸能盒压溃形态预测结果与有限元仿真结果一致, 压溃变形量的预测精度可达 95.33%, 最大吸能值的预测精度可达 99.98%。预测模型相较于有限元计算, 其计算效率分别提高了 174.5 倍和 210.5 倍, 可以快速准确地预测吸能盒的碰撞性能。

**关键词:** 汽车吸能盒; 耐碰撞性; 有限元分析; 机器学习; 图卷积神经网络; 长短期记忆神经网络

中图分类号: U463; TP181

文献标志码: A

## Machine Learning Method for Intelligent Prediction of the Crashworthiness of Automotive Energy Absorbing Boxes

HE Hongwei<sup>1</sup>, YU Haiyan<sup>1</sup>, GAO Ze<sup>1</sup>, RAO Weixiong<sup>2</sup>

(1. School of Automotive Studies, Tongji University, Shanghai 201804, China; 2. School of Software, Tongji University, Shanghai 201804, China)

**Abstract:** This study aims to achieve intelligent prediction of collision energy absorption characteristics of new structures in forward design of automotive parts. An energy-absorbing box is taken as the research object to generate training data sets by finite element crush deformation simulation. A graph-based encoder is adopted for geometric structure recognition. Long and short-term memory networks and graph convolutional neural networks were used to process adjacent temporal data. The novel neural network prediction system proposed can recognize geometric structures and memorize temporal data. The comparison between the model prediction results and simulation results shows that the predicted

crush pattern of the energy-absorbing box is consistent with the finite element simulation results, and the prediction accuracy of the model for the crush deformation amount can reach up to 95.33%, while the prediction accuracy of the maximum energy absorption value can reach 99.98%. Compared with the finite element calculations, computational efficiency is 174.5 times and 210.5 times higher respectively, which manifested that the system can accurately and quickly predict the crash performance of the energy-absorbing box.

**Keywords:** energy-absorbing box; crashworthiness; finite element simulation; machine learning; graph convolution networks; long short-term memory

传统的汽车和零部件生产厂商在设计和开发产品的过程中, 都是通过计算机辅助设计(CAE)来计算产品的力学性能, 其中有限元方法(FEM)作为一种广泛应用的分析结构和连续体的数值分析方法, 可以准确预测结构在外力作用下的变形和振动等问题的数值解<sup>[1]</sup>。但由于汽车安全性和轻量化的要求越来越高, 需要有限元求解的问题也越来越复杂, 通常情况下, 一些结构的细微变化都需要重新建模和计算, 因此需要消耗大量的计算时间。随着人工智能的发展, 机器学习(ML)已成为此类问题的一种高效率解决方案<sup>[2]</sup>。特别是在汽车零部件的设计中, 往往已经有大量的仿真样本, 而机器学习善于从这些样本中找到潜在的映射关系, 从而预测结构在外力作用下的响应。目前, 已有许多学者利用机器学习在此方面开展探索, 如流体仿真<sup>[3-4]</sup>、拓扑优化<sup>[5-6]</sup>、应力预测<sup>[7]</sup>及物理行为仿真<sup>[8-9]</sup>等。机器学习与有限元仿真的融合已经成为一种发展趋势。

神经网络是机器学习的一个分支, 它在预测结构性能、损伤和断裂等问题方面已经被广泛应用, 许

收稿日期: 2023-12-01

基金项目: 国家重点研发计划项目(2022YFE0208000)

第一作者: 贺宏伟(1999—), 男, 硕士研究生, 主要研究方向为汽车轻量化及机器学习在汽车上的应用。E-mail: 2233517@tongji.edu.cn

通信作者: 余海燕(1976—), 女, 教授, 博士生导师, 工学博士, 主要研究方向为汽车轻量化。E-mail: yuhaiyan@tongji.edu.cn

多学者针对这些问题提出了不同的方法。例如, Chen<sup>[10]</sup>等人开发了一种具有注意力机制的数据驱动故障模型,可以用于冷轧镀锌钢带表面缺陷的检测和分类。Xu<sup>[11]</sup>等人提出了一种将有限元法和卷积神经网络结合的框架,用于环形异形装药系统的优化设计。Shamass<sup>[12]</sup>等人提出了一种预测开口钢梁屈曲阻力和破坏模式的模型。此外,有研究人员开始尝试在神经网络中引入时间特征,以更好地预测结构的时间相关特性<sup>[13-16]</sup>。因此,神经网络在结构性能预测中具有巨大潜力,并且不断有新的方法和技术被提出用于提高预测的准确性和效率。在先前的研究中,学者们针对二维结构或者具有特定参数的结构做了大量研究,取得了不少成果,尤其是卷积神经网络的应用<sup>[17-19]</sup>。然而,实际工程案例中的几何结构往往是三维的,因此三维结构特征的学习和表示应成为关注的重点,这对神经网络解决更多结构分析问题具有重要意义<sup>[20-21]</sup>。值得注意的是, Kohar<sup>[22]</sup>等人提出了一种基于 3D 卷积神经网络和长短期记忆神经网络的模型来模拟方管的破碎过程,通过体素化的方法识别方管的几何结构,并有效地捕捉了破碎的动态过程。然而,3D 卷积神经网络受限于体素化过程的分辨率,对于薄壁结构等一类问题,体素空间大多未被占用<sup>[23-24]</sup>,而对于更复杂的结构,则很难捕捉到其几何特征。为了克服这些限制,图神经网络<sup>[25]</sup>成为了一个备受关注的解决方法。图神经网络近年来发展迅速,已成功应用于多个领域<sup>[26-28]</sup>。例如, Tobias<sup>[29]</sup>等人设计了一种基于网格的图神经网络仿真框架,可以表示有限元网格节点之间的关系,可应用于空气动力学、固体力学和结构力学等多个领域。

