

doi: 10.19562/j.chinasae.qcgc.2024.12.009

基于机器学习的变形模式控制耐撞性优化

李治祥, 祝丹晖, 张佳欢

(比亚迪汽车有限公司, 西安 710311)

[摘要] 耐撞性优化是实现车辆更好被动安全保护性能的有效途径,但目前的优化都专注于数值型响应的提升,而忽略了变形模式这一类别型响应的控制。关键部件的变形模式关乎车辆传力路径设计是否有效,如果不理想的变形模式出现在优化解中,则无法保证优化结果的有效性。为此,本研究提出了基于机器学习的变形模式控制优化方法,以实现在提升耐撞性指标的同时保证优化解中的样本均以理想模式变形。结构变形以图片形式进行数据表示,利用深度学习自编码提取变形特征并进行聚类识别不同的变形模式,然后对识别出的变形模式和数值型响应均建立基于Light Gradient Boosting Machine (LightGBM)的机器学习预测模型,最后在机器学习预测模型上开展优化求解。使用整车正碰案例对提出的机器学习优化方法进行验证,结果显示该优化方法在提升耐撞性数值响应的同时保证了纵梁以理想模式变形。本研究展示了机器学习在提升结构优化有效性方面的前景。

关键词: 结构优化; 机器学习; 图像聚类; 耐撞性

Machine Learning Based Crashworthiness Optimization with Structural Deformation Mode Control

Li Zhixiang, Zhu Danhui & Zhang Jiahuan

BYD Auto Co., Ltd., Xi'an 710311

[Abstract] Crashworthiness optimization is an effective way to achieve better passive safety protection performance of vehicles, but current optimization focuses on improving numerical response, while neglecting the control of a category response, namely, deformation modes. The deformation mode of key components is related to the effectiveness of vehicle force transmission path design. If an unsatisfactory deformation mode occurs in the optimization solution, the effectiveness of the optimization result cannot be guaranteed. Therefore, in this study a machine learning based deformation mode control optimization method is proposed to improve the crashworthiness index while ensuring that all samples in the optimization solution deform in ideal modes. Structural deformation is represented in the form of images, and deep learning auto encoder is used to extract deformation features and cluster them to identify different deformation modes. Then, machine learning prediction models based on Light Gradient Boosting Machine (LightGBM) are established for the identified deformation modes and numerical responses. Finally, the optimization is solved based on the machine learning prediction models. The proposed machine learning optimization method is validated using a full vehicle frontal collision case, and the results show that while improving the numerical crashworthiness responses, the deformation mode of the longitudinal beam is ensured to deform in an ideal mode. This study demonstrates the prospects of machine learning in improving the effectiveness of structural optimization.

Keywords: structural optimization; machine learning; image clustering; crashworthiness

原稿收到日期为2024年06月28日,修改稿收到日期为2024年08月16日。

通信作者: 祝丹晖, 博士, E-mail: zhudanhui_byd@163.com。

前言

汽车被动安全保护和轻量化水平要求的不断提高为车辆结构设计带来了巨大挑战,要实现以上两种性能都达到最优水平就必须对二者进行权衡和协调,耐撞性参数优化是实现以上需求的最有效途径^[1]。

目前的耐撞性参数优化基本都在仿真结果基础上开展,考虑到优化过程都要迭代成千上万次,一般会先使用较少的仿真样本来构建代理模型,然后在代理模型上进行寻优进而提高优化效率。当优化对象是单个结构时,耐撞性响应一般是吸能量、峰值力等能反映单个结构吸能性能的指标;优化对象是整车时,耐撞性响应会考虑加速度、侵入量等能体现整车被动安全性能的指标。然而,以上优化工作中的耐撞性响应均未考虑变形模式这一重要响应。

在汽车碰撞中,变形模式的要求是非常严格的。一方面,优良吸能结构的变形必须是稳定可控的^[2],但是一些吸能结构在设计变量变化范围内会表现出非理想变形模式,这是结构设计中不希望看到的。更关键的是,在某些案例中,吸能结构在表现出非理想变形模式的情况下却可以在其他吸能指标上表现良好^[3],这会导致非理想变形模式可能出现在优化解中,使得优化结果的有效性无法得到保障。另一方面,整车碰撞的传力路径是提前规划好的,在优化中一旦改变了吸能结构的变形模式会破坏原有传力路径,对碰撞安全性能带来极大影响。汽车碰撞的多个工况中均有变形模式的要求,比如,正碰中前纵梁的理想变形模式为“三点弯折”,该变形模式能在保证纵梁实现最大吸能量的同时,与其相连的其他车辆部件发生有序可控变形^[4];侧碰中B柱不允许出现“中部折弯”模式,因为该模式会对乘员损伤威胁较大^[5];行人保护中要求 aPLI(advanced pedestrian legform impactor)腿型在与轿车、MPV、大型越野车碰撞中的理想变形模式分别为“腿型上滑”、“上部后倾”和“下端后卷”模式,这样的变形模式对行人的伤害最小^[6]。目前工程应用中往往根据经验或采用试错法在所关注结构的某些位置设置诱导结构为实现以上碰撞场景中的理想变形模式,然而这种做法虽然能实现对变形模式的优化,但是无法保证其他耐撞性和轻量化指标达到最优。因此,使用参数优化方法来对耐撞性响应优化的同时对变形模式进行控

制是非常有必要的。

以上分析可以看出,工程中对吸能结构变形模式是非常重要的,但之所以没有在优化过程中进行控制,主要是缺乏有效的手段。目前优化中考虑到的耐撞性响应如峰值力、吸能量、加速度、侵入量等均是数值型响应,而变形模式是类别型响应,传统的拟合方法只能处理数值型响应,却无法处理如变形模式等类别型响应,这使得带有类别型响应的优化问题变得极其困难。

