

基于 BS-TabNet 和 LSSA 的车架智能轻量化设计

聂昕¹, 刘文涛^{1,2†}, 陈少伟¹, 张承霖¹, 陈勇¹, 杨昊³

(1. 湖南大学 整车先进设计制造技术全国重点实验室, 湖南 长沙 410082;

2. 株洲中车时代电气股份有限公司, 湖南 株洲 412000;

3. 湖大艾盛汽车技术开发有限公司, 湖南 长沙 410205)

摘要:为解决传统牵引车车架轻量化设计中设计周期长、设计难度较大和过分依赖工程师经验等问题,提出了一种智能轻量化设计方法.首先,通过试验设计(Design of Experiments, DOE)联合仿真获取车架性能表格数据.其次,基于TabNet算法、贝叶斯优化算法和沙普利增量解释理论(SHapley Additive exPlanation, SHAP)构建出BS-TabNet模型,用于学习车架性能表格数据,生成车架代理模型.最后,采用莱维飞行策略对麻雀搜索算法(Sparrow Search Algorithm, SSA)进行改进,得到莱维麻雀搜索算法(Levy Sparrow Search Algorithm, LSSA),用于求解车架轻量化任务,找到最优车架结构参数.相较于传统机器学习算法,BS-TabNet模型在准确性、稳定性和可解释性三个方面都有着更高的评价,其准确度达到了0.98左右,稳定性提高50%以上,而且具有更强的可解释能力,解决了深度学习在表格型数据上表现较差的问题.相较于传统群智能优化算法,LSSA算法能够寻找到更好的优化结果,在满足其他性能要求的同时,实现了车架质量减轻5.64%的轻量化效果.智能轻量化设计方法将人工智能与车架轻量化设计相结合,能够节省大量设计时间,提高设计效率.

关键词:深度学习;贝叶斯优化;车架设计;TabNet;SHAP;SSA

中图分类号:U463.32;TP181

文献标志码:A

Intelligent Lightweight Chassis Design Based on BS-TabNet and LSSA

NIE Xin¹, LIU Wentao^{1,2†}, CHEN Shaowei¹, ZHANG Chenglin¹, CHEN Yong¹, YANG Hao³

(1. Hunan University, State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Changsha 410082, China;

2. Zhuzhou CRRC Times Electric Co., Ltd., Zhuzhou 412000, China;

3. Aisheng Automotive Technology Development Co., Ltd., Changsha 410205, China)

Abstract: In order to address the issues of long design cycles, high design complexity, and excessive reliance on engineer experience in traditional lightweight design of tractor chassis, an intelligent lightweight design method is proposed. Firstly chassis performance data is obtained through Design of Experiments (DOE) combined simulation. Then, the BS-TabNet model is constructed based on the TabNet algorithm, Bayesian optimization algorithm, and

* 收稿日期:2023-04-24

基金项目:广西区科技计划重大专项(桂科 AA23062072), Guangxi Science and Technology Major Program (AA23062072); 柳州市科技计划重大专项(2022ABA0104; 2022ABB0101), Liuzhou Science and Technology Major Program (2022ABA0104; 2022ABB0101); 国家重点研发计划资助项目(2019YFB1706504), National Key Research and Development Program of China (2019YFB1706504)

作者简介:聂昕(1982—),男,湖南常德人,湖南大学副研究员,博士

† 通信联系人, E-mail: liuwentao19970908@163.com

SHapley Additive exPlanation (SHAP) theory. This model is used to learn from the chassis performance data and generate a surrogate model for the chassis. Finally, the Levy flight strategy is applied to improve the Sparrow Search Algorithm (SSA), resulting in the Levy Sparrow Search Algorithm (LSSA), which is used to solve the lightweight design task and find the optimal structural parameters for the chassis. Compared with traditional machine learning algorithms, the BS-TabNet model shows higher accuracy, stability, and interpretability. Its accuracy reaches around 0.98, stability is improved by over 50%, and it has stronger interpretability, addressing the poor performance of deep learning on tabular data. Compared with traditional swarm intelligence optimization algorithms, the LSSA algorithm can obtain better optimization results. While meeting other performance requirements, it achieves a 5.64% reduction in chassis weight. The intelligent lightweight design method combines artificial intelligence with chassis lightweight design, and it can save a significant amount of design time and improve design efficiency.

Key words: deep learning; Bayesian optimization; chassis design; TabNet; SHAP; SSA

牵引车作为一种高效、快捷的运输车辆,在长途货运物流中扮演着越来越重要的角色,由于我国超载检测标准以车辆总质量为依据,牵引车轻量化可以在保护基础设施的前提下提升载重能力,降低耗油量,从而提升经济效益.车架作为牵引车的重要组成部分^[1],其快速轻量化设计受到业界广泛关注.

随着车辆产品设计周期的不断压缩和产品迭代速度的加快,仅依赖传统的有限元仿真软件进行优化设计难以满足市场对车辆产品高速迭代的需求.人工智能技术的发展给汽车设计领域提供了全新的发展方向,越来越多的机器学习算法被应用到了结构设计领域.Forsberg等^[2-3]基于响应面法和克里金法建立了结构性能和设计参数之间的近似关系,应用于车辆结构碰撞安全性的优化领域,在有效减少有限元模拟次数的基础上提高了优化效率.王琥等^[4]通过响应面方法研究了汽车前纵梁中不同构件板厚的优化设计问题,在保证汽车前纵梁总体质量不变的情况下提高吸能效果.Li等^[5]基于人工神经网络建立了发动机罩的代理模型,在保持结构刚度和频率的同时有效减小了发动机罩的重量和行人伤害指数.Zhu等^[6]使用决策树设计汽车锂离子电池模块的碰撞安全性,提高锂离子电池模块碰撞安全性设计的准确性和效率.

上述车辆结构代理模型研究的学习对象主要为表格数据.在处理这类数据时,决策树集成方法的各种变体已成为众多应用领域的主导技术^[7],例如极

致梯度提升(eXtreme Gradient Boosting, XGBoost)算法.随着大数据时代的到来,深度学习领域得到了飞速发展,涌现出了各种创新型深度神经网络模型,深度神经网络能够将原始数据快速编码为有意义的表达,进而实现对复杂数字信息的高效处理,随着数据量的不断增加,深度学习模型在许多领域的性能表现越来越出色.然而,尽管表格数据是现实世界人工智能中最常见的数据类型,在处理表格型数据方面,由于基于卷积层的卷积神经网络或多层感知器等模型结构的参数数量庞大,容易导致归纳偏差能力不足,从而在处理大量数据时出现过拟合现象,因此传统的深度神经网络并非最佳选择.