在诸多研究中可以发现,利用神经网络可以实现结构力学性能的预测,但在三位几何结构的学习和表达上还有诸多不足。因此,本文以汽车吸能盒为研究对象,基于图卷积神经网络和长短期记忆神经网络搭建预测模型,来预测吸能盒在特定工况下的压溃变形和吸能特性。

## 1 耐撞性预测算法

### 1.1 图卷积神经网络

卷积神经网络(CNN)在图像处理方面表现出色,善于捕捉图像中潜在的特征信息。而图像本身可被视为具有规则网格状结构的图,其单个像素是节点,每个 RGB 通道值都被用作节点特征。相比之

下,图可以表示节点之间的拓扑关系,即表示为节点、边和全局属性的集合。图卷积神经网络(graph convolutional neural networks, GCN)可以通过对每个节点进行卷积来实现节点属性的更新,通过相邻节点和更远的节点来改变其状态,其中不同的相邻节点具有不同的效果<sup>[30-31]</sup>。GCN 通过邻接矩阵  $A$  和拉普拉斯矩阵  $L$  来衡量节点与邻居节点之间的关系。拉普拉斯矩阵的定义为:

$$L = D - \frac{1}{2} \hat{A} D^{\frac{1}{2}} \quad (1)$$

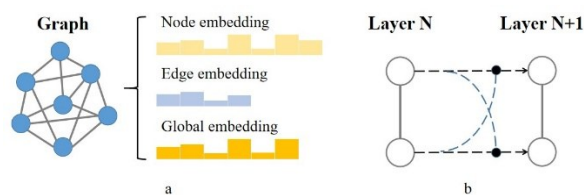
$$\hat{A} = D - A \quad (2)$$

式中:  $D$  是度矩阵,其只有对角线上有值,表示节点的度。对图形进行一次卷积计算后,图形上所有节点的嵌入信息都会被传递和更新。节点属性的更新可以表示为:

$$H = \sigma \left( D^{-\frac{1}{2}} \hat{A} D^{\frac{1}{2}} X W \right) \quad (3)$$

式中:  $H$  是更新后的特征矩阵,包含所有节点更新后的特征;  $\sigma$  是激活函数;  $X$  是更新前的特征矩阵;  $W$  是可学习的参数。该算法通过卷积聚合邻居节点和节点本身特征,实现信息的传递和更新。

图 1 表示了图的基本组成和图卷积神经网络的计算过程。在模拟薄壁结构变形的过程中,图卷积神经网络算法用于识别几何结构,通过每次更新后的节点特征信息以得到结构随时间变化产生的变形。



(a)图的基本组成和

(b)图卷积计算过程

图 1 图卷积神经网络基本组成与计算过程

Fig. 1 Basic structure of graph and Message passing with graph convolution

### 1.2 长短期记忆网络

图 2 为长短期记忆神经网络(LSTM)单元的结构图。其中,  $h_{t-1}, c_{t-1}$  为上一时刻的输出和细胞状态;  $f_t$  为遗忘门,控制上一时刻有多少输出信息添加到当前时刻的记忆中;  $g_t$  为候选门,控制当前输入信息和上一时刻输出信息的混合;  $i_t$  为输入门,控制当前时刻输入信息多大程度添加至记忆中;  $o_t$  为输出门,控制记忆输出用于下一层网络计算。相关门的计算方式为<sup>[32]</sup>:

$$i_t = \sigma(W_{ii}x_t + b_{ii} + W_{hi}h_{t-1} + b_{hi}) \quad (4)$$

$$f_t = \sigma(W_{if}x_t + b_{if} + W_{hf}h_{t-1} + b_{hf}) \quad (5)$$

$$g_t = \tanh(W_{ig}x_t + b_{ig} + W_{hg}h_{t-1} + b_{hg}) \quad (6)$$

$$o_t = \sigma(W_{io}x_t + b_{io} + W_{ho}h_{t-1} + b_{ho}) \quad (7)$$

式中:  $\sigma$ 、 $\tanh$  分别表示一种激活函数;  $W = [W_{ii}, W_{if}, W_{ig}, W_{io}, W_{hi}, W_{hf}, W_{hg}, W_{ho}]$  和  $b = [b_{ii}, b_{if}, b_{ig}, b_{io}, b_{hi}, b_{hf}, b_{hg}, b_{ho}]$  为可学习的权重和偏差。单元状态和每一时刻隐藏层状态计算方式为:

$$c_t = f_t \odot c_{t-1} + g_t \odot i_t \quad (8)$$

$$h_t = o_t \odot \tanh(c_t) \quad (9)$$

式中:  $\odot$  为哈达玛积运算符, 表示将每一时刻的隐藏状态输出以得到具有时间序列信息的结果。LSTM 确保了由网格生成图之后节点的时序特征, 由于 LSTM 单元计算过程中节点之间相互独立, 因此数据在经过 LSTM 单元之后再通过 GCN 进行节点之间的信息传递和更新<sup>[33]</sup>。




图2 LSTM单元结构

Fig. 2 Schematic structure of LSTM cell

### 1.3 变形-吸能预测模型

在有限元分析过程中,几何模型可以通过划分成网格的形式在有限元软件中表示,但这些网格信息难以直接传递到机器学习框架中。因此,该预测模型需要学习有限元模型数据中隐藏的信息,以区分不同的几何结构信息。然后利用学习到的这些几何结构信息,来预测在外界工况下变形-吸能特性的响应。预测模型的过程总结为以下3个部分。