有幸的是,得益于机器学习的发展,带有类别型变量或响应的优化问题有望得到解决。近几十年来,机器学习技术已经成功应用于诸多领域^[7-8]。机器学习最重要的应用是预测,如分类预测和回归预测等,意味着其既可以处理数值型响应,也可以处理类别型响应。因此,利用机器学习来处理变形模式问题是一个很好的选择。此外,与传统拟合方法相比,机器学习在捕捉非线性等复杂关系方面具有更大优势^[9-10],有助于提高吸能结构优化的准确度。近些年来已经有学者尝试使用机器学习方法来解决变形模式控制优化的问题。Li等^[11]采用4种机器学习方法对一款列车吸能结构进行了考虑变形模式的优化,最终实现了优化解中的样本均以理想模式变形的同时提高了比吸能并降低了峰值力。然而该研究中对变形模式须人为地标定,会增加模式识别的主观性,也增加了优化的工作量。因此目前仍然缺乏一种客观且自动化程度高的变形模式控制耐撞性优化方法。

出于以上考虑,本研究将建立基于机器学习的变形模式控制优化方法,使用深度学习图像识别技术对变形模式进行自动且客观的识别,在保证对数值型耐撞性响应提升的同时对变形模式进行控制,实现优化解中仅保留理想的变形模式。最后以整车正碰优化为案例,来验证该优化方法的有效性。

1 机器学习优化框架

本研究提出的基于机器学习的结构变形模式控制耐撞性优化方法,目的在于对吸能结构进行优化后,优化结果中不会出现不理想的变形模式,这样可以显著提高吸能结构优化的有效性,进一步确保所优化结构在碰撞中与其他结构及整车的耦合性。为此建立了如图1所示的优化框架,该优化框架由5个步骤组成,详细叙述如下。

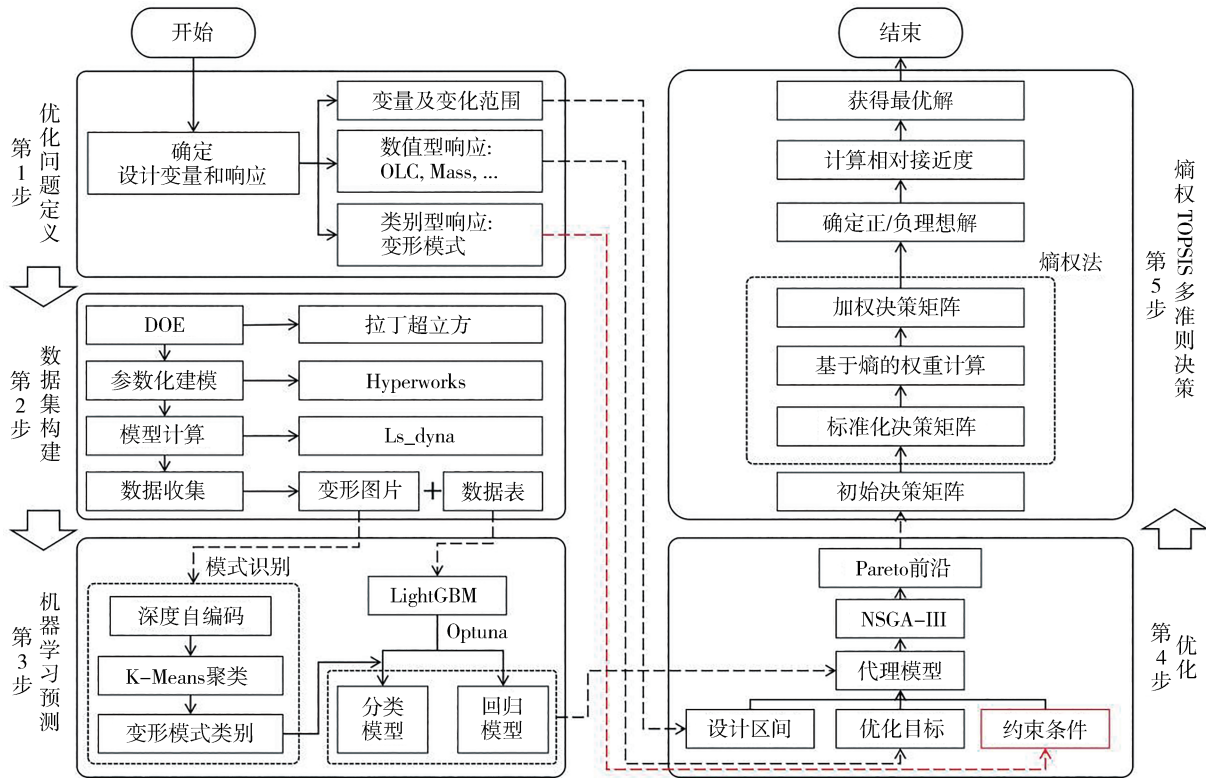


图1 机器学习增强结构变形模式控制的耐撞性优化框架

第1步:优化问题定义

首先,对于具体的碰撞问题,确定影响其吸能性能的相关变量和响应。对于变量,确定其变化区间;对于响应,确定将哪些响应作为优化目标,将哪些响应作为约束条件。响应由数值型和分类型响应构成,数值型响应包括乘员载荷准则(OLC)、质量(Mass)等,类别型响应着重考虑变形模式,这也是该方法的重点所在。

第2步:数据集构建

对于耐撞性优化问题,数据一般来源于有限元仿真。首先采用DOE(design of experiments)方法在设计空间中具有代表性的样本点,在本研究中,选用拉丁超立方方法;然后利用Hyperworks参数化建模方法将所需样本点进行快速建模;最后将模型样本提交有限元软件Ls-dyna计算得到每个样本点的响应值,对于数值型响应以数据表形式进行存储,对于变形模式这一类别响应以图片形式进行数据存储,所有样本的响应值(数值型响应和类别型响应)和变量值构成所需的数据集。

第3步:机器学习预测

这一步是本优化框架的关键,其目的是通过机器学习建立变形模式和数值响应的预测模型。在对

变形模式进行分类之前,须对变形模式进行快速准确的识别,为此采用深度自编码^[12]对变形图片进行特征提取,然后在提取的特征基础上采用K-Means^[13]进行聚类,即可识别出不同的变形模式。变形模式识别过程建立的是其与图片特征间的关系,并未建立起与设计变量间的关系,因此须在此基础上进一步建立分类模型。对于数值响应和类别响应均采用Optuna^[14]调优的LightGBM^[15]机器学习算法来进行回归预测和分类预测。

