

碳纤维汽车底盘后纵臂 CAE 设计的 优化算法*

朱迪, 姚远, 彭雄奇

(上海交通大学 材料科学与工程学院, 上海 200030)

(本刊编委彭雄奇来稿)

摘要: 后纵臂是汽车底盘的主要结构之一.采用碳纤维复合材料设计后纵臂可以有效减重.然而复合材料的应用也给其优化设计带来了很大的挑战,如复杂的多工况和大量的设计变量.使用 Python 语言对 ABAQUS 二次开发,对于各角度铺层占比进行全局遍历得出其有效解与最优解.为了解决多工况下运算时间长的问题,将基于树的算法模型,如 XGBoost、DART、随机森林,引入到各铺层角度占比设计的计算中,同时考虑到计算量和计算准确率两者的关系,在新工况计算量在 0 条和 10 条的情况下, Tsai-Wu 因子的准确率分别可以达到 96.3%和 98.3%(与失效值 1 相比).在将已有工况数据量减少一半的情况下,如果提高新工况计算量到 40 条,准确率可以达到 95.0%.为多工况下碳纤维复合材料零件轻量化计算提供了有益的参考.

关键词: 汽车底盘纵臂; 碳纤维复合材料; ABAQUS 二次开发; 基于树的模型; 铺层优化

中图分类号: TB324

文献标志码: A

DOI: 10.21656/1000-0887.390001

引言

新能源汽车因电池自重大,故进行底盘的轻量化设计就显得十分重要和迫切,以期大幅度降低底盘自重、延长电池的续航里程^[1].碳纤维增强复合材料以其高的比强度、比刚度、耐疲劳以及耐腐蚀等优异的力学和物理性能,成为汽车底盘零部件轻量化发展方向之一^[2].在复合材料零件优化设计中,采用模拟仿真而非试验的方法找出最优解,可以减少试验消耗和预算开支.国内外通常将算法分为确定型优化算法和概率型优化算法,确定型优化算法的理论基础完善,但无法解决复杂性高、数据量大的问题且易陷入局部寻优,实际使用较少.概率型优化算法将随机搜索引入优化算法中,有效改善了确定型优化算法的不足^[3-4].在复合材料层合板设计中常见的概率型算法有遗传算法和群智能算法.在遗传算法方面, Dileep 等基于圆孔的有效测试数据,将神经遗传算法用于石墨/环氧树脂层压板切口强度的预测,具有一个隐层的 NME 神经网络的层压板的强度预测与实测数据吻合得非常好^[5].刘振国等提出了一种铺层分级遗传优化的方法,对受力分布极度不均匀的层合板进行优化^[6].在群智能算法方面, Rao 等提出了应用混合蛙跳算法(SFLA),求解组合优化问题与层压复合材料结构的铺层顺序优化相结

* 收稿日期: 2018-01-02; 修订日期: 2018-01-14

作者简介: 朱迪(1993—),女,硕士生(E-mail: iriszhudi@163.com);

彭雄奇(1970—),男,教授,博士生导师(通讯作者. E-mail: xqpeng@sjtu.edu.cn).

合^[7],对复合材料板的屈曲和破坏载荷优化问题进行了数值试验,然后对加筋复合材料圆柱壳进行了优化设计.Salamat 等研究了 4 种简支横向荷载作用下反对称角铺设层合板和正交铺设层的优化问题,使用了蜜蜂算法以优化提高层合板的强度^[8].但这两种算法的特点决定了对数据量大小要求高,所以本文从碳纤维复合材料的使用入手,对多工况下各角度铺层厚度占比的有效值和最优值进行了计算.引入基于树的深度学习算法,提出了一种优化方案解决传统有限元耗时长的的问题,大幅度降低了计算所需时间,为复合材料零部件设计提供了有益的参考.

1 试验方法

1.1 全局有效解与最优解的计算

基于 Yao 等的研究^[9],利用 SOLIDWORKS 软件进行复材后纵臂的三维造型.接着将其导入 HYPERMESH 中进行几何清理、网格划分,根据纵臂各部分几何特征分别采用 CAE 商业软件 ABAQUS 中的 S3 和 S4R 壳单元,以及 C3D8R、C3D6 和 C3D4 实体单元,纵臂 CAE 模型见图 1.