Arik等^[8]提出一种针对表格型数据处理的深度学习模型 TabNet,它在保留深度学习模型端到端和表征学习特点的基础上,具备决策树模型的可解释性优点,在表格型数据的学习上不弱于主流的树算法.Yan等^[9]将 TabNet 用于降雨预测上,利用气象信息之间的多变量相关性进行降雨预测,并通过实验验证了模型的有效性.Shah等^[10]提出一种基于多尺度卷积和自适应阈值改进的 TabNet 模型,并用于高光谱图像分类,在多个高光谱图像数据集上取得优于其他方法的分类性能.TabNet 的提出改变了深度学习在表格型数据上表现不佳的现状,为车辆结构代理模型的搭建提出了新的研究方向.

本文将深度学习应用于车架代理模型的搭建上,基于 BS-TabNet 模型对车架性能数据集进行学

习,并结合 LSSA 群智能优化算法,实现了车架的智能轻量化设计.

1 智能轻量化设计流程

将车架计算机辅助工程 (Computer Aided Engineering, CAE) 研究与人工智能理论相结合,构建如图 1 所示的基于深度学习的车架智能轻量化设计流程,首先通过 DOE 分析获得车架数据集,然后将处理完成的数据集输入到由贝叶斯优化算法、TabNet 算法和 SHAP 理论结合成的 BS-TabNet 模型中进行学习,训练出车架输出响应预测模型.将预测模型与车架优化目标、约束条件相结合确立轻量化任务.最后,采用 LSSA 算法对轻量化任务进行求解,得到最终优化结果.




图 1 车架智能轻量化设计流程

Fig.1 Intelligent lightweight design process for chassis

1.1 BS-TabNet 模型

BS-TabNet 模型将贝叶斯优化算法、SHAP 可解释性理论与 TabNet 深度学习算法相结合.如图 2 所示,BS-TabNet 模型首先对 TabNet 算法的超参数进行贝叶斯优化,通过对数据集的学习,模型可以精确预测车架的性能.然后引入 SHAP 理论来解释车架结构的预测过程.BS-TabNet 模型学习得到的车架预测模型不仅能根据特征设计变量数值预测车架性能,还能解释每个车架特征设计变量对车架性能的影响程度,有助于直观理解各个特征对车架性能的贡献.

1.1.1 TabNet 算法

TabNet 算法以神经网络的决策流形为基础,可以视为一种前向加性模型,如图 3^[8]所示,模型以步骤 1、步骤 2 等多个重复的决策结构为基础构造,每个决策结构都包含注意力转换器层、掩码层、特征转




图 2 BS-TabNet 模型

Fig.2 BS-TabNet model

换器层、分裂层和激活函数 ReLU 层,各个步骤依次相连形成累加模型.每个步骤的输入数据首先经过批正则化层进行批量归一化,然后在特征转换器层进行特征加工,随后,分裂层将数据分为两个子集,一个子集通过激活函数 ReLU 层处理,作为当前步骤的输出,另一个子集则被用作下一步骤的输入.在接收到处理好的数据后,每一步骤都会先通过注意力转换层和掩码层进行特征筛选,然后重复前述数据处理操作,经特征转换器层完成特征加工.最后将各步骤的输出求和后,作为最终输出结果.




图 3 TabNet 算法框架^[8]

Fig.3 TabNet algorithm framework^[8]

1.1.2 超参数贝叶斯优化

BS-TabNet 模型中的超参数优化问题^[11]是通过多次迭代评估 TabNet 算法的超参数配置,优化出最佳性能的超参数组合,可以表述为式(1),将需要优化的超参数设置为一个向量 $\mathbf{x}$,将目标函数设置为 $f(\mathbf{x})$,目标函数为训练后的模型在测试集上的评价指标.优化目标为在超参数选择空间中找到一组使 TabNet 学习后在测试集上表现最好的超参数向量 $\mathbf{x}^*$.

$$\mathbf{x}^* = \arg \min_{\mathbf{x} \in X} f(\mathbf{x}) \quad (1)$$

式中: X 表示待调优超参数空间; $\mathbf{x}$ 表示超参数向量; $\mathbf{x}^*$ 是 X 中寻找到的一组使 $f(\mathbf{x})$ 目标函数得到最优值的超参数组合。

贝叶斯优化算法^[12-13]利用过去的评价结果建立一个概率模型, 以此反映超参数在目标函数上表现的概率分布, 用于指导下一次参数选择, 从而避免把大量时间、计算资源都耗费到无谓的采样点上。其优化过程主要包含两个方面, 一是高斯过程(Gaussian Processes, GP), 用来代表被优化函数的分布假设, 输出为高斯分布的平均数和方差; 二是采集函数(Acquisition Function), 用于在模型后验分布中构造出效用函数, 从而决定下一代用于评估的超参数组合向量 $\mathbf{x}$ 。

1) 高斯过程

高斯过程是一种观测值出现在一个连续域的随机统计过程, 是多维高斯分布在无限维随机过程上的扩展, 从而将无限维的数据样本拟合成一个高斯回归模型。如式(2)所示。

$$\begin{aligned} f(x) &\sim \text{GP}(m(x), k(x, x')) \\ m(x) &= E[f(x)] \\ k(x, x') &= E[(f(x) - m(x))(f(x') - m(x')))] \end{aligned} \quad (2)$$

式中: GP 表示高斯过程; $m(x)$ 是均值, 表示函数相对于原点的偏移量; $k(x, x')$ 是方差, 描述了函数的分布形状。

通常设置均值函数为 0, 将上述过程变为服从正态分布的随机变量的联合分布, 且该联合分布服从多元高斯分布, 如式(3)所示。

$$f(x) \sim \text{GP}(0, k(x, x')) \quad (3)$$

对于 n 个点和其评价指标数据集 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 满足 n 维高斯分布条件, 代入式(3)中, 构建 n 元高斯分布函数, 如式(4)所示。

$$\begin{bmatrix} f(x_1) \\ \vdots \\ f(x_n) \end{bmatrix} \sim N \left(0, \begin{bmatrix} k(x_1, x_1) & \cdots & k(x_1, x_n) \\ \vdots & & \vdots \\ k(x_n, x_1) & \cdots & k(x_n, x_n) \end{bmatrix} \right) \quad (4)$$

式中: N 表示 n 元高斯分布函数; $k(x, x')$ 为协方差函数, 可表达为式(5)。

$$k(x_i, x_j) = \exp \left(-\frac{1}{2} (x_i - x_j)^2 \right) \quad (5)$$

要得到 x_{n+1} 的预测结果 y_{n+1} , 则假设 $n+1$ 个点满足高斯分布, 代入式(4)中, 从而得到第 $n+1$ 个点的

评价值。

$$\begin{bmatrix} f_{1:n} \\ f_{n+1} \end{bmatrix} \sim N \left(0, \begin{bmatrix} \mathbf{K}, \mathbf{k}^T \\ \mathbf{k}, k(x_{n+1}, x_{n+1}) \end{bmatrix} \right) \quad (6)$$