第4步:优化

设计变量、优化目标及约束条件与第1步中确定的问题相对应,并将第3步得出的机器学习预测模型作为代理模型,然后在此基础上开展优化求解。要注意的是,在优化过程中必须将变形模式作为一个约束条件,使其必须为理想变形模式。多目标优化算法选用NSGA-III(non-dominated sorting genetic algorithm III)^[16],求解之后即可得到帕累托(Pareto)前沿。

第5步:熵权TOPSIS多准则决策

多目标优化得到的优化解是由一组解构成的Pareto前沿,在工程应用中需要从中选出最优解。由于优化目标之间相互冲突,因此很难从Pareto前

沿直接选择出最优解,该问题本质上属于多准则决策问题,因此使用熵权 TOPSIS (technique for order preference by similarity to an ideal solution)^[3]法来进行择优。

本优化框架最大的优势在于将变形模式这一类别型响应通过机器学习方法进行预测,进而将其定义为约束条件,解决了传统优化方法在含有类别响应的优化问题中无法明确定义有效设计空间的难题。通过将变形模式作为约束,不再需要显式地定义有效设计空间。这样,即可保证优化解中不再包含不理想变形,从而获得更准确有效的优化结果。下面,将对该优化框架中采用的一些重要的方法进行详细介绍。

1.1 基于图片数据的变形模式识别

要实现优化过程中对变形模式的控制,关键在于建立变形模式的预测模型,变形模式的预测本质上是分类问题,建立分类模型时数据中必须要有类别标签。在建立数据集的过程中,可以人为地对所有样本的变形进行判断并打标签,但是人为判断一方面存在一定的主观性,另一方面比较耗时,因此本研究采用深度学习自动对变形模式进行识别。

本研究建立的变形模式自动识别方法如图2所示。方法的总体思路是先通过自编码^[12]来提取结构变形的特征,然后在此基础上开展聚类分析识别出不同的变形模式类别。自编码是一种深度学习方法,其被广泛用于数据降维与压缩、图片去噪、数据重构等场景^[13]。自编码可以分为两个部分,从输入降维得到特征编码的过程称为编码器,从特征编码升维得到输出的过程称为解码器。本研究中结构的变形以图片形式进行数据表示,由于只须识别形状特征,使用灰度图即可,也即图片通道数为1,图片的像素尺寸定为224×224,因此每张图片输入到自编码模型的尺寸为1×224×224的三维形式。自编码模型的网络构架如表1所示,编码器由3层2维卷积神经网络(Conv2d)和1层全连接神经网络(Linear,线性层)构成,图片数据经编码器后得到尺寸为1×256的特征编码;解码器由1层全连接神经网络和3层2维逆卷积神经网络(ConvTranspose2d)构成,特征编码经解码器后得到的数据尺寸为1×224×224,与网络的输入尺寸一致。可以看出,编码是一个降维过程,解码是一个升维过程,在本问题中使用自编码模型主要是为了得到降维后的特征编码。




图2 变形模式自动识别方法

表1 自编码模型网络构架

| 层数 | 模型 | 网络 | 输出尺寸 |
|----|-----|-----------------|---------------|
| 1 | 编码器 | Conv2d | 64×112×112 |
| 2 | | Conv2d | 128×56×56 |
| 3 | | Conv2d | 256×28×28 |
| 4 | | Linear | 1×256 |
| 5 | 解码器 | Linear | 1×(256×28×28) |
| 6 | | ConvTranspose2d | 128×56×56 |
| 7 | | ConvTranspose2d | 64×112×112 |
| 8 | | ConvTranspose2d | 1×224×224 |

自编码模型为无监督学习,在模型训练过程中得到的输出与输入本身进行损失计算,模型在训练结束后能够输出与输入一致的数据即说明模型提取到了有效的特征编码。训练过程中损失函数采用均方根误差(mean squared error, MSE)^[17],定义如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

式中: n 为样本个数; y_i 和 \hat{y}_i 分别为第 i 个样本的真实值与预测值。

在得到结构变形图片的特征之后,即可基于此开展聚类学习,聚类同样是无监督学习,其目的是将已经获得的特征编码根据其自有属性进行类别划分。本研究中采用K-Means聚类算法,其具有简单快速的优点^[18]。K-Means的基本思想是确定聚类数量 K ,随机选择 K 个数据点作为初始聚类中心,然后计算每个数据点到 K 个聚类中心的距离,并将数据点分配给最近的聚类中心。经过聚类操作,即可识别出不同的变形模式以及隶属于不同变形模式的样本,在此基础上进一步进行分类学习,得到设计变量与变形模式类别间的关系。

1.2 基于Optuna调优的LightGBM预测方法

对于数值型响应和变形模式这一类别响应,本研究均采用LightGBM机器学习算法来建立预测模型。LightGBM是一种集成学习算法,其将多个决策树个体学习器集成为更复杂的学习器。LightGBM

和 eXtreme Gradient Boosting (XGBoost)^[19] 一样是对 Gradient Boosting Decision Tree (GBDT) 的优化和高效实现, 但它在训练效率和预测精度等方面均优于 XGBoost。LightGBM 之所以具有如此好的性能, 是因为其采用了基于直方图的决策树算法和按叶生长策略, 如图 3 所示。直方图算法占用的内存更低, 数据分割的复杂度更低; 按叶生长策略可以减少更多误差, 得到更好的精度。

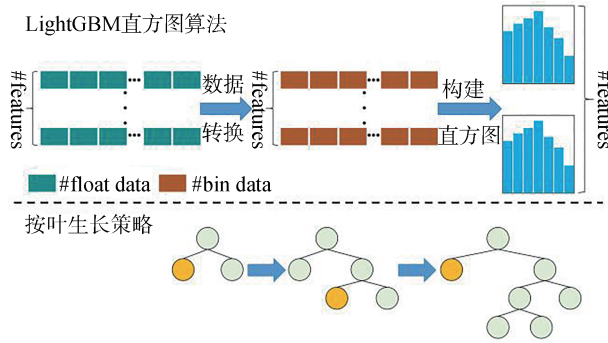


图3 LightGBM算法示意图^[20]