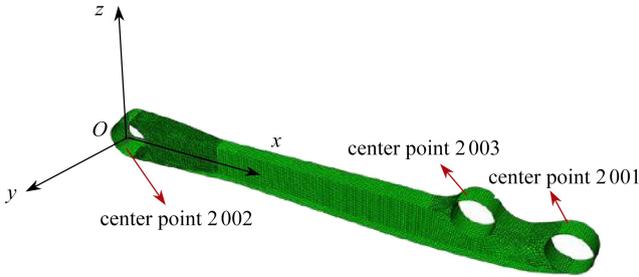


图 1 碳纤维复合材料(CFRP)后纵臂三维有限元模型

Fig. 1 The 3D finite element model of the CFRP rear longitudinal arm

套管和纵臂臂身通过理想的共节点连接,套管中心点与套管表面上的各节点建立耦合约束,材料参数基于龚友坤等对 T700 碳纤维单向带的力学性能测试^[10],载荷和边界条件施加在套管的中心点上,后纵臂各载荷点的载荷信息见表 1.

表 1 后纵臂各载荷点的载荷信息

Table 1 Load information of each load point in the rear longitudinal arm

working condition	position	F_x / N	F_y / N	F_z / N	$T_x / (\text{N} \cdot \text{mm})$	$T_y / (\text{N} \cdot \text{mm})$	$T_z / (\text{N} \cdot \text{mm})$
GK1	center point 2 001	157.6	0.360 7	-262.5	-53.62	299.9	-4.888
	center point 2 002	-465.3	-10.94	-50.69	-21.11	8 191	-2.180
	center point 2 003	307.7	10.58	313.2	-53.62	299.9	-4.888
GK2	center point 2 001	-4 254	-94.13	-6 216	-66.96	7 475	-55.57
	center point 2 002	4 644	100.2	-2 021	-261.8	8 065	-377.1
	center point 2 003	-390.0	-6.109	8 237	-66.96	7 475	-55.57
GK3	center point 2 001	-1 632	-481.1	-6 172	-4 082	7 422	-441.0
	center point 2 002	-561.2	-129.2	-1 644	1.592E+4	2.273E+4	-3 034
	center point 2 003	2 193	610.3	7 816	-4 082	7 422	-441.0
GK4	center point 2 001	486.3	167.7	-707.6	-1 055	781.4	1 064
	center point 2 002	-1 291	26.33	-133.6	-1 079	2.308E+4	5 810
	center point 2 003	804.3	-194.0	841.2	-1 055	781.4	1 064

续表 1

working condition	position	F_x / N	F_y / N	F_z / N	$T_x / (N \cdot mm)$	$T_y / (N \cdot mm)$	$T_z / (N \cdot mm)$
GK5	center point 2 001	-2 463	35.07	-5 456	-334.6	6 996	567.0
	center point 2 002	1 633	68.29	-1 554	-793.3	-9 759	4 210
	center point 2 003	829.9	-103.4	7 010	-334.6	6 996	567.0
GK10	center point 2 001	1 341	156.2	4 629	5 270	-6 163	441.7
	center point 2 002	-1 065	11.22	1 290	-1.264E+4	-4 475	812.5
	center point 2 003	-275.1	-167.4	-5 920	5 270	-6 163	441.7
GK6-7	center point 2 001	1 417	111.0	-375.9	-493.5	327.5	511.7
	center point 2 002	-2 943	-41.39	110.0	-680.8	8 278	600.7
	center point 2 003	1 526	-69.62	265.9	-493.5	327.5	511.7
GK8-9	center point 2 001	-1 054	-110.7	-142.5	394.0	264.6	-529.5
	center point 2 002	2 010	18.96	-207.1	647.4	8 128	-657.5
	center point 2 003	-956.3	91.71	349.7	394.0	264.6	-529.5
GK17	center point 2 001	4 322	-91.97	-9 506	-5 057	8 815	2 272
	center point 2 002	-1.541E+4	-359.8	-1 420	1.354E+4	2.383E+4	6 500
	center point 2 003	1.108E+4	451.8	1.093E+4	-5 057	8 815	2 272
GK18	center point 2 001	-193.0	-349.5	2 620	7 157	-3 557	-2 548
	center point 2 002	1 399	-85.74	579.6	-8 229	-1 613	-1.060E+4
	center point 2 003	-1 206	435.2	-3 200	7 157	-3 557	-2 548
GK19	center point 2 001	-6 781	-491.4	-1 148	-3 084	1 970	-875.1
	center point 2 002	1.244E+4	192.1	-1 312	1.234E+4	2.589E+4	4 003
	center point 2 003	-5 655	299.3	2 461	-3 084	1 970	-875.1
GK20	center point 2 001	2 083	444.3	6 634	2 152	-7 645	1 995
	center point 2 002	-2 058	63.22	1 851	-1.175E+4	7 350	1 215
	center point 2 003	-24.74	-507.5	-8 485	2 152	-7 645	1 995
GK21	center point 2 001	-339.6	-1 265	4 781	1.196E+4	-6 117	-6 591
	center point 2 002	2 539	-359.5	1 065	-1 773	-6 421	-3.978E+4
	center point 2 003	-2 199	1 624	-5 846	1.196E+4	-6 117	-6 591
GK22	center point 2 001	82.30	341.6	-5 038	-8 100	6 251	5 321
	center point 2 002	-3 340	86.42	-1 128	1.084E+4	1.981E+4	2.703E+4
	center point 2 003	3 257	-428.1	6 167	-8 100	6 251	5 321

铺层角度只选取 $0^\circ, 45^\circ, -45^\circ, 90^\circ$ 这 4 个值, 铺层厚度是 0.175 mm (单层碳纤维单向带预浸料厚度) 的倍数, 均为离散性变量. 各铺层角度占比如图 2 所示.