式中: $\mathbf{K}$ 和 $\mathbf{k}$ 的表达式分别如式(7)和式(8)所示。

$$\mathbf{K} = \begin{bmatrix} k(x_1, x_1), \dots, k(x_1, x_n) \\ \vdots \\ k(x_n, x_1), \dots, k(x_n, x_n) \end{bmatrix} \quad (7)$$

$$\mathbf{k} = [k(x_{n+1}, x_1), k(x_{n+1}, x_2), \dots, k(x_{n+1}, x_n)] \quad (8)$$

2) 采集函数

采集函数是贝叶斯优化算法的重要步骤, 作用为决定算法执行过程中下一步的具体走向, 通常方向为模型预测值大的地方或结果不确定(即方差大)的地方。采集函数是一个均衡开发(exploitation)和探索(exploration)两个方面的函数, 开发是在当前找到的最优值附近加大搜索参数力度, 从而更快地寻找到全局范围的最优值; 探索是尝试选取没有评估过的参数组合值, 让 $f(x)$ 的后验概率与真实的 $f(x)$ 更加贴近, 进而避免进入局部最优值。BS-TabNet 模型采用改进概率 PI 作为采集函数, 其核心是最大化下一步选择的点以增加最大值的概率, 如式(9)所示。

$$\begin{aligned} u(x) &= \text{PI}(x) = P(f(x) \geq f(x^*) + \theta) = \\ &\Phi \left(\frac{\mu(x) - f(x^*) - \theta}{\sigma(x)} \right) \end{aligned} \quad (9)$$

式中: $f(x)$ 为目标函数值; $f(x^*)$ 为当前最佳目标函数值; $\Phi(\cdot)$ 为正态累积分布函数; $\mu(x)$ 、 $\sigma(x)$ 分别为高斯过程获取的目标函数的均值与方差; θ 为动态调整系数, 通过调整 θ 的数值来控制下一步方向是偏向探索还是偏向开发。

1.1.3 SHAP 可解释理论

随着机器学习算法复杂度的不断增加, 机器学习模型的预测精准度也随之不断增加, 但算法复杂度的增加使模型的可解释性大幅度降低, 在结构设计领域中, 工程师会难以理解构建出的结构性能预测模型中各个输入特征对模型的预测输出结构有着怎样的影响。所以, BS-TabNet 模型引入 SHAP 理论对智能化设计有着重要意义。

SHAP 可解释理论是 Lunderg 等^[14]提出的一种与模型无关的全局解释理论。通过博弈论的理论, 将每一个特征都作为贡献者, 计算每个特征对模型的边际贡献来衡量特征对模型输出结果影响的大小, 即 Shapley 值, 如式(10)所示。

$$g(z) = \phi_0 + \sum_{i=1}^M \phi_i z_i \quad (10)$$

式中: g 代表解释模型; M 代表特征的数量; z 取值为0或1,代表该特征是否存在; ϕ_i 为第*i*个特征 Shapley 值; $\phi_i > 0$ 时,说明特征对预测值有提升作用, $\phi_i < 0$ 时,说明特征对预测值有降低作用。

1.2 LSSA 算法

1.2.1 麻雀算法(SSA)

SSA算法是一种基于麻雀觅食行为和反哺食行为的群智能优化算法,由Xue等^[15]在2020年提出.麻雀种群在觅食过程中分为探索者和追随者两种类型,探索者的搜索范围是最大的,主要是为麻雀寻找食物,并向追随者传递食物所在位置的信息,追随者主要跟随探索者进行搜索,它们的搜索范围小且多用来局部查找极值。

SSA算法在搜索过程中,探索者需要为整个种群寻找食物,为之后的追随者提供食物方位的搜索方向,因此,探索者的搜索范围较大,其位置更新如式(11)所示。

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{a \cdot \text{iter}_{\max}}\right), & \text{if } R_2 < ST \\ X_{i,j}^t + Q \cdot L, & \text{if } R_2 \geq ST \end{cases} \quad (11)$$

式中: t 是迭代次数; $\text{iter}_{\max}$ 代表迭代次数的上限; $X_{i,j}$ 是第*i*个麻雀于第*j*维中所处的位置; a 是取值于(0,1]之间的随机数; L 是一个元素均为1的 $l \times d$ 矩阵; Q 是一个服从正态分布的随机数; R_2 和 ST 分别为预警值和安全值.当 $R_2 < ST$ 时,表示探索者所处位置周围没有发现捕食者,可以进行大范围的搜索操作,当 $R_2 > ST$ 时,说明当前麻雀被捕食者所发现,需要向种群成员传递信息,迁移到其他地点进行觅食行为。

一些追随者会在觅食过程中跟随探索者,如果探索者发现了更好的食物,追随者会立即加入去争抢食物,追随者的位置更新描述如式(12)所示。

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_{\text{worst}}^t - x_{i,j}^t}{t^2}\right), & \text{if } i > n/2 \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A^+ \cdot L, & \text{otherwise} \end{cases} \quad (12)$$

式中: X_p 是探索者发现的最好位置; x_{worst} 是截至当前迭代中位置最差的地方; A 表示一个 $l \times d$ 的矩阵,其中每个元素的值依概率随机分配为1或-1. $i > n/2$ 的

情况,意味着第*i*个适应度较低的追随者无法获得食物,需要寻找其他地方以获取更丰富的食物资源。

麻雀种群在感知到潜在危险时,将会采取反捕食行为进行预警,数学表达式如式(13)所示。

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t|, & \text{if } f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right), & \text{if } f_i = f_g \end{cases} \quad (13)$$

式中: X_{best} 是到*t*次迭代的全局最优位置; β 是一个服从正态分布的随机数; K 是在区间[-1,1]内均匀分布的随机数; ε 是较小的常数,作用为避免分母变成零; f_g 与 f_w 分别表示麻雀种群中当前具有最高和最低适应度值的个体; f_i 表示当前麻雀个体的适应度值.当 $f_i > f_g$ 时表示当前麻雀位于觅食位置的边缘,极易遭遇捕食者的袭击;当 $f_i = f_g$ 时表示当前麻雀处于觅食范围的中心,需要向附近的麻雀靠近,从而减小自身被捕食的概率。

SSA算法的流程如图4所示。




图4 SSA算法流程图

Fig.4 SSA algorithm flowchart

1.2.2 莱维飞行策略

莱维飞行^[16](Levy-flight)是一种基于莱维分布的随机搜索策略,它将较短距离的局部搜索和较长距离的随机行走结合起来,帮助算法快速跳出局部最优解进行全局搜索.许多生物采用该随机游走策略寻找食物,因此对于基于生物种群的SSA算法来说,通过莱维飞行策略进行改进后,搜索算法可以在自身周围进行长时间的局部勘探,同时也能够进行

