



基于 Kriging 代理模型的高速列车头型多目标优化设计

姚拴宝^①, 郭迪龙^①, 孙振旭^{①*}, 杨国伟^①, 陈大伟^②

① 中国科学院力学研究所, 工程系统应用力学重点实验室, 北京 100190;

② 南车青岛四方机车股份有限公司, 青岛 266111

* E-mail: sunzhenxu@imech.ac.cn

收稿日期: 2012-06-13; 接受日期: 2012-08-24

国家科技支撑计划(批准号: 2009BAG12A03)和国家重点基础研究发展计划(“973”计划)(批准号: 2011CB71100)资助项目

摘要 随着列车运行速度的提高, 气动阻力成为制约列车提速和节能环保的重要因素之一, 尾车的气动升力是影响列车乘坐舒适性和运行安全性的关键气动载荷. 本文针对 CRH380A 三辆编组简化外形, 以整车气动阻力和尾车气动升力为优化目标, 结合局部型函数三维参数化方法和基于迭代局部搜索算法的带有极大极小准则的中心拉丁超立方采样方法, 提出了一套基于自适应非劣分类遗传算法的高速列车头型有约束多目标气动优化设计方法. 研究表明: 局部型函数参数化方法可以较好的应用于复杂三维气动外形的优化设计; 自适应非劣分类遗传算法能够较为准确、高效的找到 Pareto 最优解集; 优化后, 三辆编组简化外形的整车气动阻力减小 3.2%, 尾车升力系数减小 8.24%, 流线型部分的体积减小 2.16%, 真实外形的整车气动阻力减小 2.26%, 尾车气动升力减小 19.67%, 两种外形的气动力变化主要集中在鼻锥和尾锥的变形区域; 本文提出的优化设计方法简单、高效, 可以为高速列车气动外形多目标、带约束工程优化设计提供参考.

关键词

多目标优化
Kriging 模型
遗传算法
气动外形
高速列车

高速列车技术的发展是一个国家高新技术发展水平的重要标志. 近些年, 中国高速列车技术取得了重大进展, 京沪高铁运行速度达到了 300 km/h. 高速列车贴近地面或轨道运行, 长径比远大于其他交通工具, 在高速运行的情况下, 其空气动力特性变得更为复杂^[1-3]. 列车的阻力特性直接关系到其提速和节能环保的能力, 头部长度稍大于 5 m 的高速列车时速在 300 km 时, 空气阻力达到总阻力的 85%; 头部长度在 10 m 左右, 且流线型程度非常高的动车组, 时速 300 km 时空气阻力占总阻力的 75%^[4]. 在无横风

条件下, 尾车的气动升力是影响列车乘坐舒适性和运行安全性的关键气动载荷, 大的气动抬升力会显著减小轮轨接触力, 对尾车的运行平稳性和乘坐舒适性有不利影响, 过大的抬升力容易导致列车脱轨, 对运行安全性十分不利. 因此, 减小列车的气动阻力和尾车的气动升力成为高速列车头型优化设计的关键问题. 高速列车头型是复杂的流线型外形, 设计参数达到了几十个. 目前, 列车气动外形的设计方法主要是通过传统的风洞试验、动模型试验和实车试验获取个别关键参数与列车气动性能的规律, 进而进行

英文版发表信息: Yao S B, Guo D L, Sun Z X, et al. Multi-objective optimization of the streamlined head of high-speed trains based on the Kriging model. Sci China Tech Sci, 2012, 55: 3495-3509, doi: 10.1007/s11431-012-5038-8

相应的改进设计, 投资大, 设计周期长. 随着计算机技术的发展和计算流体力学(CFD)应用的逐步工程化, CFD 技术成功应用到了高速列车的设计研发过程中. 但设计一款具有良好气动性能的高速列车头型仍需计算大量的运行工况, 耗费大量的计算资源, 而且得到的规律往往仅是单个设计参数与优化目标之间的规律.