#### 1.3.1 多层感知机编码器

多层感知机(MLP)又称人工神经网络,通过一个全连接网络可将输入数据集映射到输出数据集<sup>[34]</sup>。它由输入层、隐藏层和输出层组成。首先处理有限元网格信息,提取网格节点坐标  $\{x_n, y_n, z_n\}$ , 单元编号  $\{N_{ele}^{(n)}\}$ , 和组成单元的节点的编号  $\{N_{node}^{(i)}, N_{node}^{(j)}, N_{node}^{(k)}, N_{node}^{(l)}\}$ , 以及单元属性  $p$ , 编码成图。其图可以表示为:

$$G = (u, V, E) \quad (10)$$

式中:  $u$  为全局属性;  $V$  为节点的集合;  $E$  为边的集合。图中的节点重新编号为  $\{N_0, N_1, N_2, \dots\}$ , 初始的节点特征为节点坐标。每次图进行更新计算中, 节点集合的属性 and 边集合的属性可以用特征矩阵  $H$ , 和邻接矩阵  $\hat{A}$  表示。编码器的输入为:

$$V_{in\_MLP} = \{N_s, (x_s, y_s, z_s), p\}, s \in V \quad (11)$$

编码器将输入矩阵  $V_{in\_MLP}$  转化为隐藏的特征空间  $V_{out\_MLP}$ , 来识别结构的几何特征。特征空间的特征矩阵可以表示为:

$$H_{out\_MLP}: \{v_0^s\} \leftarrow \text{MLP}(N_s, (x_s, y_s, z_s), p), s \in V \quad (12)$$

边的信息通过读取单元包括的相邻节点的编号获得, 从而生成初始的邻接矩阵  $A$ , 其中  $a_{ij}$  表示初始邻接矩阵对应位置的元素。如果有限元模型的  $N_{node}^{(i)}$  节点和  $N_{node}^{(j)}$  节点相邻, 则对应元素  $a_{ij}$  为 1, 初始邻接矩阵没有节点连接的对应位置填充为 0, 然后经过归一化得到邻接矩阵  $\hat{A}$ 。编码器输出的特征矩阵  $H_{out\_MLP}$ , 和邻接矩阵  $\hat{A}$  作为输入参与信息传递和更新模块的计算。

#### 1.3.2 信息传递和更新

编码后的节点特征矩阵作为 LSTM 模块的输入, 用于独立计算每个节点的特征信息, 得到具有时序特征的节点属性。LSTM 模块的计算过程可以表示为:

$$H_{out\_LSTM}: \{v_1^s, v_2^s, \dots, v_t^s\} \leftarrow \text{LSTM}(\{v_0^s\}), s \in V \quad (13)$$

根据 LSTM 模块输出的特征信息, 可以得到每个时刻的特征矩阵和相互独立的节点属性  $\{v_1^s, v_2^s, \dots, v_t^s\}$ 。为了得到更新图的边属性和全局属性, 通过图卷积网络在节点间传递和更新信息, 从而得到每个时刻对应的图。GCN 模块的计算过程可以表示为:

$$H_{out\_GCN}: \{v_1^s, v_2^s, \dots, v_t^s\} \leftarrow \text{GCN}(\{v_1^s, v_2^s, \dots, v_t^s\}, \hat{A}), s \in V \quad (14)$$

每个图都包含潜在的节点特征空间和边的属性, 以此来预测该时刻下的节点坐标和整体内部能量变化。图3为信息传递和更新过程的框架。

#### 1.3.3 多层感知机解码器

通过多层感知器对图中包含的节点特征信息进行解码, 得到每个时刻的节点坐标和结构的吸能特性。解码器对结构  $t$  时刻输出结果的计算公式为:

$$\{(x_t^s, y_t^s, z_t^s), u_t\} \leftarrow \text{MLP}(\{v_t^s\}), s \in V \quad (15)$$

式中:  $(x_t^s, y_t^s, z_t^s)$  为节点坐标;  $u_t$  为全局属性, 用于预测结构的能量吸收特性。

变形预测的训练采用均方误差(MSE)作为损失






图3 信息传递和更新

Fig. 3 Passing and updating process

函数。同时对每个图形中包含的全局属性  $\{u_1, u_2, \dots, u_t\}$ , 进行解码, 得到每个时刻的内能变化, 并使用平均绝对误差(MAE)作为内能预测训练的损失函数, 以此实现对网格变形结果的预测和对能量吸收特性的预测。图4为变形-吸能特性预测模型的框架示意图。

## 2 有限元分析和数据集生成

汽车的吸能盒位于前横梁和前纵梁之间, 主要作用是通过自身的压溃变形来吸收汽车碰撞产生的动能, 并将前保险杠传递过来的碰撞力以更均匀地方式传递到车身的前纵梁上。分析吸能盒的变形规律和吸能特性, 对车身设计和轻量化设计具有重要意义<sup>[35]</sup>。

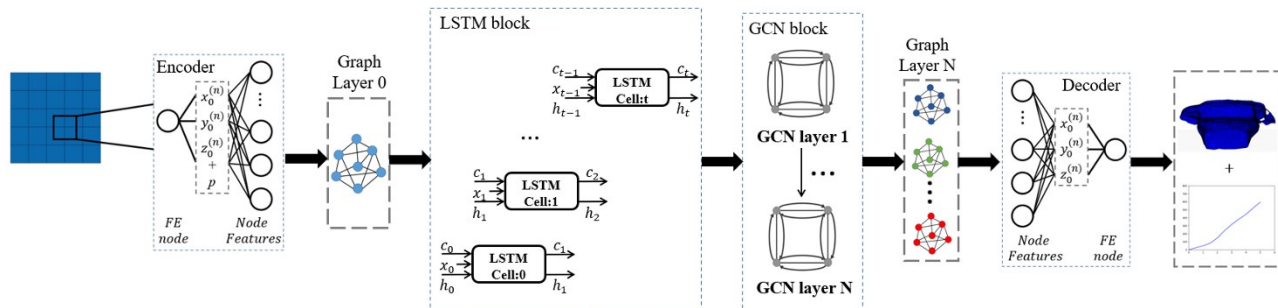


图4 变形-吸能预测模型框架

Fig. 4 The schematic framework of prediction system

### 2.3 吸能盒仿真结果

汽车吸能盒结构的耐撞性通常通过压溃变形和吸能特性来表示<sup>[39]</sup>。从验证集中随机选取一样本进行分析, 该样本吸能盒厚度为2.637 mm。碰撞仿真往往需要计算内能变化和沙漏能变化。沙漏能是由