较长距离的搜索,有助于发现新的解空间区域.莱维飞行的数学表达式为:

$$s = \frac{\mu}{\left|v^{\frac{1}{\beta}}\right|} \tag{14}$$

式中: s 表示参数为 β 莱维飞行的路径; $\mu \sim N(0, \sigma_u^2)$, $v \sim N(0, \sigma_v^2)$; σ_u 和 σ_v 可由式(15)和式(16)所得.

$$\sigma_u = \left\{ \frac{\Gamma(1+\beta) \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left[\frac{1+\beta}{2}\right] \beta \cdot 2^{\frac{\beta-1}{2}}} \right\}^{\frac{1}{\beta}} \tag{15}$$

$$\sigma_v = 1 \tag{16}$$

式中: $\Gamma(x)$ 是Gamma函数; $0 < \beta \leq 2$,通常取值1.5.

1.2.3 改进麻雀算法(LSSA)

使用莱维飞行策略对SSA算法中的式(11)进行修改,如式(17)所示.

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + X_{i,j}^t \cdot s, & \text{if } R_2 < ST \\ X_{i,j}^t + Q \cdot L, & \text{if } R_2 \geq ST \end{cases} \tag{17}$$

式中: s 是参数为 β 的莱维分布随机函数.

对式(13)进行修改,修改后的公式为式(18).

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t \cdot s + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t \cdot s|, & \text{if } f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right), & \text{if } f_i = f_g \end{cases} \tag{18}$$

式中: s 是参数为 β 的莱维分布随机函数.

2 牵引车车架联合仿真分析

2.1 牵引车车架CAE分析

2.1.1 车架参数化建模

由于传统车身结构设计开发过程繁琐,参数化设计被广泛应用在车辆总成结构的设计上.如图5所示,牵引车车架的基本结构包括纵梁、前板簧固定横梁、中桥处横梁、变速处横梁、平衡悬架横梁和后横梁,车架采用钢材制造,其中包括750L、590L和Q345等主要材料,具体结构的材料属性如表1所示.对这些结构进行隐式化参数建模以保持其原有的拓扑关系和几何关系,保证模型在参数修改后可以后续的分析,将可修改的基本结构参数作为特征设计变量,用于对牵引车车架进行智能轻量化设计.




图5 车架的基本结构组成

Fig.5 Basic structural components of chassis

表1 车架基本组成结构的材料

Tab.1 Chassis basic structure materials

车架基本组成结构	材料
纵梁	750L
平衡悬架横梁	750L
变速处横梁	750L
前板簧固定横梁	Q345
中桥处横梁	750L
后横梁	590L

2.1.2 车架有限元分析

车架在设计初期需进行有限元仿真模拟分析其刚度性能和模态性能^[17].车架所承担的载荷^[18]可以分为两类,一是使车架弯曲的弯曲载荷,二是使车架扭转的扭转载荷,车架在各种载荷的共同影响下要确保结构受到的最大载荷不超过材料的屈服强度,使得在工作过程中不会发生开裂等失效状况,这是车架正常工作的基本保证.根据载荷的分类,车架的刚度工况主要分为弯曲工况和扭转工况,刚度工况如表2所示,前三行详细列出了三种刚度工况的 F (Force,载荷)和 C (Constraint,约束)条件,分别对应图6(a)、图6(b)、图6(c).

牵引车车架是一个多自由度的弹性振动系统,为避免在车辆运行过程中产生共振现象,需要在设计过程中考虑车架的模态性能,对车架进行模态分析,得出车架的固有频率和振型.车架在实际工作中需要连接发动机、悬架系统、传动系统等部件,约束条件复杂,因此在概念设计阶段通常对自由模态进行分析,自由模态分析是指在不定义任何约束的自由边界条件下进行模态分析,如表2最后一行所示,对应图6(d).

表 2 车架刚度工况表

Tab.2 Chassis stiffness operating conditions table

工况	载荷位置	载荷大小	约束位置	约束自由度
弯曲 工况	约束点中心对 应纵梁上翼面 中线节点处	左右各 2 500 N·m	车架前轴板簧固	1、2、3
			定端支座轴销孔	1、2、3
前扭 工况	车架前轴板簧 固定端支座轴 销孔	3 000 N·m	第一横梁底部正 中处节点	3
			后悬平衡悬架铸 件轴中心主节点	1、2、3
后扭 工况	后悬平衡悬架 铸件轴中心主 节点	3 000 N·m	车架前轴板簧固	1、2、3
			定端支座轴销孔	1、2、3
自由 模态	无	无	无	无




图 6 车架工况图

Fig.6 Chassis operational diagram

2.1.3 车架后处理分析

通过 OptiStruct 求解器对四种工况进行有限元计算,得到位移云图,车架在四种工况下计算得到的 Hyperview 位移云图如图 7 所示.

车架刚度性能分析是通过图 7(a)弯曲工况位移云图和图 7(b)、图 7(c)扭转工况位移云图得到车架施加载荷点的最大位移和扭转角度,然后结合式(19)~式(21),得到车架的弯曲刚度和扭转刚度.

$$K_{\text{bend}} = \frac{\frac{F}{D_{\text{maxl}}} + \frac{F}{D_{\text{maxr}}}}{2}$$

(19)




图 7 Hyperview 位移云图

Fig.7 Hyperview displacement cloud map

式中: K_{bend} 为弯曲刚度,N/mm; F 为纵梁在左右侧施加载荷之和,N; D_{maxl} 和 D_{maxr} 分别为图 7(a)弯曲工况下车架位移云图左侧纵梁和右侧纵梁的 Z 向最大位移,mm.

$$K_{\text{flor}} = \frac{M_{\text{lf}}}{\theta_{\text{lf}}} \tag{20}$$

$$K_{\text{rtor}} = \frac{M_{\text{tr}}}{\theta_{\text{tr}}} \tag{21}$$

式中： K_{flor} 和 K_{rtor} 分别为前扭刚度和后扭刚度， $(\text{N}\cdot\text{m})/(\text{^\circ})$ ， M_{lf} 和 M_{tr} 分别为前扭工况和后扭工况的扭矩， $\text{N}\cdot\text{m}$ ； θ_{lf} 和 θ_{tr} 为图7(b)、图7(c)扭转工况下车架位移云图前端扭转角和后端扭转角， $(\text{^\circ})$ 。

车架模态分析是将模态工况计算结果在Hyper-view软件中进行动态分析,如图7(d)所示,得到一阶固有频率为6.07 Hz,根据振型可知为扭转模式。

2.2 车架DOE分析

车架代理模型搭建的前提步骤是需要获取要学习的数据集.根据工程设计经验从车架结构中选取 $F_1\sim F_9$ 9个特征变量,表3给出了9个特征变量的名称和描述,这些变量的变化范围为 $-12\sim12\text{ mm}$,如图8所示.这些车架设计变量可以反映车架整体的结构特征,包含主要横梁和纵梁在三个方向上的宽度变化和位移变化.车架的输出响应见表3后5行,分别是Mass、Kbend、Kftor、Krtor和Mode_1.