目前, 关于使用 CFD 技术和优化算法相结合的高速列车气动外形多目标优化设计方法的文献比较少, 已有的研究成果^[5-10]大都针对列车的二维型线或使用效率较低的优化算法开展的无约束单目标优化设计, 很难应用到具有大规模 CFD 流场计算量、多个设计参数、带约束的工程实际问题中. Ku 等人^[5]将两种单目标优化过程相结合, 先以列车通过隧道时产生的微气压波为优化目标, 获取了头车流线型部分的最优截面变化率, 然后保证截面变化率不变, 基于 Kriging 模型和 VMF(Vehicle Modeling Function)三维参数化方法完成了减小了头车气动阻力的单目标优化设计. Sun 等人^[6]结合遗传算法和任意网格变形技术, 针对 CRH3 头车流线型部分的气动阻力, 提取 4 个设计参数, 进行了无约束单目标优化设计, 在优化过程中, 进行了 6 代遗传, 计算了 96 次流场, 并使用 Kriging 模型得到了关键设计变量与优化目标的非线性关系. Ku 等人^[7]以减小微气压波为优化目标, 使用 BFGS(Broyden-Fletcher-Goldfarb)算法和响应面模型对不同鼻锥长度的头车流线型部分的截面变化率进行了无约束单目标优化设计. Lee 等人^[8]基于支持向量机响应面模型与连续二次规划方法, 提取 9 个设计变量, 试验设计出 100 样本点, 针对列车纵剖面型线, 以减小微气压波为优化目标, 进行了列车气动外形的单目标优化设计. 本文在上述文献工作的基础上, 针对 CRH380A 高速列车流线型外形, 使用基于自由曲面变形的局部型函数参数化方法; 以减少三辆编组列车气动阻力、尾车气动升力和 CFD 计算量为目标, 提取 5 个关键设计变量; 使用基于迭代局部搜索算法的带有极大极小准则的中心拉丁超立方采样方法, 初始试验设计出 20 个样本点; 采用基于最小化响应面加点准则的序列优化设计方法, 使用自适应遗传算法对 Kriging 代理模型的相关参数进行单目标寻优, 经过 4 次序列迭代, 构造出了满足工程精度要求的 Kriging 代理模型; 结合自适应非劣分类遗传算法, 提出了一套高效的高速列车头型多目标有

约束的气动优化设计方法, 使用该套方法得到了以整车气动阻力和尾车气动升力为优化目标的 Pareto 最优解集, 并选取其中一个优化外形改造成真实外形与 CRH380A 三辆编组真实外形的气动性能进行了对比分析.

1 Kriging 代理模型

Kriging 代理模型是一种基于统计理论, 充分考虑变量空间相关特征的插值技术^[11-14], 包含回归部分和非参数部分:

$$y(\mathbf{x}^{(i)}) = F^T(\mathbf{x}^{(i)})\boldsymbol{\beta} + z(\mathbf{x}^{(i)}), (i = 1, \dots, n), \quad (1)$$

其中 n 为样本点个数, $\boldsymbol{\beta}$ 是回归系数, $\mathbf{x}^{(i)}$ 为样本点, $F^T(\mathbf{x}^{(i)})$ 为确定性函数, 提供对设计空间的全局近似, 一般用 $\mathbf{x}^{(i)}$ 的多项式表示, 由于随机部分已经有足够的捕捉对象响应的变化趋势^[15, 16], 所以本文将回归部分 $F^T(\mathbf{x}^{(i)})\boldsymbol{\beta}$ 取为常数 μ , $z(\mathbf{x}^{(i)})$ 为随机分布的误差, 提供对模拟局部偏差的近似, 其均值为零, 方差为 σ_z^2 , 协方差矩阵为

$$\text{cov}[z(\mathbf{x}^{(i)}), z(\mathbf{x}^{(j)})] = \sigma_z^2 [R(\boldsymbol{\theta}, \mathbf{x}^{(i)}, \mathbf{x}^{(j)})], (i, j = 1, \dots, n_s), \quad (2)$$

其中 n_s 为训练样本点的个数, $R(\boldsymbol{\theta}, \mathbf{x}^{(i)}, \mathbf{x}^{(j)})$ 是带有参数 $\boldsymbol{\theta}$ 的相关函数, 表示训练样本点之间的空间相关性, 常用高斯函数作为相关函数, 其表达式为

$$R(\boldsymbol{\theta}, \mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \exp[-d(\mathbf{x}^{(i)}, \mathbf{x}^{(j)})], \quad (3)$$

其中

$$d(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \sum_{k=1}^m \theta_k |x_k^{(i)} - x_k^{(j)}|^2; (i, j = 1, \dots, n_s), \quad (4)$$

其中 m 为设计变量的个数, $x_k^{(i)}$ 为样本点 $\mathbf{x}^{(i)}$ 对应的设计变量值. 当 θ_k 的值相同时, 相关函数各向同性, 即样本点 $\mathbf{x}^{(i)}$ 的所有分量有相同的权重, 此时, 模型的预测精度会有所降低, 因此, 为提高 Kriging 模型的预测精度, 本文取 θ_k 的值各不相同.