LightGBM 算法中涉及到多个超参数, 因此在使用时须对算法中的超参数进行调优才能建立起最优的预测模型。LightGBM 中的超参数包括 num_leaves (叶子节点数)、learning_rate (学习率)、feature_fraction (特征比例)、bagging_fraction (bagging 的比例)、bagging_freq (bagging 的频率)、min_child_samples (叶子节点所需的最小样本数) 等, 对于如此多的超参数必须采用高效的调参方式才能实现保证预测模型建立的效率。为此, 本研究采用 Optuna 调参框架, 其使用 Tree-structured Parzen Estimator 算法, 这种算法结合了贝叶斯优化的优点和决策树的灵活性, 能够高效地搜索超参数空间并找到最佳的模型配置。

在使用如上方法建立预测模型前, 须对数据集进行归一化, 并将数据集划分为 80% 训练集和 20% 测试集。对于数值型响应, 采用决定系数 (R^2)、平均相对误差 (MRE) 和相对平均绝对误差 ($RAAE$) 3 个指标来对预测结果进行评判, 定义如下^[21]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (3)$$

$$RAAE = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4)$$

对于变形模式的分类结果, 采用 AUC (ROC 曲线下面积, ROC 全称为 Receiver Operating Characteristic 曲线, 又称接受者操作特征曲线) 指标来进行评判, ROC 曲线的横坐标为 FPR (假正例率), 纵坐标为 TPR (真正例率)。AUC 值处于 0~1 之间, 其值越大说明分类精度越高。

1.3 多目标优化及多准则决策方法

本研究中对于耐撞性多目标优化, 采用 NSGA-III 算法进行求解。NSGA-III 是在其前身 NSGA-II 的基础上提出的最先进的多目标优化算法之一, 与 NSGA-II 相比, NSGA-III 改进了选择策略^[22]。NSGA-III 的流程图如图 4 所示。

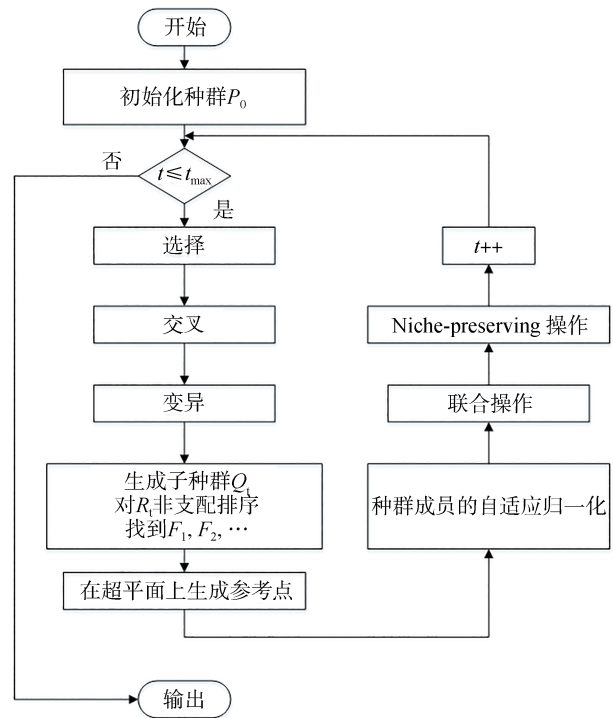


图4 NSGA-III优化算法示意图

多目标优化的结果为 Pareto 前沿, 其中包含了满足优化条件的一组解, 直接从这一组解中选出一个最优解比较困难, 由于这种择优问题涉及到多个评价准则 (也即优化目标), 因此可以引入多准则决策方法来从 Pareto 前沿中选出最优解。本研究中使用 TOPSIS 方法进行择优, 其中需要人为地确定不同准则的权重, 但由于人为地赋权方式必定会带入一

定的主观性,因此本研究使用熵权法来进行赋权,使择优过程更加客观。本研究将熵权法和TOPSIS组合方法称为熵权TOPSIS,其建立过程如图1中的第5步所示,更为具体建立流程参见作者已发表的论文^[3]。

2 汽车正碰优化案例

采用汽车正碰案例来验证本研究提出的优化方法的有效性,正碰是汽车碰撞安全验证中最为重要的一环,乘员的伤害程度是最重要的考量指标。正碰中有多条传力路径设计,其中沿纵梁的传力路径承担最大的吸能任务,因此纵梁的变形模式直接关系到汽车正碰设计的有效性。在本正碰优化案例中,通过改变纵梁的结构,来实现碰撞安全性能得到优化的同时,保证优化解中纵梁只能以理想的模式进行变形。

2.1 有限元模型

本研究采用美国乔治华盛顿大学碰撞分析中心公开的丰田Yaris正碰有限元模型进行分析,如图5所示。该模型由Ls-dyna有限元软件创建,模型的有效性已经使用碰撞试验得到了验证,更多关于该模型的信息请在美国乔治华盛顿大学碰撞分析中心官网查询。

该模型整车质量为1 263 kg,碰撞场景设定为车辆以56 km/h速度正面冲击刚性墙。




图5 丰田Yaris汽车正碰有限元模型

2.2 耐撞性指标

在耐撞性优化中,选取3个指标作为响应,分别为乘员载荷指数(occupant load criterion, OLC)、纵梁Mass(质量)和纵梁变形模式。OLC是一项评价车辆减速度的指标,其是在给定车辆减速度波形的条件下,通过假定乘员做单纯的前向运行而求得乘员平均减速度用于评价车辆减速度对乘员作用载荷大小。此外,由于本优化案例中主要考虑通过改变纵梁结构来改善碰撞安全性能,因此质量也只须考虑

纵梁即可。通过在优化中考虑OLC和Mass两个指标,即能实现碰撞安全性能和轻量化水平的协同提升。

纵梁作为汽车上最主要的吸能部件,其变形模式直接关系到整车的吸能效果。吸能结构的最优变形模式为渐进压溃,这样能够将材料利用率发挥到最大,但是由于纵梁要与发动机以及车体其他部件连接,几乎不可能实现渐进压溃。对于纵梁变形模式,大量的工程应用已经证明,其最理想的变形模式为三点弯折,特斯拉Model 3即采用的此变形模式设计,使得Model 3获得了E-NCAP(欧洲新车安全评鉴协会)和IIHS(美国公路安全保险协会)五星认证,说明三点弯折变形模式的优势。图6是本研究中使用的丰田Yaris汽车正碰纵梁变形模式,可以看出左右纵梁均只出现了2个弯折点,前部没有变形充分,完全可以在纵梁前部继续设置弯折点来提高纵梁的吸能量。纵梁的变形模式用DM表示。