### 2.1 有限元模型

采用壳单元建立有限元模型, 可以生成具有不同厚度属性的有限元模型。图5为有限元模型, 共有2 885个节点和2 758个单元。吸能盒模型采用Belytschko-Tsay壳单元, 材料为铝合金, 设置为双线性弹塑性材料(MAT\_24), 材料属性见表1。吸能盒的一侧设置为固定约束, 另一侧设置一刚性平板进行碰撞。刚性平板的初始速度设置为40 km/h<sup>[36]</sup>。吸能盒自身采用“AUTOMATIC\_SINGLE\_SURFACE”算法, 吸能盒和刚性板之间的接触采用“AUTOMATIC\_SURFACE\_TO\_SURFACE”接触算法。静摩擦系数设置为0.3, 动摩擦系数设置为0.2<sup>[37]</sup>。

### 2.2 样本空间

实验设计了具有不同厚度的吸能盒模型进行仿真模拟, 同时生成数据集以供神经网络框架学习以区分不同结构。设置碰撞停止时间为5.0 ms。为了更好地观察吸能盒碰撞过程中的内能变化, 每1.0 ms输出一次变形结果, 每0.5 ms输出一次吸能盒的内能。图6显示了变形预测模型和吸能预测模型的数据集空间分布。采用拉丁超立方采样(LHS)方法<sup>[38]</sup>设置实验变量, 使用LS-Dyna软件在Inter Core i7-12700H处理器计算, 生成数据集。为训练变形预测模型, 生成了30组实验数据, 总计算时间为17 min 28 s, 每个样本的平均计算时间为34.9 s。为训练吸能预测模型, 生成了40组实验数据, 总计算时间为28 min 40 s, 每个样本的平均计算时间为42.1 s。

于缩减积分单元的计算方式导致的应变和应力为零的现象, 在碰撞仿真的过程中, 一般要求整体沙漏能的最大值不超过整体内能最大值的5%<sup>[40]</sup>。图7为吸能盒的内能变化结果和沙漏能变化结果。最大沙漏能为9.18 kJ, 最大内能为595.04 kJ。总体沙漏能




图5 有限元模型和边界条件  
Fig.5 FE model and boundary conditions

表1 吸能盒材料属性

Tab.1 Material properties of the energy-absorbing box

Material	$E/\text{GPa}$	$\rho/(\text{g}\cdot\text{mm}^{-3})$	$\mu$	$\sigma_{0.2}/\text{MPa}$
Aluminum alloy	70.0	$2.7\times 10^{-3}$	0.33	210

约为内能的1.5%,说明吸能盒的有限元计算结果是可靠的。同时分析该样本吸能盒在每个时刻的变形情况,最大变形出现在吸能盒与刚性平板的碰撞一侧的边缘处,最大变形量为73.114 mm。





图6 样本空间分布:(a)变形预测,(b)吸能预测

Fig. 6 Dataset distribution of (a) deformation prediction, (b) energy-absorbing prediction





图7 吸能盒有限元计算结果:(a)沙漏能,(b)内能

Fig. 7 Simulated energy curves of energy-absorbing box by FEM (a) hourglass energy (b) internal energy

### 3 结果分析

本文探索了不同网络结构对几何结构信息的捕捉能力和对网格变形的预测能力,并最终确定了一种具有确定深度和神经元数量的网络框架。在多层感知机编码器部分和图卷积神经网络部分均采用ReLU单元作为激活函数,该函数具有计算高效的

特点。采用Adam优化方法,该算法可以自动调整学习率,适用于噪声较大的问题,同时计算高效,需要内存也较小<sup>[41]</sup>。

#### 3.1 压溃变形预测

压溃变形预测数据集被拆分,其中80%作为模型的训练集。由于数据中的所有节点都包含相同大小和幅度的坐标信息,因此在训练过程中没有对这

些数据进行归一化处理。均方误差(MSE)作为损失函数,用于评估模型输出相对于理想输出数据的误差。图8显示了训练集和验证集的损失收敛情况。

对整个数据集进行了10 000次训练,训练集和测试集的损失均迅速收敛。训练集损失函数收敛到

最小值为1.826 mm<sup>2</sup>,测试集损失函数收敛到最小值为6.850 mm<sup>2</sup>。损失的收敛情况说明该模型对于吸能盒碰撞变形的预测是有效地。预测模型平均每次计算时长为0.2 s,相比于有限元计算速度提高了174.5倍,计算效率显著提升。