为提高预测精度及模型的泛化能力, Kriging 模型要求预测误差的均值为零, 预测误差的均方差最小, 由此可以得到 concentrated log-likelihood 函数:

$$-\frac{n_s}{2} \ln(\hat{\sigma}_z^2) - \frac{1}{2} \ln(|R|). \quad (5)$$

通过最大化公式(5), 即求解最大化问题:

$$\max_{\theta_k > 0} \left(-\frac{n_s}{2} \ln(\hat{\sigma}_z^2) - \frac{1}{2} \ln(|\mathbf{R}|) \right), k=1, \dots, m, \quad (6)$$

可以得到 θ_k 的值.

采用训练样本点的响应值的线性组合估计设计空间内任意点的响应值, 得到预测响应值和预测值的均方差分别为

$$\hat{y}(\mathbf{x}^*) = \hat{\boldsymbol{\mu}} + \mathbf{r}(\mathbf{x}^*)^T \mathbf{R}^{-1}(\mathbf{Y} - \mathbf{I}\hat{\boldsymbol{\mu}}), \quad (7)$$

$$\sigma^2(\mathbf{x}^*) = \sigma_z^2 \left[\mathbf{I} + (\mathbf{I}^T \mathbf{R}^{-1} \mathbf{I})^{-1} (\mathbf{I} - \mathbf{I}^T \mathbf{R}^{-1} \mathbf{r})^2 - \mathbf{r}^T \mathbf{R}^{-1} \mathbf{r} \right], \quad (8)$$

其中

$$\hat{\boldsymbol{\mu}} = (\mathbf{I}^T \mathbf{R}^{-1} \mathbf{I})^{-1} \mathbf{I}^T \mathbf{R}^{-1} \mathbf{Y}, \quad (9)$$

$$\hat{\sigma}_z^2 = \frac{(\mathbf{Y} - \mathbf{I}\hat{\boldsymbol{\mu}})^T \mathbf{R}^{-1} (\mathbf{Y} - \mathbf{I}\hat{\boldsymbol{\mu}})}{n_s}, \quad (10)$$

其中 \mathbf{I} 为所有元素均为 1 的矩阵, \mathbf{Y} 为训练样本点的响应值, 矩阵 \mathbf{r} 为 \mathbf{x}^* 与初始训练样本点间的相关函数向量.

2 局部型函数参数化方法

几何外形的参数化方法在气动外形的优化设计中起着至关重要的作用, 良好的参数化方法不仅能够充分描述外形的变化, 而且能在很大程度上缩短优化周期, 提高优化效率. 自由变形法^[17]和样条曲面法是性能较好的曲面参数化方法, 能够使用较少的控制点控制较大的变形区域, 而且能够保证曲面的光顺性, 但对于复杂曲面的三维参数化问题, 自由变形法和样条曲面法需要的设计变量比较多, 较难应用于需要大规模计算量的工程优化问题. 为解决这一问题, Kulfan 和 Bussolletti^[18]提出了类函数和型函数参数化方法并实现了翼型、机翼和机身的二维及三维参数化设计, Rho 等人^[19]在此基础上提出了 VMF 三维参数化方法, 使用较少的设计参数实现了汽车

等复杂外形的三维参数化设计, Ku 等人^[5]将 VMF 方法应用到了高速列车头型的三维参数化设计中, 完成了头型减阻的优化工作. 本文借鉴自由变形法和样条曲面法的基本思想, 设计了一种利用关键设计点和型函数控制复杂曲面变形的局部型函数曲面参数化方法.

实现步骤如下.

1) 对于给定的几何外形, 根据具体的优化问题, 划分出需要局部变形的区域, 为了更加容易的实现几何曲面光滑变形, 在不影响整体变形的情况下, 选取的变形区域应尽可能的保证边界坐标值一致, 即同一边界的某个方向的坐标值相等.

2) 对划分的区域进行网格离散, 得到所有区域的离散网格点的坐标值, 为使变形曲面更为光顺, 网格离散使用结构网格离散方法, 如图 1 所示.