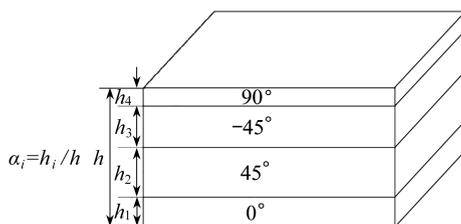


图 2 各铺层角度占比示意图

Fig. 2 Schematic diagram of the proportion of different ply angles

碳纤维复合材料后纵臂 CAE 分析的要求是,在各个强度工况下强度达到标准并且变形小于 2 mm.强度分析采用 Tsai-Wu 失效准则^[9],当 Tsai-Wu 因子大于 1 时,碳纤维复合材料发生失效.

初步设定铺层数为 21,对不同工况下的 0°铺层厚度占比 (α_1)、45°铺层厚度占比 (α_2)、-45°铺层厚度占比 (α_3)、90°铺层厚度占比 (α_4) 进行遍历求解,读取 Tsai-Wu 因子和位移值.具体流程如下:

1) 批量生成 input 文件.这里面包含两个子步,先生成一个 input 文件模板,后用 Python 将 input 模板修改成可以批量化输出 input 的文件.主要的工作是将模板文字查询关键字位置后插入需要修改的参数值,调用 Python 的循环语句,循环生成 input 文件.对于 21 层铺层下的所有 α_i 的组合值与 14 种工况叠加生成 28 336(2 024×14) 个 input 文件.

2) 批量提交 input 文件进行计算.采用 Windows 批量处理文件,直接在 DOS 窗口提交.Windows 批量处理文件有如下优势:① 可以批量提交,实现全日夜工作,节省时间;② 删掉不需要的结果文件,选择只存储 ODB 文件,节省磁盘空间.每个工况(2 024 个 job)平均计算时间为 12.34 h,生成 29.6 GB 的海量数据.

3) 批量读取 ODB 文件目标数据.后处理 ODB 文件分为两步:第一步是根据 ODB 文件的数据结构,使用 Python 批量调取 ODB 文件.由于 ODB 文件的数据结构复杂,且每个分支的读取格式不完全相同,所以需要先确定读取的目标数据.第二步循环读取 Tsai-Wu 因子、最大位移值,并写出到文本文件中.每个工况(2 024 个 ODB 文件)平均计算时间为 11.35 h,生成约 88 kB(约为总数据量的 0.29%)的数据.

1.2 针对新工况的算法优化

作为一类回归模型,基于树 (tree based) 的算法^[11-12]增加了模型准确性和可靠性以及减小了解释的难度.和线性模型不同,它们对非线性关系也能进行很好的映射.常见的基于树的模型^[12]有:决策树 (decision tree)、随机森林 (random forest) 和提升树 (boosted tree).决策树^[12]是最基础的算法,为了克服决策树的各种缺点,发展出了很多其他算法^[13-14],比如袋装 (bagging)^[15]、随机森林^[12]、XGBoost^[16]、DART(dropouts meet multiple additive regression tree)^[17-18].每种方法都包括生成多种树,如图 3 所示.这些树被联合起来,生成一个单一的一致性预测结果,并且经常带来预测精度的提升.

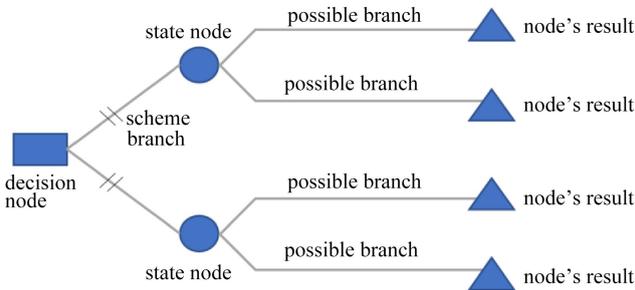


图 3 决策树概念图

Fig. 3 Decision tree

对于新工况的计算,本文提出了采用基于树的算法解决计算量大、耗时长的问题.对新工况 GK0 进行了遍历性计算,GK0 的载荷信息如表 2 所示,生成了 2 024 行数据.