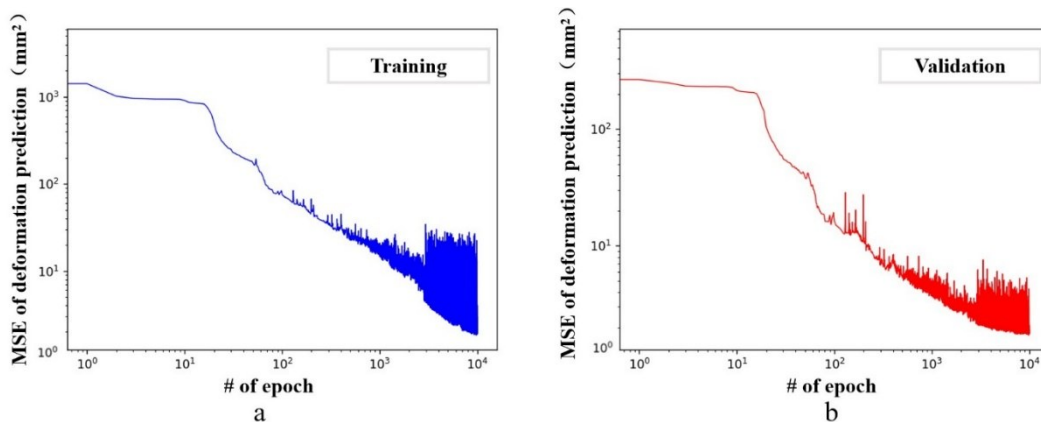


图8 变形预测模型的(a)训练集损失曲线和(b)测试集损失曲线

Fig. 8 Histogram of loss for (a) training set and (b) validation set

图9为测试集中厚度2.637 mm吸能盒样本的不同时刻的变形预测模型计算结果(ML Prediction)和有限元计算结果(FE Simulation)的对比。机器学习预测模型对于识别吸能盒结构具有良好的效果,同时很好地捕捉了吸能盒随着碰撞进行,发生压溃

变形的趋势。说明了该模型可以有效地预测吸能盒的变形。图10为变形预测模型预测得到的变形云图,预测最大变形为76.528 mm,与有限元结果误差为4.67%,最大变形的的位置与有限元计算结果相同,说明对最大误差的预测较为准确。




图9 机器学习预测模型与有限元计算的压溃变形预测结果

Fig. 9 Calculated collapse deformation by ML prediction and FE simulation

表2为测试集中厚度2.637 mm的吸能盒样本计算所得到的位移预测结果与有限元计算结果的误差。误差计算式为:

$$Err_i^t = \sqrt{(\tilde{x}_i - x_i)^2 + (\tilde{y}_i - y_i)^2 + (\tilde{z}_i - z_i)^2} \quad (16)$$

式中:  $\tilde{x}_i$ ,  $\tilde{y}_i$ ,  $\tilde{z}_i$  为节点坐标的预测值。

分别计算预测结果中每个节点的误差。通过机器学习模型预测得到的变形结果,平均误差随着时间增加逐渐增大,说明该模型的预测精度对于时间的增加和变形量的逐渐增大有逐渐下降的趋势,并且平均误差在  $t=4.0$  ms 和  $t=5.0$  ms 时迅速增加。同样,在碰撞结束后,即碰撞时间和变形量均达到峰



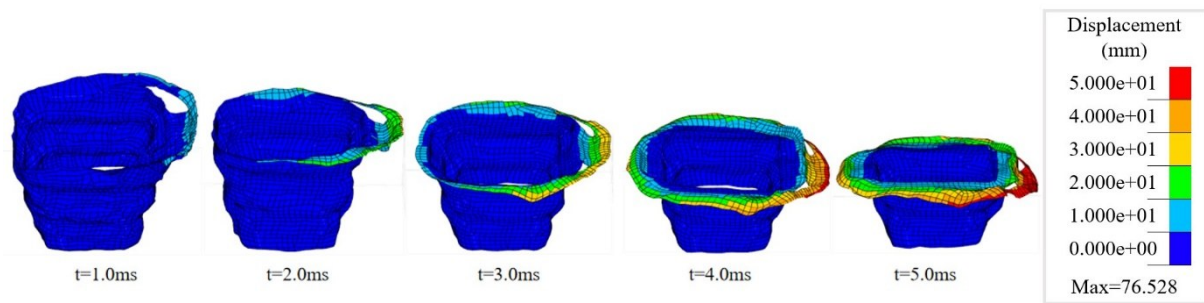


图 10 机器学习预测模型计算的位移云图

Fig.10 Predicted displacement by ML prediction

值时,最大误差也达到峰值。节点的位移误差代表了模型对吸能盒变形之后的结构捕捉能力,说明该模型对吸能盒碰撞产生的变形预测的精度随着时间增大逐渐下降,但整体误差仍在可接受范围,有效地捕捉了结构的变形趋势。

同样对于该吸能盒样本,通过机器学习模型预

表 2 机器学习模型与有限元计算的节点误差

Tab.2 Node errors between the displacement of ML and FE simulation

Time/ms	1.0	2.0	3.0	4.0	5.0
Mean $Err_t^i$ /mm	1.543	1.576	1.606	2.467	3.850
Max $Err_t^i$ /mm	6.472	9.516	8.754	11.623	12.927

测后得到结果的单元误差计算方式为:

$$Ele\_Err_t^i = \frac{1}{n} \sum_{i=1}^n Err_t^{ele(n)} \quad (17)$$

由于使用的是壳单元模型,每个单元都包括多个节点,单元误差由单元中节点的误差计算得出。图 11 显示了变形预测的单元误差。随着时间的增加,碰撞后吸能盒的变形逐渐增大,与有限元计算结果相比,由机器学习模型得到的预测结果单元误差逐渐增大。碰撞结束时,单元计算误差达到最大值 11.334 mm。最大误差出现在吸能盒与刚性平板接触一侧的边缘,该处存在较大变形,因此机器学习模型预测的结果也产生了较大误差。