表3 特征变量和响应描述

Tab.3 Characteristic variables and response descriptions		
符号	名称	描述
F_1	spring_beam_width_x	前板簧固定横梁x向宽度变量
F_2	speed_beam_width_x	变速处横梁x向宽度变量
F_3	bridge_beam_width_x	中桥处横梁x向宽度变量
F_4	carling_width_y	两侧纵梁y向宽度变量
F_5	carling_width_z	两侧纵梁z向高度变量
F_6	rear_beam_width_x	后横梁x向宽度变量
F_7	balance_beam_width_x	平衡悬架横梁x向宽度变量
F_8	bridge_beam_dis_x	中桥处横梁x向位移变量
F_9	speed_beam_dis_x	变速处横梁x向位移变量
1	Mass	车架整体质量
2	Kbend	车架整体弯曲刚度
3	Kftor	车架前扭刚度
4	Krtor	车架后扭刚度
5	Mode_1	一阶模态




图8 车架特征向量图

Fig.8 Chassis feature vector diagram

通过Isight软件联合CAE进行DOE分析,得到牵引车车架的特征和性能的表格型数据集,如图9所示.数据集包含2 000条数据,每一行对应一次工作流程得到的车架数据。

	F1	F2	F3	F4	F5	F6	F7	F8	F9	Mass	Kbend	Kftor	Krtor	Mode_1	
0	-10.619	-1.639	8.242	5.853	7.309	-9.143	-8.566	5.361	-0.726	1.055	531	12086.7678	10811.97597	8833.344915	5.846323
1	5.025	-5.553	-5.205	-11.556	-0.966	1.963	8.086	-8.614	-6.081	1.073766	12274.9542	12008.81532	8622.598004	6.825573	
2	-2.779	-0.474	7.714	8.218	-8.338	-0.234	11.832	6.009	-7.522	1.031691	12153.3030	11138.61748	9266.445448	6.113580	
3	0.006	4.004	10.583	-7.402	-6.825	-10.475	5.697	-7.354	-8.374	1.052116	12288.4038	11337.54886	8934.612518	6.276345	
4	5.637	-1.951	-0.834	6.177	1.831	1.723	11.088	-11.184	-2.791	1.047200	12144.5946	11866.29458	9084.116399	6.708963	
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
1995	10.319	-8.014	11.760	-6.165	1.075	5.001	8.602	-0.078	-4.808	1.061988	12281.0670	12241.42076	8836.153027	7.015890	
1996	2.479	-11.304	7.654	-2.275	-7.078	-5.721	-11.280	8.782	-0.054	1.079703	12136.7664	11522.14995	8570.188443	6.427385	
1997	8.554	-4.316	-9.803	2.107	2.731	-3.680	0.318	-8.578	5.697	1.063987	12097.1556	12162.91885	8856.403706	6.951660	
1998	-10.043	-1.039	6.057	1.279	5.721	-1.255	-11.640	2.035	-6.117	1.059044	12078.4266	10930.43771	8731.436556	5.943248	
1999	3.524	-10.295	5.073	-0.150	7.930	6.921	-8.218	5.613	-11.292	1.074704	12198.6990	11694.21982	8618.607582	6.568172	

图9 牵引车车架数据集

Fig.9 Tractor chassis dataset

3 车架轻量化

3.1 车架BS-TabNet代理模型

3.1.1 代理模型学习

TabNet算法有许多超参数,这些超参数的选取严重影响模型的性能.表4给出了TabNet算法超参数的含义、初始值以及优化范围,BS-TabNet模型可以通过贝叶斯算法对这些超参数进行优化,获得车架不同响应预测任务中的最佳超参数取值。

表4 BS-TabNet模型的超参数

Tab.4 Hyperparameters of the BS-TabNet model			
超参数	含义	初值	优化范围
n_d	特征转换器层和决策转换器层的隐藏维度大小	64	[4,64]
n_a	特征转换器层和决策转换器层中的注意力头数	8	[4,64]
n_steps	每个TabNet Block的迭代次数	3	[1,10]
gamma	用于控制重要性损失的系数	1.5	[0.5,2.0]
epsilon	用于控制分割函数的阈值	1e-8	[1e-8,1e-2]
ls	用于控制稀疏性约束的系数	1e-5	[1e-5,1e-1]
lr	学习率	0.02	[1e-5,0.1]

图10展示了BS-TabNet模型在搭建车架质量预测代理模型中超参数的优化过程,前7列为7种超参数的取值范围,最后一列为评价指标,可以看出这些超参数的取值对于学习到的预测模型的准确性有非常大的影响,不同的超参数组合能够学习到不同预测精度的车架代理模型,BS-TabNet模型通过高效方法快速寻找到最佳的超参数组合,从而获得最好的车架预测代理模型。




图 10 BS-TabNet 超参数优化图

Fig.10 Hyperparameter optimization diagram for BS-TabNet

BS-TabNet 模型对车架 5 种输出响应进行学习,得到的超参数最终取值如表 5 所示,对于车架 5 个输出响应的预测任务,BS-TabNet 模型采用了不同的超参数数值,这不仅提升了模型预测的精确性和稳定性,同时也增大了模型在车架实际预测应用中的鲁棒性和准确性.

表 5 车架预测模型 BS-TabNet 最佳超参数

Tab.5 Optimal BS-TabNet’s hyperparameters of the chassis prediction model

超参数	Mass	Kbend	Kftor	Krtor	Mode_1
n_d	37	39	24	20	48
n_a	42	37	35	34	54
n_steps	10	8	1	10	5
γ	0.5	0.57	0.5	0.5	0.62
ϵ	$1e-8$	$2.2e-3$	$1e-2$	$1e-2$	$8.3e-3$
ls	0.089	0.005 2	$1e-5$	$1e-5$	$6.8e-3$
lr	0.051	0.062	0.1	0.1	0.023

3.1.2 模型准确性分析

将车架数据集进行 7:3 划分,其中 70% 的数据作为训练集输入至 BS-TabNet 模型中,剩下的 30% 数据作为测试集用于评估学习到的模型性能.使用均方根误差(Root Mean Squard Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)、决定系数(R-Squared, R^2)作为评价指标,它们的公式如下:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \tag{22}$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \tag{23}$$

$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\bar{y} - y_i)^2} \tag{24}$$

式中: m 表示样本数量; y_i 为测试集上的真实值; $\hat{y}_i$ 为测试集上的预测值.