图6 丰田Yaris汽车正碰纵梁变形模式

2.3 模型参数化

本研究优化中的设计参数都集中在纵梁上,如图7所示。左右纵梁均由内板、外板及内部的加强筋构成,将以上部件的厚度设置为设计变量来开展优化。根据当前模型特征,设定4个厚度变量,分别为左右纵梁的内板厚度 t_{in} 、左右纵梁的外板厚度 t_{out} 、左纵梁加强筋厚度 t_{left} 和右纵梁加强筋厚度 t_{right} 。

另外可以观察到左右纵梁前部均设置有一个诱

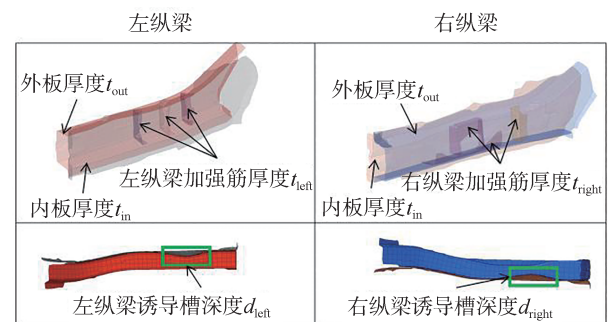



图7 纵梁参数化

导槽来诱导前部也出现弯折点,但是结果显示并未起到作用。因此将左右纵梁各自的诱导槽深度也设置为变量,通过优化来实现纵梁能够以三点弯折模式变形。左右纵梁诱导槽深度分别表示为 d_{left} 和 d_{right} 。

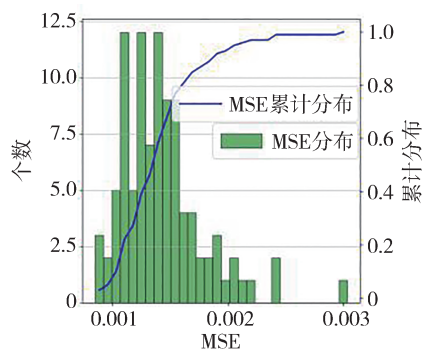
2.4 优化问题定义

该正碰优化问题定义如式(5)所示。优化目标为最小化 OLC 和 Mass, 根据纵梁结构特征, 定义 t_{in} 、 t_{out} 、 t_{left} 、 t_{right} 的变化范围为 1~2 mm, d_{left} 和 d_{right} 的变化范围为 0~10 mm, 以上变量范围决定了设计空间。此外将左右纵梁的变形模式 DM 均约束为三点弯折模式。须说明一点, 参数优化过程中进行的是数值计算, 但是变形模式是一种类别响应, 必须将其转化为数值才能在优化中进行约束并求解。在本研究中, 纵梁出现了 3 种变形模式, 将三点弯折模式设定为 0, 另外 2 种模式设定为 1 和 2, 这样即可在优化中进行有效的求解。

$$\begin{cases} \min(\text{OLC}, \text{Mass}) \\ \text{s. t.} \begin{cases} DM = \text{三点弯折} \\ 1 \text{ mm} \leq t_{in}, t_{out}, t_{right}, t_{left} \leq 2 \text{ mm} \\ 0 \text{ mm} \leq d_{right}, d_{left} \leq 10 \text{ mm} \end{cases} \end{cases} \quad (5)$$



(a) 左纵梁变形自编码模型损失



(b) 左纵梁变形重建误差分布

图8 左纵梁变形自编码网络训练结果

为更为直观地展示重建效果, 随机抽取了测试集中 18 个样本进行原始数据与重建数据的对比, 如图 9 所示。可以看出重建结果很好地还原了左纵梁的变形, 尽管重建图片相比原始图片在局部有失帧的情况, 但是对于结构变形的总体特征捕捉得非常到位。从以上自编码网络的误差以及变形重建结果的对比分析说明, 左纵梁变形重建结果良好。

左纵梁变形重建结果良好说明自编码网络中获得的特征编码是左纵梁变形的一种准确表示, 在本

3 结果与讨论

3.1 纵梁变形模式识别

纵梁变形模式自动识别分为两步, 第 1 步是对纵梁变形图片自编码来提取特征编码, 第 2 步是在第 1 步得到的特征编码基础上聚类。自编码实际上是一个重建过程, 先通过降维得到中间态的特征编码, 再升维得到重建结果, 通过原始数据和重建结果的对比来不断训练网络。自编码网络中, 数据随机分为 80% 的训练集和 20% 的测试集, 学习率设置为 0.000 1, 损失函数选用 MSE, 训练了 100 个 Epoch。图 8 为左纵梁变形自编码网络的训练结果。从图 8(a) 中可以看出, 随着训练进程的推进, 训练集和测试集的损失不断下降并趋于收敛, 且收敛后训练集和测试集损失基本相等, 说明没有出现拟合现象。图 8(b) 展示了测试集中所有样本重建结果的 MSE 误差分布情况, 可以看出误差总体呈现出正态分布, 且大部分样本误差处于 0.001~0.002 之间, 从误差累计分布结果可以看出, 该范围内的样本占比超过了 90%, 说明模型训练精度较高。

研究中, 特征编码是长度为 256 的一维向量, 而原始图片尺寸是 224×224, 可见特征编码相比于原始图片大幅降低了数据维度。另外, 在自编码网络中, 原始图片经过编码器得到特征编码是多层卷积的过程, 该过程使得到的特征编码捕捉到了变形图片中的重要特征并对输入图片数据中的噪声和冗余信息进行过滤。这种低维特征编码能够提高后续聚类模型的鲁棒性和泛化能力, 提高变形模式识别的准确度。