图 11 机器学习模型与有限元计算的单元误差

Fig. 11 Element errors of displacement between ML prediction and FE simulation

### 3.2 吸能盒吸能预测

本文探索了不同深度和隐藏状态的网络模型,最终确定了吸能预测模型。吸能盒内能数据的范围会随着设计变量不同产生较大的差异,这会给神经网络学习捕捉内能变化规律的过程带来不良的影响。因此在训练过程中,对吸能数据进行了归一化,归一化计算公式为:

$$E' = \frac{(E - E_{\min})}{(E_{\max} - E_{\min})} \quad (18)$$

式中: $E_{\max}$ 和 $E_{\min}$ 为样本数据中的最大值和最小值。采用平均绝对误差(MAE)作为损失函数进行训练,

以评估模型预测数据与真实数据之间的误差。图 12 分别为模型训练过程的损失变化,可以看出,训练集和测试集的损失均迅速下降,测试集误差最低下降到 0.005 mm,说明模型可以稳定地得到预测结果。

图 13 显示了吸能预测模型和有限元仿真对验证集中不同样本的预测结果。图 14 显示了机器学习预测与有限元模拟之间的绝对误差和相对误差。可以看出,吸能预测模型可以有效地预测吸能盒的内能变化情况。由于  $T=1.36$  mm 和  $T=1.90$  mm 的样本在厚度较小,处于样本空间的边缘,因此与其他厚度的样本相比,预测结果的相对误差较大,但仍

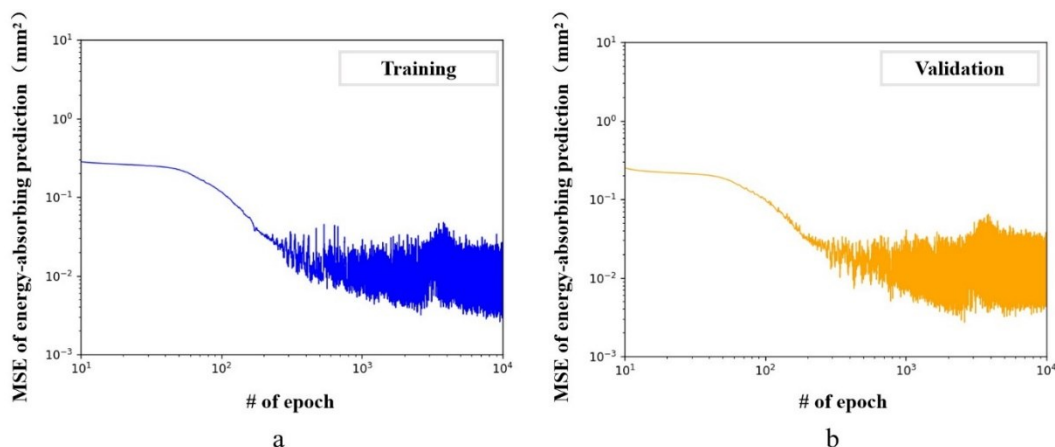


图 12 吸能预测模型的(a)训练集损失曲线和(b)测试集损失曲线

Fig. 12 Histogram of loss for (a) training set and (b) validation set

在可接受的范围内。验证集中其他样本的预测结果与有限元计算结果一致。吸能预测模型有效地捕捉了吸能盒内能变化的时间序列特征,预测的吸能曲线与有限元计算结果基本一致。

表 3 为碰撞结束时刻的最大吸能值预测结果与有限元结果的误差。最大吸能值是反映吸能盒吸能特性的重要指标,可以看出,机器学习预测模型对于吸能盒最大吸能值的预测较为准确。由于厚度较小的样本处于与整个样本空间的边缘,相对误差较大,对于其余厚度的测试样本,相对误差均低于 1%。同时平均每次计算时长约为 0.2 s,相比于有限元计算速度提高了 210.5 倍。说明该预测模型可以准确且快速地预测吸能盒吸能特性。

### 3.3 预测模型分析

综上所述,压溃变形预测模型和吸能预测模型能够有效捕捉吸能盒的几何结构差异,预测碰撞后




图 13 吸能预测模型与有限元计算得到的吸能曲线

Fig. 13 Energy absorption of the energy-absorbing box for different samples in the validation set

的压溃变形形态和吸能特性。编码器和解码器可以有效地学习结构的几何特征,实现有限元网格、边界

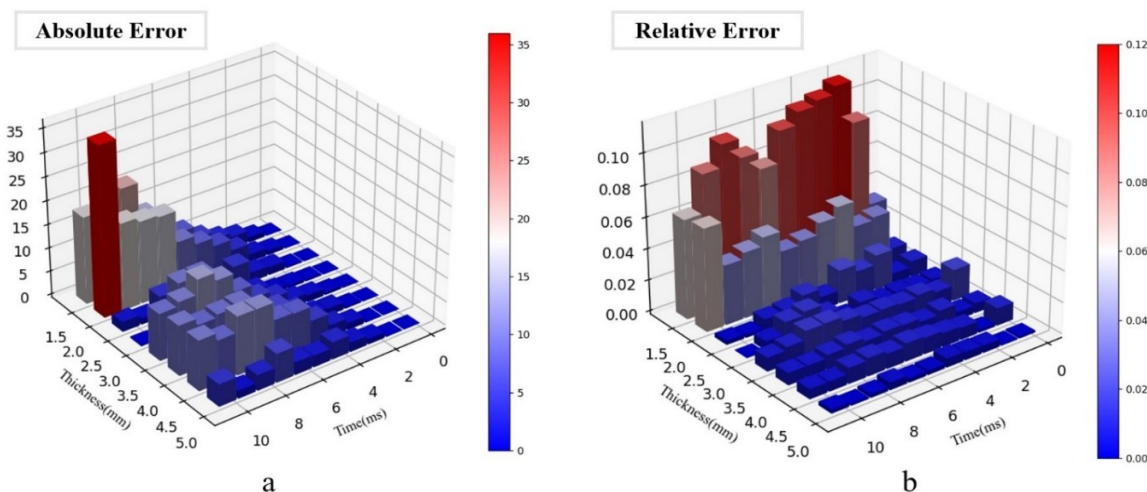


图 14 吸能预测的绝对误差和相对误差

Fig. 14 Absolute errors and relative errors between ML prediction and FE simulation



表3 最大吸能值的绝对误差和相对误差

Tab.3 Absolute errors and relative errors of the maximum energy absorption value.