在使用 BS-TabNet 模型对车架五种输出响应预测的同时,对比传统的机器学习算法 K 近邻回归(K-Nearest Neighbor, KNN)、支持向量机(Support Vector Regression, SVR)、随机森林(Random Forest, RF)和当前在表格型数据上表现较好的 XGBoost 算法.根据评价指标定义可知, RMSE 和 MAE 值越小, R^2 值越大,模型的预测性能越优秀.对比结果见表 6,可以看出,相较传统机器学习算法, BS-TabNet 模型在预测精确度更加准确.即使是在表格型数据上表现较好的 XGBoost 算法,其学习到的车架代理模型预测精确度也比不上 BS-TabNet 模型.

表 6 车架代理模型评价指标

Tab.6 Evaluation metrics for the chassis surrogate model

性能	模型	RMSE	MAE	R^2
Mass	KNN	0.069 619	0.056 235	0.872 539
	SVR	0.049 502	0.040 915	0.923 471
	RF	0.043 057	0.034 709	0.947 779
	XGBoost	0.037 739	0.030 125	0.963 216
	BS-TabNet	0.021 713	0.017 926	0.985 233
Kbend	KNN	0.071 063	0.058 259	0.822 619
	SVR	0.049 762	0.040 263	0.905 880
	RF	0.051 303	0.041 167	0.911 822
	XGBoost	0.047 723	0.038 787	0.922 541
	BS-TabNet	0.031 658	0.022 961	0.975 273
Kftor	KNN	0.089 947	0.068 315	0.871 833
	SVR	0.065 392	0.057 286	0.926 112
	RF	0.029 558	0.023 116	0.985 311
	XGBoost	0.024 631	0.019 308	0.989 324
	BS-TabNet	0.012 677	0.010 531	0.994 161
Krtor	KNN	0.063 168	0.050 595	0.880 472
	SVR	0.046 850	0.038 678	0.921 749
	RF	0.039 622	0.031 191	0.949 654
	XGBoost	0.033 375	0.026 222	0.961 884
	BS-TabNet	0.017 335	0.014 183	0.993 377
Mode_1	KNN	0.089 947	0.068 315	0.871 833
	SVR	0.065 392	0.057 286	0.926 112
	RF	0.029 387	0.023 204	0.985 824
	XGBoost	0.024 631	0.019 308	0.989 324
	BS-TabNet	0.013 671	0.011 053	0.982 542

根据 BS-TabNet 模型和其他机器学习算法预测结果,绘制散点图进行对比分析,由于预测结果较多,只选取车架质量的预测结果图作为代表,如图 11 所示,可以看出不同算法的预测值与真实值的偏差,相对于其他机器学习算法, BS-TabNet 模型预测出来的点基本上都更加聚集于中间的直线,说明 BS-TabNet 模型预测值更加贴近真实值,预测出的结果




图 11 车架质量预测散点图

Fig.11 Chassis mass prediction scatter plot

更加准确.

3.1.3 模型稳定性分析

为了更准确地评估 BS-TabNet 模型对车架性能预测结果的稳定性,将预测精准度绘制成箱型图与其他机器学习算法预测结果对比.用 K 折分层抽样交叉验证方法测试车架数据集,把样本全集采用分层抽样的方法分成 K 个子集,然后每次把 $K-1$ 个子集作为训练集,剩下一个子集作为测试集,测试模型的评价指标,取 K 为 10 分别对车架五种响应进行预测,将预测结果绘制成箱型图,以观察算法预测精度的整体分布情况,如图 12 所示.

图 12 分别为对质量、弯曲刚度、前扭刚度、后扭刚度和一阶模态的预测箱型图,箱型图的横坐标为不同的机器学习算法,纵坐标是预测出的性能指标 R^2 ,每个箱子中间线表示用该算法 10 次预测精度的中位数,箱子的上下底分别代表上四分位数(Q_3)和下四分位数(Q_1),箱子的上下边缘线表示 10 次预测精度值中的最大值和最小值.分析对比可知,BS-TabNet 模型的箱型图位置均在最高处,说明预测精度最高,同时箱子的宽度最小,说明 BS-TabNet 模型对车架性能预测结果的稳定性更强,相较于 KNN 算法,BS-TabNet 模型的稳定性提高了 75%;相较于 XGBoost 算法,稳定性提高了 50%.这种稳定性优势得益于 BS-TabNet 模型在每次数据集学习过程中进行深度学习迭代和超参数调优,从而使每一次预测精准度都达到最好的效果.而其他机器学习算法在不同响应预测的精度方面存在较大波动,所以 BS-TabNet 模型更适合应用于车架性能响应的预测.

3.1.4 模型可解释性分析

BS-TabNet 模型具有较强可解释能力,图 13 展示了该模型在预测车架弯曲刚度时单个样本的 SHAP 特征分析效应图,可以查看单个样本的特征贡献.图中 $f(x)$ 为模型预测车架性能单个样本的输出值,弯曲刚度预测模型所有样本的输出平均值为 12 108.2 N/mm,箭头方向和长度分别表示不同车架特征对车架性能的正面和负面贡献,蓝色特征将预测值推向较低值,红色特征将预测值推向较高值.箭头越长,对应特征的贡献越大,特征 F_7 和 F_2 对弯曲刚度增大有较大贡献, F_9 、 F_6 和 F_5 对弯曲刚度的减小有较大贡献.

图 13 是对单个样本的解释,通过进一步绘制所




图12 模型对比箱型图

Fig.12 Model comparison box plot




图13 SHAP分析效应图

Fig.13 SHAP analysis effect plot

有样本的车架特征与SHAP值之间的关系,得到SHAP特征分析汇总图,如图14所示,可从全局角度解释车架特征属性如何影响车架性能.以弯曲刚度为例,图14分别显示了每个特征尺寸参数对弯曲刚度影响的范围和分布,图中Y轴代表所有按其全局贡献排序的特征,X轴代表SHAP值.图中有大量样本点,这些样本点使用不同颜色代表不同的特征值,从低(蓝色)到高(红色).对于弯曲刚度预测模型来说,影响性能的主要特征为 F_9 ,其值越大,对模型预测值的负贡献越大,其他特征如 F_1 和 F_6 等对弯曲刚度也有着较大影响.