图9 左纵梁变形原始图片与重建图片对比

在得到的特征编码基础上,使用K-Means聚类算法开展变形模式的识别。K-Means是一种无监督学习方法,意味着学习过程中没有标签,因此该算法会自动对比分析输入特征的差异,将具有相似特征的样本划分为同一类。对于左纵梁变形,设置类别个数为3,得到了如图10所示的变形模式识别结果。图10针对每一类随机展示了12个样本,可以看出模式1与初始设计中的变形模式一致(图6),为两点折弯变形;模式2在前端出现了明显上翘;模式3为理想的三点弯折变形。在后续的优化中,约束左纵梁的变形模式只能按照模式3进行变形。

对于右纵梁的变形,同样按照与左纵梁相同的方法进行了模式识别,最终同样识别出了3种变形模式。由于分析过程与左纵梁基本一致,右纵梁的变形模式识别结果不在本文中展示。

3.2 机器学习代理模型构建

在本优化问题中,将OLC和纵梁Mass设置为优化目标,纵梁变形模式设置为约束条件,本节将使用LightGBM机器学习方法建立以上响应的代理模型,为后续优化建立基础。

上节使用聚类算法已经识别出左右纵梁各自的变形模式,但是聚类只是建立了特征编码与变形模式之间的关系,也就是为变形图片打上了变形模式的标签。要建立变形模式的代理模型,就必须建立起变形模式与设计变量之间的关系,此处使用LightGBM分类算法来建立变形模式代理模型。使




图10 左纵梁变形模式聚类结果

用Optuna对LightGBM中涉及到的超参数进行调优,最终搜索到最优参数。使用最优LightGBM模型对左右纵梁变形模式的分类结果如表2所示。可以看出,对于左纵梁变形模式,模式1、模式2、模式3分类错误的样本数分别为1、1、2,准确率为0.96;对于右纵梁变形模式,模式1、模式2、模式3分类错误的样本数分别为1、1、4,准确率为0.94。

表2 变形模式分类混淆矩阵

| 模式 | 左纵梁 | | | 右纵梁 | | |
|-----|-----|-----|-----|-----|-----|-----|
| | 模式1 | 模式2 | 模式3 | 模式1 | 模式2 | 模式3 |
| 模式1 | 20 | 1 | 0 | 8 | 0 | 1 |
| 模式2 | 1 | 55 | 0 | 1 | 46 | 0 |
| 模式3 | 2 | 0 | 21 | 4 | 0 | 40 |

从准确率来看,左右纵梁的分类结果都足够高,但是从表2中可以看出,由于左右纵梁中3种变形模式样本数是不均衡的,单看准确率是不够的。为此使用AUC指标对分类结果进一步进行评估,AUC指标的优势就在于其不受样本分布影响,对于正负样本比例不均衡的情况具有较好的鲁棒性,能够更准确地评估模型的性能。AUC评价结果如图11所示。可以看出,对于左纵梁3种变形模式,AUC均大于0.98;对于右纵梁3种变形模式,AUC均大于0.96。AUC值越接近于1说明分类效果越好,AUC ≥ 0.9 即可认为模型具有优秀的分类能力。结合准确率的分析,说明左右纵梁变形模式的分类结果准确度较高,也即说明左右纵梁变形模式的代理模型可以用于后续优化。

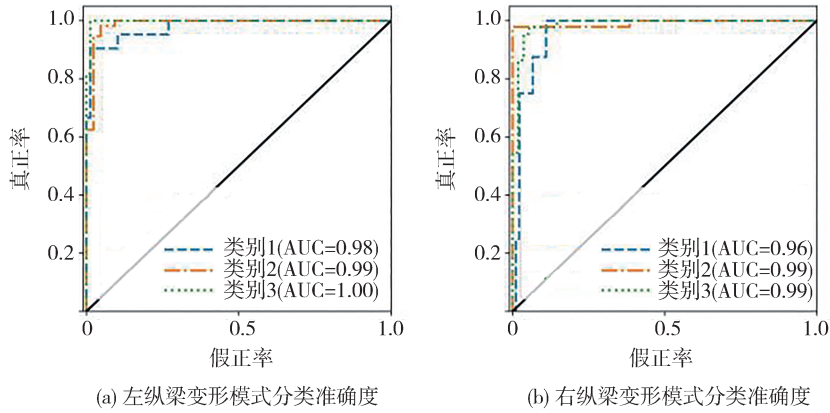


图11 变形模式分类准确度评估

对于 Mass 和 OLC,采用 Optuna 调优的 LightGBM 回归算法进行预测。Mass 和 OLC 预测准确度分别如图 12(a)和图 12(b)所示。可以看出在训练集和测试集上,样本点均基本分布在 45°线附近,且仅有个别样本点偏离 45°线较大。对 R^2 、 MRE 和 $RAAE$ 3 个评价指标进行了计算,也绘制在图 12 中。 R^2 的值通常在 0 和 1 之间变化, R^2 值越高,表明拟合质量越好。在工程优化中, R^2 的值高于 0.92 即可认为拟合质量较好; $RAAE$ 表示平均绝对误差与标准差的比率, $RAAE$ 越低越好,因为这表明拟合预测值中的方差主要由数据中的实际方差控制,而不是由预测模型误差控制; MRE 为所有样本相对误差百分比的平均值, MRE 越接近于 0 表明预测结果越好。从以上 3 个指标的值可以看出,Mass 和 OLC 的预测模型精度均较高。

此外,将 Mass 和 OLC 的预测值和真实值分别按照样本点数绘制于图 13 和图 14 中,方便观测单个样本上预测误差。同样可以看出,预测值与真实值之间具有较好的吻合度。以上对于 Mass 和 OLC 预测精度的分析均证明,这两个数值型响应的机器学习代理模型具有较高的准确度,可以用于后续优化。

3.3 优化结果

在构建好 Mass、OLC 和纵梁变形模式的代理模型后,即可按照式(5)开展多目标耐撞性参数优化。优化算法选用 NSGA-III,最大遗传代数设置为 1 000,种群规模设置为 500。优化求解后得到如图 15(a)所示的 Pareto 前沿,Pareto 前沿中包含了满足优化条件的一组解。在工程应用中只能选用其中一个解,因此就必须从 Pareto 前沿中选出最优解。按照本研究提出的优化方法的第 5 步(图 1),使用熵权