Thickness/mm	1.36	1.90	2.45	2.82	3.09	3.54	4.08	4.84
Absolute error/mm	18.47	35.98	2.06	0.21	9.93	10.56	10.61	4.69
Relative error/%	6.33	6.55	0.25	0.02	0.86	0.75	0.62	0.22

条件和图网络嵌入属性等信息的相互转换,生成潜在的特征空间以供预测模型计算。由于吸能盒碰撞产生的变形和内能变化与时间相关,LSTM模块保证了潜在信息的时序特征,并通过图卷积实现图的信息传递和更新。最后,通过解码器输出结果,分别得到吸能盒的压溃变形结果和吸能特性。与有限元模型相比,机器学习模型的变形预测效率提高了174.5倍,吸能预测的效率提高了210.5倍。此外,最大变形量和最大吸能值的预测精度最高可达到95.33%和99.98%。

变形-吸能预测模型有效解决两个问题:几何形状的识别;特定工作条件下部件的响应预测。在保证精度的同时,与有限元相比,机器学习可显著提高计算速度。因此,本文提出的基于图卷积神经网络和长短期记忆网络的模型框架为未来探索各种具有时间依赖性的结构变化和特性变化提供了思路。

### 4 结语

本文提出了一种基于图卷积神经网络和长短期记忆网络的机器学习模型,用于预测汽车吸能盒的耐撞性。通过一系列不同厚度的吸能盒有限元仿真实验,生成了用于训练的数据集。通过训练后的变形-吸能预测模型预测了变形模式、位移和吸能特性,并与有限元仿真数据进行了比较。

机器学习模型使用基于图的编码器捕捉结构的几何特征,通过长短期记忆网络获取不同时刻的特征矩阵,使用图卷积神经网络进行节点间的信息传递和更新,并使用 Adam 优化器进行训练。在模型训练过程中,损失迅速收敛,训练结束后的模型可以稳定地得到预测结果。利用训练后的模型预测吸能盒的压溃变形和吸能特性,最大变形量的预测精度可达95.33%,最大吸能值的预测精度可达99.98%,计算速度分别提高了174.5倍和210.5倍。与有限元模型相比,该模型在保证预测精度的同时,计算效率有了显著提高。

鉴于图神经网络和长短期记忆网络能够有效地捕捉节点之间的拓扑关系和时序特征,因此本文提

出的吸能盒变形-吸能预测模型具有重要意义。此模型不仅可用于预测当前吸能盒的耐撞性,还为进一步探索预测基于时间依赖性的各种结构和多种载荷工况下的仿真结果提供了思路和方法。

### 参考文献:

[1] MARZBANRAD J, ALLJANPOUR M, KIASAT M S. Design and analysis of an automotive bumper beam in low-speed frontal crashes[J]. *Thin-Walled Structures*. 2009, 47(8/9):902.

[2] BAIGES J, CODINA R, CASTAÑAR I, *et al.* A finite element reduced - order model based on adaptive mesh refinement and artificial neural networks [J]. *International Journal for Numerical Methods in Engineering*. 2019, 121(4):588.

[3] MOHAN AT, GAITONDE D V. A deep learning based approach to reduced order modeling for turbulent flow control using LSTM neural networks[J]. *arXiv preprint*, 2018, arXiv: 1804.09269.

[4] ROY A G, CONJETI S, KARRI S P K, *et al.* ReLayNet: retinal layer and fluid segmentation of macular optical coherence tomography using fully convolutional networks[J]. *Biomed Opt Express*, 2017, 8(8):3627.

[5] HERATH S, HAPUTHANTHRI U. Topologically optimal design and failure prediction using conditional generative adversarial networks [J]. *International Journal for Numerical Methods in Engineering*. 2021, 122(23):6867.

[6] WANG L, SHI D, ZHANG B, *et al.* Real-time topology optimization based on deep learning for moving morphable components[J]. *Automation in Construction*. 2022, 142: 112.

[7] LIANG L, LIU M, MARTIN C, *et al.* A deep learning approach to estimate stress distribution: a fast and accurate surrogate of finite-element analysis [J]. *J R Soc Interface*, 2018, 15(138). DOI: 10.1098/rsif.2017.0844.

[8] ABUEIDDA D W, LU Q, KORIC S. Meshless physics - informed deep learning method for three - dimensional solid mechanics[J]. *International Journal for Numerical Methods in Engineering*. 2021, 122(23):7182.

[9] TANDALE S B, MARKERT B, STOFFEL M. Intelligent stiffness computation for plate and beam structures by neural network enhanced finite element analysis [J]. *International Journal for Numerical Methods in Engineering*. 2022, 123(17): 4001.

[10] CHEN H, NIE Z, XU Q, *et al.* Intelligent detection and classification of surface defects on cold-rolled galvanized steel strips using a data-driven faulty model with attention mechanism [J]. *Journal of Computing and Information Science in Engineering*, 2022, 23(4): 041001.

[11] XU W, WANG C, YUAN J. Impact performance of an annular shaped charge designed by convolutional neural networks[J]. *Thin-Walled Structures*, 2021, 160(35): 107241.