图14 SHAP特征分析汇总图

Fig.14 SHAP feature summary plot

3.2 车架轻量化任务

结构优化是实现轻量化的关键方法之一,旨在找到最优设计方案,在确保强度、刚度等基本性能的前提下实现结构最小重量.本文基于车架的参数化模型,可以实现对车架的尺寸优化和形状优化,尺寸优化涉及7个特征($F_1 \sim F_7$),通过调整车架结构水平和竖直方向的尺寸来实现优化.形状优化包含两个特征(F_8 和 F_9),通过改变车架横梁结构的整体位置实现优化.

车架优化任务的数据如表7所示,车架特征设计变量的优化范围为该特征变量的最大最小值之间,可以适量在变化范围内增大10%,以扩大其寻优范围.表中 f_{Mass} 、 g_{Bend} 、 g_{Flor} 、 g_{Rtor} 、 g_{Model} 分别为使用BS-TabNet模型学习出来的车架五种输出响应的代理模型.在车架轻量化优化过程中,除寻找最小质量及相

应特征设计变量取值外,其余性能指标应能够维持原状,本文将其余性能的目标值在初始值的基础上进行适度增大,用于提高车架各种性能,在工程应用中可以根据具体的工程要求对目标值进行更改,以满足不同的工程实际应用要求.

表 7 车架优化任务

Tab.7 Chassis optimization task

优化目标	数学模型	初始值	目标值
$F_1 \sim F_9/\text{mm}$	$x_1 \sim x_9$	0	-14~14
Mass/kg	f_m	1 053.75	min
Kbend/(N/mm)	g_{Bend}	12 110	$\geq 12\ 200$
Kftor/[N·m/(°)]	g_{Flor}	11 463	$\geq 11\ 500$
Krtor/[N·m/(°)]	g_{Rtor}	8 925	$\geq 9\ 000$
Mode_1/Hz	g_{Mode_1}	6.38	≥ 6.40


定义了具体优化任务后,车架的轻量化问题可以被表述为一个受约束的最优化问题,相应的数学表达式如式(25)所示.

$$\begin{aligned} & \min f_{\text{Mass}}(x_1, x_2, \dots, x_9) \\ & \text{s.t.} \begin{cases} \min(x_i) < x_i < \max(x_i) & i = 1, 2, \dots, 9 \\ g_{\text{Bend}}(x_1, x_2, \dots, x_9) > 12\ 200 \\ g_{\text{Flor}}(x_1, x_2, \dots, x_9) > 11\ 500 \\ g_{\text{Rtor}}(x_1, x_2, \dots, x_9) > 9\ 000 \\ g_{\text{Mode}_1}(x_1, x_2, \dots, x_9) > 6.40 \end{cases} \end{aligned} \quad (25)$$


3.3 车架优化结果

使用 LSSA 算法对式(25)描述的车架优化任务进行寻优,并与 SSA 算法进行对比,图 15 是优化过程,图 15(a)、图 15(b)反映了种群在迭代过程中向最优适应度探寻的趋向,可以看到,经过 1 000 次迭代,SSA 算法的种群平均适应度已经位于种群最佳适应度位置,而 LSSA 算法种群平均适应度并未完全靠近种群最佳适应度;图 15(c)、图 15(d)是种群初始适应度和迭代结束后种群最终适应度位置图,可以看到,SSA 算法优化后只有一小部分种群最终位置位于上方的搜索区域,而 LSSA 算法优化后大部分种群仍在较高的适应度范围内进行搜索.这说明相较于 SSA 算法,经过莱维飞行策略改进后的 LSSA 优化算法在寻找到较优解后,还会积极向其他方向探索,有效避免了陷入局部最优解,从而寻找到其他更优的解决方案.


LSSA 优化算法的优化出的设计变量 F1~F9 取值见表 8,并与粒子群算法(Particle Swarm Optimization, PSO)、遗传算法(Genetic Algorithm, GA)和差分




(a)SSA 算法适应度迭代图



(b)LSSA 算法适应度迭代图



(c)SSA 算法种群变化图



(d)LSSA 算法种群变化图

图 15 LSSA 和 SSA 算法优化图

Fig.15 LSSA and SSA algorithm optimization diagram

进化算法(Differential Evolution, DE)等经典的群智能优化算法进行对比,可以看出,各个特征设计变量

的优化结果大多都在一定的范围内,例如, F_2 优化结果取值基本上在 11~14 mm, F_5 的优化结果取值在 -5~-2 mm.

表 8 车架特征设计变量优化结果

Tab.8 Optimization results of chassis design variables									
算法	$F_1/$ mm	$F_2/$ mm	$F_3/$ mm	$F_4/$ mm	$F_5/$ mm	$F_6/$ mm	$F_7/$ mm	$F_8/$ mm	$F_9/$ mm
PSO	4	14	8	8	-2	1	14	12	-10
GA	5	13	9	11	-2	1	12	12	-8
DE	7	12	8	14	-2	0	10	14	-13
LSSA	5	13	10	12	-5	-1	12	12	-8

这 4 种群智能优化算法求解出的车架输性能结果见表 9,可以看出,LSSA 优化算法优化出的车架质量最小,为 994.27 kg,较车架初始质量减少了 5.64%,并在优化出车架最轻质量的同时,也保证了弯曲刚度、前扭刚度、后扭刚度和一阶模态满足工程设计要求.

表 9 车架输出响应优化结果

Tab.9 Optimization results of chassis output responses					
算法	Mass/kg	Kbend/ (N/mm)	Kftor/ [N·m/(°)]	Krtor/ [N·m/(°)]	Mode_1/ Hz
PSO	1 003.97	12 201.1	11 525.6	9 743.4	6.453 9
GA	1 004.26	12 200.8	11 666.5	9 746.1	6.534 4
DE	1 012.47	12 245.6	11 981.2	9 698.3	6.791 7
LSSA	994.27	12 211.5	11 664.6	9 724.1	6.530 8

3.4 仿真验证

为了进一步验证车架智能轻量化设计方法结果的准确性,在 Hyperworks 软件中使用表 8 优化出的特征设计变量来对牵引车车架有限元模型进行修改与求解,得到经 CAE 分析后的车架质量、弯曲刚度、前扭刚度、后扭刚度和一阶模态性能,并与前面基于 BS-TabNet 模型和 LSSA 算法搭建的智能轻量化方法得到的结果相对比,如表 10 所示,两种方法得到的结果相近,并相较于车架初始质量有了较大的减轻,实现了轻量化,证实了智能轻量化设计的可行性.