从 GK0 取出 i 行和之前已有工况的 28 336 行数据共同组成训练集 ($(i + 28 336)$ 行),而相应剩余的数据 ($(2 024 - i)$ 行)作为测试集验证算法模型的准确性,新工况所需计算量与测

试集占比的关系如表 3, 如若算法模型可靠, 那么只计算 i 行数据, 就可得到合理有效的解. 可以将 i 看作新工况的所需计算量.

表 2 新工况 GK0 的载荷信息

Table 2 Load information of new working condition GK0

position	F_x / N	F_y / N	F_z / N	$T_x / (\text{N} \cdot \text{mm})$	$T_y / (\text{N} \cdot \text{mm})$	$T_z / (\text{N} \cdot \text{mm})$
center point 2 001	1 260	139.3	4 278	5 036	-5 855	304
center point 2 002	-993.7	7.441	1 195	-11 930	-4 390	272.1
center point 2 003	-266.8	-146.8	-5 474	5 036	-5 855	304

表 3 新工况所需计算量与测试集占比的关系表

Table 3 A relationship table for the ratio of the amount of calculation to the test set in the new working condition

number of cases under GK0	0	5	10	15	20	30	40
occupation ratio of test set δ	$\frac{2\ 024}{30\ 360}$	$\frac{2\ 019}{30\ 360}$	$\frac{2\ 014}{30\ 360}$	$\frac{2\ 009}{30\ 360}$	$\frac{2\ 004}{30\ 360}$	$\frac{1\ 994}{30\ 360}$	$\frac{1\ 984}{30\ 360}$

Tsai-Wu 因子是连续值且具有一定规律性的数据, 在数学建模中, 通常建立回归模型对其进行预测. 而本文数据量只有 3 万左右, 建立基于树的模型对于这样的数据量来说是有效且合理的.

基于铺层和工况情况, 本节提取了各角度铺层占比 $\alpha_i (i = 1, 2, 3, 4)$ 、力 $f_{jk} (j = 1, 2, 3$ 分别对应套管 2 001, 2 002, 2 003; $k = 1, 2, 3$ 分别对应 x, y, z 三个坐标轴方向)、力矩 T_{jk} (参数设定同 f_{jk}). 另外计算了不同套管的力的标量值 $f_j (j = 1, 2, 3$ 分别对应套管 2 001, 2 002, 2 003) 和不同套管的力矩的标量值 T_j (参数设定同 f_j). 分析数据可以看出, 套筒 2 003 的扭矩情况与 2 001 相同, 所以剔除了套筒 2 003 的扭矩相关特征, 即 T_3 和 $T_{3k} (k = 1, 2, 3)$.

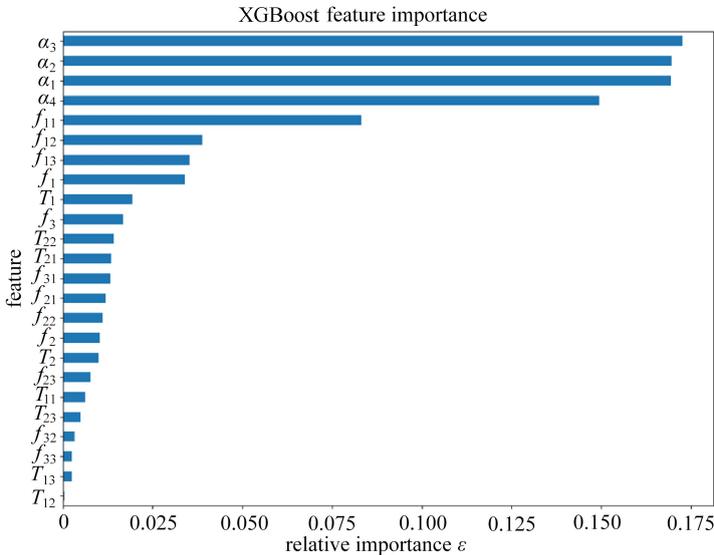


图 4 XGBoost 输出的 Tsai-Wu 特征重要性排序

Fig. 4 The sorting of characteristic importance of Tsai-Wu from the XGBoost output

现共有 24 维特征值, 这些特征中可能存在冗余, 易引起过拟合^[19]. 采用了嵌入式的方法进行特征选择. 因为模型部分采用了树模型 XGBoost 和随机森林, 这两种模型在训练后可以直接得到特征的重要性, 可以方便地进行排序, 剔除重要性低的特征. 采用 1.1 小节中计算出的数据进行了第一次 XGBoost 计算, 得到了特征重要性排序, 如下图 4 所示. 可以看出, α_i 是最重要的因素, 且影响远远大于其他特征. 分别对于 Tsai-Wu 因子剔除重要性排名最后 5 位的因素