3) 设计每个区域的变形函数, 变形函数的选择具有一定的任意性, 但需要保证每个区域边界处的光滑过渡. 为此, 对于规则边界(沿某一方向的离散点坐标值不变), 可以使用离散点的坐标值作为变形函数的自变量; 对于不规则边界(沿任意方向曲面的离散点坐标值均不同), 需要使用离散点的拓扑编号作为变形函数的自变量, 由此, 将不规则曲面投影到平面, 并成为规则的长方形区域, 如图 1 所示.

4) 为每个型函数设置一个权重因子 w_i , w_i 的代数和决定变形曲面的最大变形量.

5) 根据每个区域所选择的型函数和权重因子计算出所有离散网格点的坐标增量值 Δ .

6) 将得到坐标增量值 Δ 与原始离散网格点的坐标值代数相加, 得到变形后外形网格点的坐标值.

7) 根据变形后外形网格点的坐标值重新拟合出变形后的曲面, 完成一次变形.

步骤 3) 是参数化过程的关键, 不同的变形函数会产生完全不同的曲面变形, 选择不合适函数容易导致病态变形, 常用的变形函数有三角函数、指数函数、对数函数等, 较为复杂的有多项式函数、样条函




图 1 局部型函数曲面变形示意图

数等.

由于列车几何外形沿纵剖面对称设计, 因此, 本文针对头车流线型部分的纵剖面的一侧进行参数化, 变形后以纵剖面为对称面, 得到另一侧几何外形, 从而实现头车流线型部分的参数化设计. 本文将参数化部分分隔为 7 个变形区域, 如图 2(a)所示. 变形区域 3 和 6 控制鼻锥处的引流, 设置一个控制点 Point 1, 提取其 y 方向坐标为设计参数 w_1 ; 变形区域 1 和 3 控制鼻锥高度, 设置一个控制点 Point 2, 提取其 z 方向坐标为设计参数 w_2 ; 变形区域 4, 5, 6 和 7 共同控制车体宽度, 提取一个设计参数 w_3 为控制点 Point 3 沿 y 方向的坐标值; 变形区域 5 和 6 控制司机室的视角, 提取一个设计参数 w_4 为控制点 Point 4 沿 z 方向的坐标; 变形区域 2 控制鼻锥底部导流, 提取一个设计参数 w_5 为控制点 Point 5 沿 x 方向的坐标. 为保证列车底部宽度能够容纳底部附属装置, 除排障器区域外, 本文对列车底板的宽度不做变化. 在不影响设计空间内几何曲面任意变形的情况下, 为便于操作, 本文所有变形区域均使用三角函数作为变形函数, 图 2(b)给出了鼻锥处和排障器的变形, 可以看出, 变形区域能够保证曲面的光顺性, 而且不同变形区域之间能够实现光滑过渡.

3 CFD 计算方法及精度验证

3.1 计算外形

高速列车头型的优化设计主要针对头车流线型部分, 关键设计参数为: 头车流线型部分的截面变化

率、头车细长比(流线型部分长度与车身最大宽度的比值)、流线型部分的纵向型线和水平型线、鼻锥引流、驾驶舱倾角以及转向架侧罩. 本文针对 CRH380A 头型 1:1 三辆编组简化外形进行优化, 将风挡简化为完全封闭的外风挡, 封闭了转向架处的凹腔, 没有考虑转向架侧罩对列车气动阻力的影响. 尾锥底部的转向架对尾车底部流动及尾流场影响很大, 为更加准确的模拟尾车的气动升力, 对尾锥底部转向架不做简化处理, 如图 3 所示.

CRH380A 三辆编组车型的几何参数: 头车、尾车长度均为 26.5 m, 中间车长度为 25 m, 头、尾车几何外形完全相同. 头车流线型部分长度为 12 m, 高度为 3.5 m, 宽度为 3.38 m, 横截面积为 11.2 m², 细长比为 3.55. 截面变化为三段式, 纵剖面型线为双拱形, 水平断面型线为长扁梭型, 鼻锥为椭圆球型二维设计, 如图 3 所示.

3.2 CFD 计算方法

CFD 流场计算精度直接影响到响应面的构造和优化算法的效率, 是整个优化流程的基础. 对于样本点响应值的计算, 本文针对的高速列车运行速度为 300 km/h, 马赫数为 $Ma=0.245$, 空气的压缩效应对列车阻力会产生一定的影响. 因此, 流场计算方法采用基于格子格式有限体积法的三维定常可压缩雷诺平均 N-S 方程^[20], 空间离散格式采用 Roe 格式, 时间离散采用 LU-SGS 离散方法, 湍流模型采用 $k-w$ SST 模型, 为控制物面处的边界层网格数量并保证流场计算精度, 在壁面处使用了标准壁面函数.