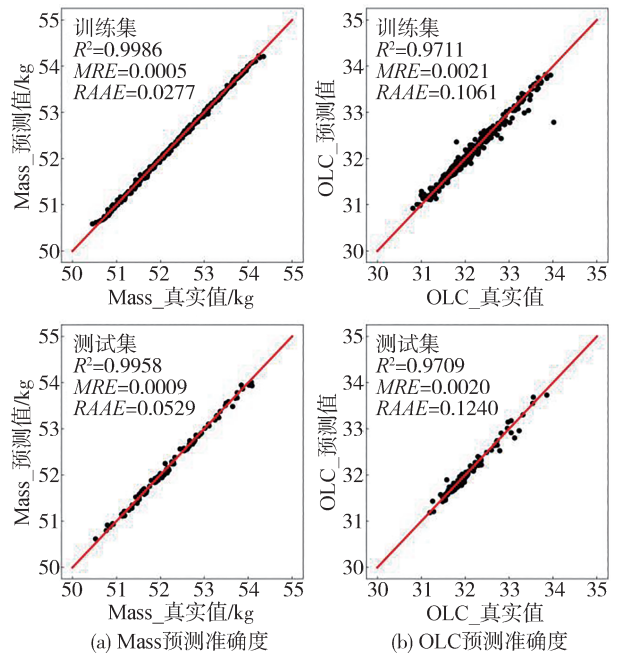


图12 Mass和OLC预测准确度评估

TOSIS 方法来选取最优解。首先使用熵权法对 Pareto 前沿中的数据进行分析,自动确定出 Mass 和 OLC 的权重,分别为 0.42 和 0.58;然后按照 TOPSIS 方法最终确定 Pareto 前沿中每个样本的相对接近度,如图 15(b)所示。相对接近度最大值对应的样本即为最优解,其在 Pareto 前沿中的位置如图 15(a)所示。

优化前后的耐撞性指标对比如表 3 所示。可以看出,最优解相较于初始设计在 Mass 和 OLC 两个指标上均有降低,说明优化取得了很好的效果。将最优解对应的样本进行了有限元仿真,得到了左右纵




图13 Mass 预测结果




图14 OLC 预测结果

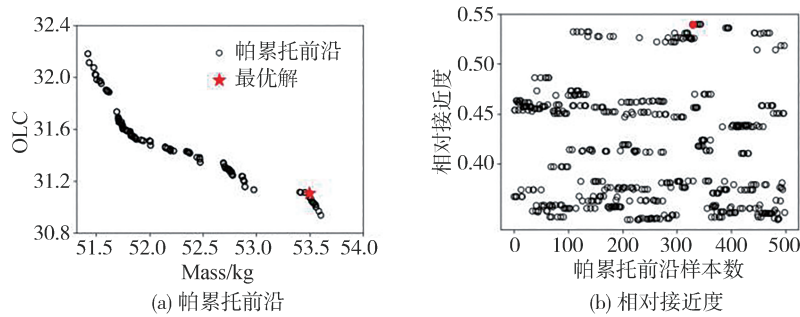


图15 多目标优化解

梁的变形模式如图16所示。左右纵梁的变形模式均为三点弯折,说明该机器学习优化方法有效地约束了变形模式,提升了耐撞性优化的有效性。

最后必须明确一点,本研究构建的深度学习模

表3 最优解与初始设计对比

| 项目 | Mass/kg | OLC |
|------|---------|-------|
| 最优解 | 53.49 | 31.10 |
| 初始设计 | 53.78 | 31.73 |




图16 最优解纵梁变形模式

型仅对 Yaris 车型有效,一般情况下对于另外一个新的优化问题,仍须重新进行数据构建,再进行模式识别,才能保证解决新问题时的有效性。但是如果仅是改变车型,仍然针对正碰中纵梁的变形模式,本文已经训练好的模式识别模型仍具有一定的预测能力,但是精度不一定有本文中精度这么高,毕竟车型改变后纵梁结构也必定有所变化。这种情况下,可以针对新车型计算少量的数据,在本研究已经建立的深度学习模型基础上进一步训练(也即迁移学习),即可达到较好的效果。换言之,如果直接使用本研究的模型,泛化能力会稍差一点,但是在此基础上使用新问题的少量数据进行迁移学习训练,即可快速达到精度要求。

4 结论

本研究提出了一种基于机器学习的耐撞性参数优化方法,以保证在耐撞性数值指标提升的同时,优化解仅能以理想的模式变形,主要研究成果如下。

(1)在该优化方法中,使用深度学习自编码结合 K-Means 聚类自动识别变形模式;采用 LightGBM 机器学习方法建立了变形模式的分类模型和数值响应的回归模型;利用 NSGA-III 进行多目标优化求解;采用熵权 TOPSIS 方法从 Pareto 前沿中选取最优解。

(2)开展了汽车正碰耐撞性优化案例研究以对本研究提出的优化方法进行验证。使用深度学习方法成功识别出左右纵梁各自的 3 种不同变形模式,其中三点弯折为理想模式;LightGBM 对变形模式分类的 AUC 指标均高于 0.96,对 OLC 和 MASS 的预测 R^2 均高于 0.97,说明了机器学习代理模型具有较高的准确性。

(3)将变形模式作为约束条件,把 OLC 和 Mass 作为优化目标进行寻优。优化结果显示使用本研究提出的优化方法获得的最优解的 OLC 和 Mass 均得到降低,且左右纵梁的变形模式均为三点弯折。