进行后续计算。

模型方面,采用了数据挖掘领域广泛使用的 XGBoost、不久之前发表的 DART、以及经典的随机森林。

据以上研究发现均方根误差(RMSE)值很小,说明模型十分可靠,于是随机剔除一半工况的数据(GK4、GK8-9、GK10、GK17、GK19、GK20、GK21)进一步降低运算量,使用剩余数据和新工况的数据训练模型得出结论。

2 结果与讨论

2.1 全局有效解与最优解的结果与讨论

由于后续还需进行铺层顺序的优化,所以本文适当放宽了最大位移值的要求.有效解设定为 Tsai-Wu 因子小于 1,最大位移值小于 5 mm 所对应的各角度铺层占比 $\alpha_i (i = 1, 2, 3, 4)$ 。而最优解采用简化处理,即为满足有效解要求的情况下,使得 Tsai-Wu 因子与最大位移值加和最小的 $\alpha_i (i = 1, 2, 3, 4)$,以工况横坐标,各角度铺层层数为纵坐标,作出不同角度下的最大层数、最小层数、最优层数的散点图,如图 5 所示。

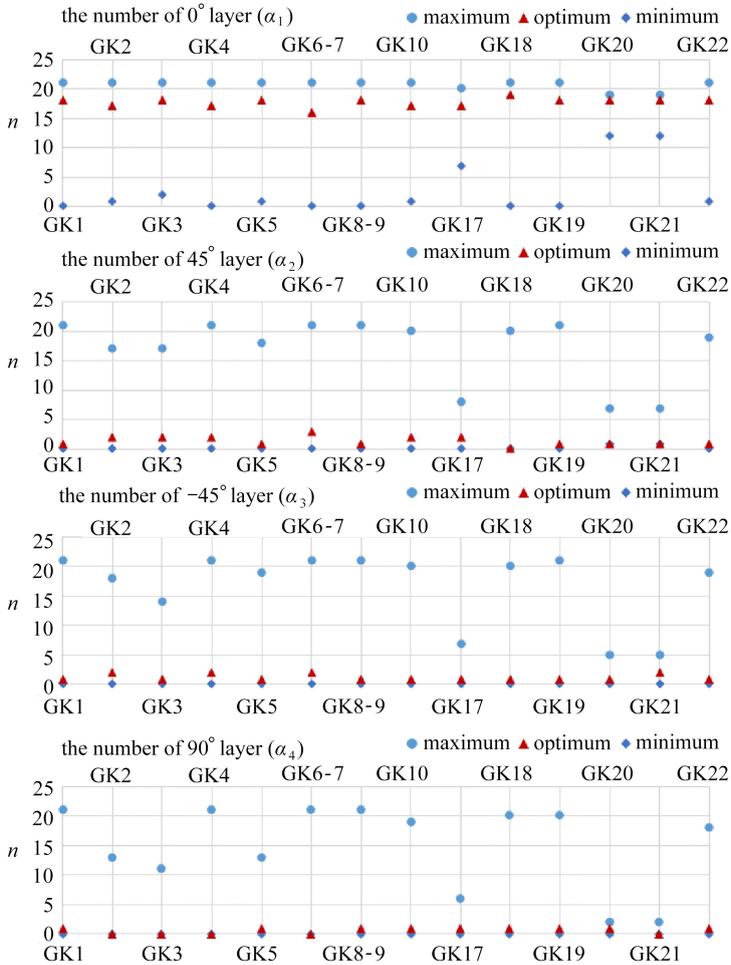


图 5 各角度铺层的有效解与最优解

Fig. 5 The effective solution and optimal solution of the plies of each angle

从图 5 中可以看出,不同工况下有效解范围不尽相同,但是最优解的波动明显小很多,所以零件形状一旦确定,其受力会出现一定的相似性。

2.2 针对新工况的算法优化结果与讨论

参数设定方面,本文采用的是回归模型,所以统一以 RMSE 作为检验数据的评价指标。另外,这三种树模型有一个共同并且重要的参数 min-child-weight。对于回归问题来说,这个参数对应的就是每个叶子节点上最小的样本个数。这个参数值设置得越小,越容易过拟合。在本文中,min-child-weight 设置为 5,相比设置为 1,RMSE 会有不小的提升。对于不同的新工况所需计算量,分别训练了 XGBoost、DART 和随机森林模型,得出的 Tsai-Wu 因子的预测值与测试集中 Tsai-Wu 因子的真实值进行计算得到 RMSE 值,如表 4 中前 3 行所示。