- [12] SHAMASS R, FERREIRA F P V, LIMBACHIYA V, *et al.* Web-post buckling prediction resistance of steel beams with elliptically-based web openings using Artificial Neural Networks (ANN)[J]. *Thin-Walled Structures*, 2022, 180: 522.
- [13] OMAR T, ESKANDARIAN A, BEDEWI N. Vehicle crash modelling using recurrent neural networks [J]. *Mathematical and Computer Modelling*, 1998, 28(9): 31.
- [14] VAN DE WEG B P, GREVE L, ANDRES M, *et al.* Neural network-based surrogate model for a bifurcating structural fracture response [J]. *Engineering Fracture Mechanics*, 2021, 241 (1). <https://www.zhangqiaokeyan.com/journal-foreign-detail/0704028668404.html>.
- [15] KOHAR C P, CONNOLLY D, LIUSKO T. *et al.* Using artificial intelligence to aid vehicle lightweighting in crashworthiness with aluminum [J]. *MATEC Web of Conferences*. 2020, 326(1): 01006.
- [16] LANZI L, BISAGNI C, RICCI S. Neural network systems to reproduce crash behavior of structural components [J]. *Computers & Structures*. 2004, 82(1):93.
- [17] GUO X X, LI W, IORIO F. Convolutional neural networks for steady flow approximation [C]// *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016: 481. <https://www.kdd.org/kdd2016/papers/files/adp1175-guoA.pdf>.
- [18] HE B, XU F, ZHANG D, *et al.* A convolutional neural network-based recognition method of gear performance degradation mode [J]. *Journal of Computing and Information Science in Engineering*. 2022, 22(5): 050902.
- [19] NIE Z G, JIANG H L, KARA L B. Stress field prediction in cantilevered structures using convolutional neural networks [J]. *J Comput Inf Sci Eng*, 2020, 20.
- [20] GUO Y L, WANG H Y, HU Q Y, *et al.* Deep learning for 3d point clouds: a survey [J]. *Ieee T Pattern Anal*, 2021, 43 (12): 4338.
- [21] XIANG C, WANG D L, PAN Y, *et al.* Accelerated topology optimization design of 3D structures based on deep learning [J]. *Struct Multidiscip O*, 2022, 65(3).
- [22] KOHAR C P, GREVE L, ELLER T K, *et al.* A machine learning framework for accelerating the design process using CAE simulations: an application to finite element analysis in structural crashworthiness [J]. *Computer Methods in Applied Mechanics and Engineering*, 2021, 385.
- [23] RAO C, LIU Y. Three-dimensional convolutional neural network (3D-CNN) for heterogeneous material homogenization [J]. *arXiv preprint*, 2020, arXiv: 2002.07600.
- [24] LIU Z, TANG H, LIN Y, *et al.* Point-voxel CNN for efficient 3D deep learning [J]. *arXiv preprint*, 2019, arXiv: 1907.03739.
- [25] ZHOU J, CUI G, HU S, *et al.* Graph neural networks: a review of methods and applications [J]. *AI Open*, 2020, 1:57.
- [26] JIN W, YANG K, BARZILAY R, *et al.* Learning multimodal graph-to-graph translation for molecular optimization [J]. *arXiv preprint*, 2028, arXiv: 1812.01070.
- [27] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting [C]//*Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*. 2018: 3634.
- [28] MAURIZI M, GAO C, BERTO F. Predicting stress, strain and deformation fields in materials and structures with graph neural networks [J]. *Scientific Reports*, 2022, 12 (1).
- [29] PFAFF T, FORTUNATO M, SANCHEZ-GONZALEZ A, *et al.* Learning mesh-based simulation with graph networks [J]. *arXiv preprint*, 2020, arXiv: 2010.03409.
- [30] WU F, JING X Y, WEI P F, *et al.* Semi-supervised multi-view graph convolutional networks with application to webpage classification [J]. *Inform Sciences*, 2022, 591:142.
- [31] GORI M, MONFARDINI G, SCARSELLI F. A new model for learning in graph domains [C]. *Ieee Ijcn*, 2005:729.
- [32] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Comput*, 1997, 9(8):1735.
- [33] WU Z H, PAN S R, LONG G D, *et al.* Connecting the dots: multivariate time series forecasting with graph neural networks [C]//*Proceedings of the 26th Acm Sigkdd International Conference on Knowledge Discovery & Data Mining*. 2020:753.
- [34] NUGRAHA R D, HE K, LIU A, *et al.* Short-term cross-sectional time-series wear prediction by deep learning approaches [J]. *Journal of Computing and Information Science in Engineering*, 2023, 23(2).
- [35] BAROUTAJI A, SAJJIA M, OLABI A G. On the crashworthiness performance of thin-walled energy absorbers: Recent advances and future developments [J]. *Thin-Walled Structures*, 2017, 118:137.
- [36] C-NCAP. C-NCAP management regulation [EB/OL]. 2018. <https://cncap.obs.cn-north-4.myhuaweicloud.com/cms/picture/319721353147125760.pdf>.
- [37] YAO S, YAN K, LU S, *et al.* Prediction and application of energy absorption characteristics of thin-walled circular tubes based on dimensional analysis [J]. *Thin-Walled Structures*, 2018, 130:505.
- [38] SINGH K, KAPANIA R K. Accelerated optimization of curvilinearly stiffened panels using deep learning [J]. *Thin-Walled Structures*, 2021, 161.
- [39] ZHANG Y, ZHU P, CHEN G L. Lightweight design of automotive front side rail based on robust optimisation [J]. *Thin-Walled Structures*, 2007, 45(7/8): 670.
- [40] ZHANG Y, XU X, SUN G Y, *et al.* Nondeterministic optimization of tapered sandwich column for crashworthiness [J]. *Thin-Walled Structures*, 2018, 122:193.
- [41] KINGMA D P, BA J. Adam: a method for stochastic optimization [J]. *arXiv preprint*, 2014, arXiv: 1412.6980.