表 10 智能轻量化结果与 CAE 分析结果对比

Tab.10 Comparison between intelligent lightweighting results and CAE analysis results					
模型	Mass/ kg	Kbend/ (N/mm)	Kftor/ [N·m/(°)]	Krtor/ [N·m/(°)]	Mode_1/ Hz
BS-TabNet-LSSA	994.2	12 211.5	11 664.6	9 724.1	6.530 8
Hyperworks	998.7	12 235.6	11 659.4	9 730.2	6.860 0

如图 16 所示,传统的轻量化设计需要对车架有限元模型进行反复多次修改与仿真分析,从中找到最好的设计方案,Hyperworks 对牵引车车架进行一次有限元仿真需要花费超过 20 min,这意味着传统轻量化设计需要耗费大量时间在有限元仿真过程上;而智能轻量化设计在构建好代理模型后,能在 4 min 内通过优化算法对代理模型进行轻量化寻优,找到寻优空间中的最优解,找到最优解后只需要一次有限元分析进行验证即可.智能轻量化设计有效地缩短了设计时间,具有重要的工程实际意义.




图 16 智能轻量化设计流程
Fig.16 Intelligent lightweight design process

4 结论

当前工程上使用的车架设计方法设计周期较长,难以满足市场产品更新迭代的速度,本文通过创建深度学习 BS-TabNet 模型研究车架表格型数据的学习,并用 LSSA 算法进行轻量化求解,主要结论如下:

- 1) BS-TabNet 模型使用贝叶斯优化算法,在选取的超参数取值范围内寻找到最优参数组合,自适应式参数选取方法使得 TabNet 模型的所有参数都被考虑进参数优化范围,解决了深度学习在表格型数据上表现不佳的现状.BS-TabNet 模型比传统机器学习算法,在 RMSE、MAE 和 R^2 等评价指标上都有着更好的表现,对于车架每个输出响应的预测,BS-TabNet 模型的 RMSE 都在 0.04 以下,MAE 都在 0.03 以下, R^2 都能达到 0.97 以上.
- 2) BS-TabNet 模型引入 SHAP 可解释性理论,解决了深度学习中难以解释的“黑箱”问题,搭建出的车架性能预测模型能够将车架各个设计特征变量对预测结果的影响进行量化和归因,更有助于工程师优化车架结构,提高车架性能.

3) BS-TabNet 模型有更好的稳定性,相较于 KNN 算法,BS-TabNet 模型的稳定性提高了 75%;相较于 XGBoost 算法,稳定性提高了 50%。不会因为工况不同、响应不同和参数不同等原因而对预测结果造成过大影响。

4) LSSA 算法针对车架轻量化任务能求解出更好的结果。相比于 SSA、PSO、GA 和 DE 等算法,LSSA 算法能更有效地跳出局部最优,从而找到更优的车架结构取值,优化后的结果接近 CAE 仿真结果,说明了智能轻量化设计的可行性。同时相较于传统的轻量化设计方法,智能轻量化设计可以节省大量的有限元仿真时间,提高设计效率。

参考文献

- [1] 徐鑫海. DL4100 牵引车车架拓扑优化及有限元分析 [D]. 太原: 太原理工大学, 2013: 1-9.
XU X H. Topology optimization and finite element analysis of DL4100 vehicle [D]. Taiyuan: Taiyuan University of Technology, 2013: 1-9. (in Chinese)
- [2] FORSBERG J, NILSSON L. On polynomial response surfaces and Kriging for use in structural optimization of crashworthiness [J]. Structural and Multidisciplinary Optimization, 2005, 29 (3): 232-243.
- [3] FORSBERG J, NILSSON L. Evaluation of response surface methodologies used in crashworthiness optimization [J]. International Journal of Impact Engineering, 2006, 32 (5): 759-777.
- [4] 王琥, 李光耀, 李恩颖, 等. 基于响应面法的汽车吸能部件优化问题研究 [J]. 系统仿真学报, 2007, 19(16): 3824-3829.
WANG H, LI G Y, LI E Y, et al. Study of optimization for absorbing energy member of automobile based on response surface method. [J]. Journal of System Simulation, 2007, 19(16): 3824-3829. (in Chinese)
- [5] LI H, LIU Z, ZHU P. An improved multi-objective optimization algorithm with mixed variables for automobile engine hood lightweight design [J]. Journal of Mechanical Science and Technology, 2021, 35: 2073-2082.
- [6] ZHU F, LOGAKANNAN K. Crash safety design for lithium-ion vehicle battery module with machine learning [J]. SAE International Journal of Advances and Current Practices in Mobility, 2022, 4(5): 1667-1677.
- [7] MISIC V V. Optimization of tree ensembles [J]. Operations Research, 2020, 68(5): 1605-1624.
- [8] ARIK S Ö, PFISTER T. Tabnet: Attentive interpretable tabular learning [C]//Proceedings of the Proceedings of the AAAI Conference on Artificial Intelligence. California USA: AAAI Press, Palo Alto, 2021, 35(8): 6679-6687.
- [9] YAN J Z, XU T Y, YU Y C, et al. Rainfall forecast model based on the tabnet model [J]. Water, 2021, 13(9): 1272.
- [10] SHAH C, DU Q, XU Y. Enhanced TabNet: Attentive interpretable tabular learning for hyperspectral image classification [J]. Remote Sensing, 2022, 14(3): 716.
- [11] WANG K, DOWLING A W. Bayesian optimization for chemical products and functional materials [J]. Current Opinion in Chemical Engineering, 2022, 36: 100728.
- [12] 顾桐, 许国良, 李万林, 等. 基于集成 LightGBM 和贝叶斯优化策略的房价智能评估模型 [J]. 计算机应用, 2020, 40(9): 2762-2767.
GU T, XU G L, LI W L, et al. Intelligent house price evaluation model based on ensemble LightGBM and Bayesian optimization strategy [J]. Computer Applications, 2020, 40(9): 2762-2767. (in Chinese)
- [13] DU L, GAO R, SUGANTHAN P N, et al. Bayesian optimization based dynamic ensemble for time series forecasting [J]. Information Sciences, 2022, 591: 155-175.
- [14] LUNDERG S M, LEE S I. A unified approach to interpreting model predictions [J]. Advances in Neural Information Processing Systems, 2017, 30: 4765-4774.
- [15] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [16] MAO X J, SONG S J, DING F. Optimal BP neural network algorithm for state of charge estimation of lithium-ion battery using PSO with Levy flight [J]. Journal of Energy Storage, 2022, 49: 104139.
- [17] 葛平莹. 基于有限元法的半挂牵引车驾驶室降噪研究 [D]. 镇江: 江苏大学, 2016: 1-46.
GE P Y. Reducing noise of tractor-trailer cab based on finite element method. [D]. Zhenjiang: Jiangsu University, 2016: 1-46. (in Chinese)
- [18] 高靖博. 基于性能驱动的商用车车架轻量化优化设计 [D]. 长春: 吉林大学, 2021: 1-29.
GAO J B. Lightweight optimization design of commercial vehicle frame based on performance driven [D]. Changchun: Jilin University, 2021: 1-29. (in Chinese)