模型融合方面,XGBoost、DART、随机森林这三种模型都是基于树的模型。XGBoost 和 DART 是 boosting 算法,侧重于降低模型偏差。随机森林是 bagging 算法,侧重于降低模型方差^[20]。将这几种模型进行融合,可以进一步地提高模型的性能。常用的且效果比较好的融合方法是 stacking 或 blending,但是由于数据量相对较小,做多层 (multi level) 的 stacking/blending learning 容易过拟合^[21],所以最终只采用了简单的加权平均方法。而在本文模型中,3 种模型融合效果并不理想,所以剔除随机森林的模型,做了不同比例的 XGBoost 和 DART 的融合,如表 4 后 7 行所示。计算量的不同,所对应的最优模型配比也不尽相同,但是 0 行数据量和 10 行数据量的最优模型同为 0.2XGBoost+0.8DART,RMSE 可以分别达到 0.037 15 和 0.017 18,均比单独 XGBoost 和 DART 模型的 RMSE 值小。

表 4 不同模型的 RMSE 值 I_{RMSE}
Table 4 Different models and RMSE value I_{RMSE}

number of cases under GK0	0	5	10	15	20	30	40 cases
XGBoost	0.037 61	0.031 73	0.019 15	0.021 29	0.020 61	0.022 70	0.017 90
DART	0.037 20	0.034 88	0.017 30	0.018 35	0.018 41	0.018 98	0.018 59
random forest	0.062 08	0.077 55	0.062 64	0.054 63	0.056 71	0.065 91	0.070 13
0.45XGBoost+0.45DART+0.1RF	0.037 81	0.034 23	0.019 24	0.020 11	0.020 57	0.022 72	0.020 10
0.5XGBoost+0.5DART	0.037 20	0.033 03	0.017 48	0.018 32	0.018 60	0.019 82	0.017 54
0.6XGBoost+0.4DART	0.037 25	0.032 73	0.017 70	0.018 70	0.018 87	0.020 25	0.017 50
0.4XGBoost+0.6DART	0.037 17	0.033 36	0.017 32	0.018 06	0.018 41	0.019 47	0.017 64
0.3XGBoost+0.7DART	0.037 15	0.033 71	0.017 22	0.017 94	0.018 29	0.019 21	0.017 80
0.2XGBoost+0.8DART	0.037 15	0.034 08	0.017 18	0.017 94	0.018 25	0.019 04	0.018 01
0.1XGBoost+0.9DART	0.037 17	0.034 47	0.017 21	0.018 08	0.018 29	0.018 96	0.018 27

另作出 XGBoost、DART 模型的 RMSE 与数据量之间的关系图,如图 6 所示。从表 4 和图 6 中可以得出以下结论: 1) 对于出现的新工况不进行计算,直接通过已有数据获得的模型,RMSE 就可达到 0.037 左右,对于 Tsai-Wu 准则判断临界值 1 来说是可以接受的,对于低精度要求的计算完全可用; 2) 对于 XGBoost 和 DART 模型以及融合模型,新工况计算 10 行数据是一个使得模型 RMSE 大幅度提升的途径。从 5 行计算量到 10 行数据量,XGBoost 和 DART 模型的 RMSE 值均有大幅度下降。

减半工况后同样计算得到 RMSE 值,如表 5 所示。可以看出,减半工况后训练出的模型的 RMSE 是远远高于使用所有工况的情况,但是只需要将新工况计算量提高到 40 行数据,RMSE 就可达到 0.050 41,在精度要求不高的情况下,仍不失为一种快速有效的方法。

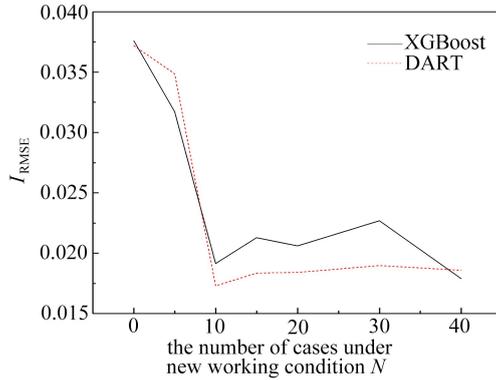


图 6 XGBoost、DART 模型的 RMSE 与数据量之间的关系

Fig. 6 The relationship between the RMSE of XGBoost and DART models and the amount of data