正碰耐撞性优化案例表明,本研究提出的基于机器学习的优化方法在提高耐撞性数值响应的同时,可以保证优化解仅能以理想的模式进行变形,提高了耐撞性优化的有效性。

参考文献

- [1] 冯毅,张德良,高翔.基于安全、轻量化、可靠性多目标的新能源汽车电池包壳体开发[J].汽车工程学报,2024,14(2):155-167.
FEN Y, ZHANG D L, GAO X. Development of new energy vehicle battery cases based on safety, lightweighting and reliability [J]. Chinese Journal of Automotive Engineering, 2024, 14(2): 155-167.
- [2] 余同希,卢国兴.材料与结构的能量吸收[M].北京:化学工业出版社,2006.
YU T X, LU G X. Energy absorption of materials and structures [M]. Beijing: Chemical Industry Press, 2006.
- [3] LI Z, MA W, YAO S, et al. Crashworthiness performance of corrugation-reinforced multicell tubular structures [J]. International Journal of Mechanical Sciences, 2021, 190: 106038.
- [4] 赵雪梅,吴昌生,邸曙升.ODB工况下车体前纵梁路径变形模式控制方法及应用[J],汽车工程学报,2019,9(5):320-326.
ZHAO X M, WU C S, DI S G. Control methods of deformation modes of front longitudinal beam in ODB test [J]. Chinese Journal of Automotive Engineering, 2019, 9(5): 320-326.
- [5] 崔克天,周丹凤.基于侧碰多工况的汽车B柱结构设计[J].汽车实用技术,2023,48(20):65-70.
CUI K T, ZHOU D F. Structure design of automobile B-pillar based on multi-work condition in side impact [J]. Automobile Applied Technology, 2023, 48(20): 65-70.
- [6] 夏艳红,邹光辉,江能辉,等.针对轿车、MPV及越野车型的aPLI腿型变形模式的设计策略及应用[C].2023中国汽车工程学会年会暨展览会,2023.
XIA Y H, ZOU G H, JIANG N H, et al. Design strategy and application of aPLI leg deformation mode of sedan, MPV and off-road vehicle [C]. SAECC2023, Beijing, 2023.
- [7] 陈国强,申正义,孙利,等.基于BP神经网络优化遗传算法的智能座舱感性意象预测[J].汽车工程,2023,45(8):1479-1488.
CHEN G Q, SHEN Z Y, SUN L, et al. Intelligent cockpit perceptual image prediction based on bp neural network optimization genetic algorithm [J]. Automotive Engineering, 2023, 45(8): 1479-1488.
- [8] 陈琳,何熲平,吴淑孝,等.基于自适应模糊C-均值算法的退役锂离子电池快速聚类[J].汽车工程,2024,46(4):643-651.
CHEN L, HE M P, WU S X, et al. Fast clustering of retired lithium-ion batteries based on adaptive fuzzy C-means algorithm [J]. Automotive Engineering, 2024, 46(4): 643-651.
- [9] ZHANG H, FU H, HE X, et al. Dramatically enhanced combination of ultimate tensile strength and electric conductivity of alloys

- via machine learning screening[J]. Social Science Electronic Publishing, 2024.
- [10] NIE Y, TANG Z, LIU F, et al. A data-driven dynamics simulation framework for railway vehicles[J]. Vehicle System Dynamics: International Journal of Vehicle Mechanics and Mobility, 2018, 56(3): 406-427.
- [11] LI Z, MA W, YAO S, et al. A machine learning based optimization method towards removing undesired deformation of energy-absorbing structures[J]. Structural and Multidisciplinary Optimization, 2021, 64: 919-934.
- [12] BENGIO Y. Learning deep architectures for AI[J]. Foundations & Trends in Machine Learning, 2009, 2(1): 1-127.
- [13] ZAPICO P, PENA F, VALINO G, et al. Virtual-point-based geometric error compensation model for additive manufacturing machines[J]. Rapid Prototyping Journal, 2023.
- [14] AKIBA T, SANO S, YANASE T, et al. Optuna: a next-generation hyperparameter optimization framework[J]. ACM, 2019.
- [15] SHI Y, KE G, CHEN Z, et al. Quantized training of gradient boosting decision trees[J]. Advances in Neural Information Processing Systems, 2022, 35: 18822-18833.
- [16] ISHIBUCHI H, IMADA R, SETOGUCHI Y, et al. Performance comparison of NSGA-II and NSGA-III on various many-objective test problems[C]. Proceedings of the Evolutionary Computation, F, 2016.
- [17] WALEE N A, ONISHA T A, AKINOLA A, et al. Impact of agile methodology in IT industries: a comparative study[C]. Proceedings of the SoutheastCon 2024, F, 2024.
- [18] DATTA S, GIANNELLA C, KARGUPTA H. K-means clustering over a large, dynamic network[C]. Proceedings of the Siam International Conference on Data Mining, F, 2006.
- [19] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[J]. ACM, 2016.
- [20] ALSHBOUL O, ALMASABHA G, SHEHADEH A, et al. A comparative study of LightGBM, XGBoost, and GEP models in shear strength management of SFRC-SBWS[J]. Structures, 2024, 61: 106009.
- [21] LI Q, MENG Q, CAI J, et al. Predicting hourly cooling load in the building: a comparison of support vector machine and different artificial neural networks[J]. Energy Conversion and Management, 2009, 50(1): 90-96.
- [22] DEB K, JAIN H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part I: solving problems with box constraints[J]. IEEE Transactions on Evolutionary Computation, 2014, 18(4): 577-601.

~~~~~

(上接第2189页)

- YANG X J, DENG C, LI Z, et al. A load mapping method and its application in mold structural optimization design[J]. Journal of Hunan University (Natural Sciences), 2011, 38(9): 27-31.
- [20] GU X, HE S, DONG Y, et al. An improved ordered SIMP approach for multiscale concurrent topology optimization with multiple microstructures [J]. Composite Structures, 2022, 287: 115363.
- [21] QI C, YAN L, YANG S, et al. An optimization procedure for concave preform design in rectangular tube hydroforming[J]. The International Journal of Advanced Manufacturing Technology, 2022, 120: 5311-5324.
- [22] 梁鸿宇, 刘百川, 马芳武, 等. 多工况碰撞载荷下点阵结构填充吸能盒设计策略研究[J]. 汽车工程, 2023, 45(2): 293-303.
- LIANG H Y, LIU B C, MA F W, et al. Research on design strategy of lattice structure filled crash box under multi-angle impact loading[J]. Automotive Engineering, 2023, 45(2): 293-303.
- [23] ALIZADEH R, ALLEN J K, MISTREE F. Managing computational complexity using surrogate models: a critical review[J]. Research in Engineering Design, 2020, 31(3): 275-298.