表 5 减半工况数据量后不同模型的 RMSE 值

Table 5 RMSE of different models with half of working conditions

number of cases under GK0	0	5	10	15	20	30	40
XGBoost	0.350 00	0.310 66	0.073 04	0.067 97	0.138 99	0.063 57	0.058 08
DART	0.264 45	0.185 99	0.064 31	0.062 34	0.122 42	0.060 15	0.050 41
random forest	0.227 98	0.425 86	0.121 15	0.154 36	0.186 96	0.157 21	0.148 12
0.1XGBoost+0.9DART	0.272 67	0.197 78	0.064 18	0.062 64	0.123 91	0.060 22	0.051 00
0.2XGBoost+0.8DART	0.280 99	0.209 79	0.064 29	0.063 00	0.125 44	0.060 34	0.051 63
0.3XGBoost+0.7DART	0.289 39	0.221 99	0.064 63	0.063 42	0.127 01	0.060 53	0.052 31
0.5XGBoost+0.5DART	0.306 40	0.246 82	0.066 00	0.064 44	0.130 26	0.061 10	0.053 78
0.6DART+0.4rf	0.130 41	0.274 95	0.080 22	0.089 95	0.138 81	0.085 55	0.072 59
0.5DART+0.5rf	0.115 35	0.299 23	0.086 08	0.099 64	0.145 29	0.096 08	0.083 66
0.4DART+0.6rf	0.115 82	0.323 96	0.092 43	0.109 90	0.152 51	0.107 42	0.095 65
0.1XGBoost+0.8DART+0.1rf	0.233 60	0.218 21	0.066 80	0.067 18	0.126 27	0.062 92	0.051 50

训练一个 XGBoost 模型时间平均为 21 min, 训练一个 DART 模型的时间平均为 12 min, 对于新工况的计算时间为 5 min, 即使加上训练时间总和也仅为 38 min, 最大位移值的模型训练时间与计算时间与 Tsai-Wu 因子基本相同, 两个值的总获取时长为 76 min, 远远短于采用路径 input 文件-提交 job-爬取数据的时长 23.70 h.

3 结 论

1) 将基于树的算法引入铺层计算中, 采用了 XGBoost、DART 和随机森林以及其融合模型, 分别在新工况计算量在 0 行和 10 行的情况下, Tsai-Wu 因子的准确率可以达到 96.3% 和 98.3% (与失效值 1 相比). 在将已有工况数据量减少一半的情况下, 如果提高新工况计算量到 40 行, 准确率可以达到 95.0% (与失效值 1 相比).

2) 作为一种通用的思路, 对于复杂零部件铺层的计算, 使用 ABAQUS 计算小部分数据, 后采用回归的算法模型进行计算, 可快速得到准确率较高的力学参数.

参考文献 (References):

- [1] 杨小平, 隋刚. 碳纤维复合材料在新能源产业中的应用进展[J]. 新材料产业, 2012(2): 20-24.
(YANG Xiaoping, SUI Gang. Application of carbon fiber composite materials in new energy

- industry[J]. *Advanced Materials Industry*, 2012(2): 20-24.(in Chinese))
- [2] 冯美斌. 汽车轻量化技术中新材料的发展及应用[J]. 汽车工程, 2006, **28**(3): 213-220.(FENG Meibin. Development and application of new materials in automotive lightweighting technologies[J]. *Automotive Engineering*, 2006, **28**(3): 213-220.(in Chinese))
- [3] PARPINELLI R S, LOPES H S, FREITAS A A. Data mining with an ant colony optimization algorithm[J]. *IEEE Transactions on Evolutionary Computation*, 2002, **6**(4): 321-332.
- [4] 肖书敏, 闫云聚, 姜波澜. 基于小波神经网络方法的桥梁结构损伤识别研究[J]. 应用数学和力学, 2016, **37**(2): 149-159.(XIAO Shumin, YAN Yunju, JIANG Bolan. Damage identification for bridge structures based on the wavelet neural network method[J]. *Applied Mathematics and Mechanics*, 2016, **37**(2): 149-159.(in Chinese))
- [5] DILEEP P N, KUMAR RR, RAO G V. A neural-genetic algorithm approach for evaluation of notched strength of laminate[J]. *Journal of the Institution of Engineers(India)*, 2002.
- [6] 刘振国, 胡杰, 胡龙. 基于遗传算法的层合板分级铺层全局优化[J]. 北京航空航天大学学报, 2013, **39**(4): 478-483.(LIU Zhenguo, HU Jie, HU Long. Global optimization of classified composite laminated structures based on genetic algorithms[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2013, **39**(4): 478-483.(in Chinese))
- [7] RAO A R M, LAKSHMI K. Optimal design of stiffened laminate composite cylinder using a hybrid SFL algorithm[J]. *Journal of Composite Materials*, 2012, **46**(24): 3031-3055.
- [8] SALAMAT A R, RAIESINEZHAD M. Optimum design of antisymmetric cross-ply and angle-ply laminate with bees algorithm[Z]. 2012.
- [9] YAO Y, WANG T, GONG Y, et al. Development of a carbon fiber reinforced composite chassis longitudinal arm[J]. *Science of Advanced Materials*, 2016, **8**(11): 2133-2141.
- [10] 龚友坤, 王韬, 姚远, 等. 汽车底盘碳纤维后纵臂成形实验与分析[J]. 汽车工程, 2016, **38**(2): 248-251.(GONG Youkun, WANG Tao, YAO Yuan, et al. Forming experiment and analysis of vehicle rear longitudinal arm of carbon fiber reinforced composite[J]. *Automotive Engineering*, 2016, **38**(2): 248-251.(in Chinese))
- [11] ROKACH L, MAIMON O. *Data Mining With Decision Trees: Theory and Applications*[M]. Singapore: World Scientific Publishing Company, 2008.
- [12] KIM Y, PERRIG A, TSUDIK G. Tree-based group key agreement[J]. *Acm Transactions on Information & System Security*, 2004, **7**(1): 60-96.
- [13] LIANG X, QU F, YANG Y, et al. An improved ID3 decision tree algorithm based on attribute weighted[C]//*International Conference on Civil, Materials and Environmental Sciences*. Paris, France, 2015.
- [14] LU G, KRISHNAMACHARI B, RAGHAVENDRA C S. An adaptive energy-efficient and low-latency MAC for tree-based data gathering in sensor networks: research articles[J]. *Wireless Communications & Mobile Computing*, 2007, **7**(7): 863-875.
- [15] QUINLAN J R. Induction on decision tree[J]. *Machine Learning*, 1986, **1**(1): 81-106.
- [16] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//*ACM Sigkdd International Conference on Knowledge Discovery and Data Mining*. San Francisco, California, USA, 2016: 785-794.
- [17] VINAYAK R K, GILAD-BACHRACH R. DART: Dropouts meet multiple additive regression trees[C]//*Proceedings of the Eighteenth International Conference on Artificial Intelligence and Statistics*. Vol **38**. San Diego, California, USA, 2015: 489-497.
- [18] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural

- networks from overfitting [J]. *Journal of Machine Learning Research*, 2014, **15**(1): 1929-1958.
- [19] GUYON I, ELISSEEFF A. An introduction to variable and feature selection [J]. *Journal of Machine Learning Research*, 2003, **3**(6): 1157-1182.
- [20] ERNST D, GEURTS P, WEHENKEL L. Tree-based batch mode reinforcement learning [J]. *Journal of Machine Learning Research*, 2005, **6**(2): 503-556.
- [21] 史忠植. 知识发现 [M]. 北京: 清华大学出版社, 2011. (SHI Zhongzhi. *Knowledge Discovery* [M]. Beijing: Tsinghua University Press, 2011. (in Chinese))

An Optimization Algorithm for CAE Design of Carbon Fiber Reinforced Composite Chassis Longitudinal Arms

ZHU Di, YAO Yuan, PENG Xiongqi
(School of Materials Science and Engineering,
Shanghai Jiao Tong University, Shanghai 200030, P.R.China)
(Contributed by PENG Xiongqi, M. AMM Editorial Board)

Abstract: The rear longitudinal arm is one of the main structures of the automobile chassis. Design of the rear longitudinal arm with carbon fiber reinforced polymer (CFRP) can reduce its weight effectively. However, the application of composite materials also brings great challenges to the optimization design process, such as complex multiple conditions and a large number of design variables. The secondary development of ABAQUS was conducted with Python to fulfill the global ergodic search for thickness ratios of different ply angles to find the effective range and the optimum solution. In order to reduce the long running time under multi working conditions, the tree-based algorithms, such as XGBoost, DART and random forest, were introduced into the thickness ratio calculation. In view of both the running time and the computation accuracy, for 0 or 10 cases of calculation under the new condition, the accuracy rate of the Tsai-Wu factor can reach 96.3% and 98.3% (compared with failure value 1). If the number of cases under new working conditions increases to 40 while existing working conditions decreases by half, the accuracy rate can reach 95.0%. The developed algorithm provides a useful reference for reducing the running time of optimization design of composite parts under multi working conditions.

Key words: automobile chassis longitudinal arm; carbon fiber reinforced composite; secondary development of ABAQUS; tree based model; ply optimization

引用本文/Cite this paper:

朱迪, 姚远, 彭雄奇. 碳纤维汽车底盘后纵臂 CAE 设计的优化算法 [J]. *应用数学和力学*, 2018, **39**(8): 925-934.

ZHU Di, YAO Yuan, PENG Xiongqi. An optimization algorithm for CAE design of carbon fiber reinforced composite chassis longitudinal arms [J]. *Applied Mathematics and Mechanics*, 2018, **39**(8): 925-934.