图 2 流线型部分的变形曲面

(a) 流线型部分的变形区域; (b) 不同变形区域的变形

外场及边界条件: 以三辆编组列车的总长度 L 为特征长度, 来流方向取 $1L$, 出口方向取 $2L$, 外场高度取 $0.5L$, 宽度取 $1L$, 车体底部离地面的高度为 $0.00235L$, 如图 4 所示. 来流速度为 $V=83.333 \text{ m/s}$, 远场压力取为 1 个大气压, 温度为 $T=288 \text{ K}$, 参考面积取列车横截面面积. 由于采用了可压缩计算模型, 因此, 远场边界通过引入与边界垂直的一维无粘流动的黎曼不变量处理, 即无反射边界条件. 流入边界、流出边界和顶部边界均为远场边界条件, 车体为无滑移固壁边界条件. 为模拟地面效应的影响, 将地面设置为移动壁面, 移动速度与来流速度相等.

3.3 网格无关性验证

空间网格的划分直接影响到计算结果的准确性和稳定性. 为考核不同空间网格的划分对数值计算结果的影响, 本文使用物面附近布置三棱柱网格和空间布置切割正交六面体网格相结合的混合网格进行了网格无关性验证. 在保证第一层边界层网格厚

度满足壁面函数要求的情况下(第一层边界层高度为 0.45 mm , $30 \leq y^+ \leq 50$), 通过改变边界层内的网格层数、加密区的网格尺寸和加密区域的范围, 共划分了三套网格. 第一套网格边界层的层数为 6 层, 增长比为 1.5, 最小加密区网格单元尺寸为 12 mm , 网格量为 1086 万; 第二套网格边界层的层数为 9 层, 增长比为 1.2, 最小加密区网格单元尺寸为 12 mm , 网格量为 1467 万; 第三套网格边界层的层数为 9 层, 增长比为 1.2, 最小加密区网格单元尺寸为 6 mm , 网格量为 2104 万. 空间网格的整体分布及局部分布如图 5 所示.

三套网格的计算结果如表 1 所示, 可以看出, 网格量的不同对计算结果的影响并不明显, 整车的阻力系数的变化均在 1% 以内, 尾车气动升力系数的变化在 3% 以内, 而且压差阻力与摩擦阻力的变化也很小; 因此, 空间网格的划分对计算结果的影响可以忽略; 考虑到 CFD 流场计算的效率, 本文选用 1086 万量级的网格.

为进一步验证列车简化外形 Model-I 的合理性,




图 3 列车简化外形(列车各部件的示意图及流线型部分的几何参数)




图 4 流场计算区域




图5 整体网格分布及局部面网格

表1 不同网格量的计算结果

| Mesh number/million | Total Cd | Tail Cl | Pressure drag | Shear drag |
|---------------------|----------|---------|---------------|------------|
| 10.86 | 0.1971 | 0.0546 | 0.0660 | 0.1311 |
| 14.67 | 0.1974 | 0.0560 | 0.0658 | 0.1316 |
| 21.04 | 0.1975 | 0.0563 | 0.0669 | 0.1306 |

本文将对完全简化外形 Model-II(即不考虑所有转向架和风挡)和真实外形 Model-III(即考虑所有的转向架和风挡)与 Model-I 进行对比分析,表2给出了3种模型的计算结果,可以看出:3种模型的总气动阻力系数相差较大,但都为正值,Model-I 和 Model-III 的尾车气动升力系数为正值,而 Model-II 的尾车气动升力系数为负值.可见,尾车最后一个转向架对列车气动性能的影响较大,Model-I 的简化方法相对于 Model-II 更能反映出真实外形的气动性能,Model-I 的简化方法更为合理.

4 多目标自适应遗传算法

NSGA-II 将父代种群 P_n 与子代种群 Q_n 相结合成一个大的种群 R_n ,然后基于多目标解对群体进行逐层分类,按解个体的非劣关系进行排序^[21].在对个体进行排序之后,按照个体的非劣等级赋予每个个

表2 不同模型的计算结果

| Model type | Total Cd | Tail Cl | Pressure drag | Shear drag |
|------------|----------|---------|---------------|------------|
| Model-I | 0.1971 | 0.0546 | 0.0660 | 0.1311 |
| Model-II | 0.1567 | -0.0237 | 0.0231 | 0.1336 |
| Model-III | 0.3224 | 0.0366 | 0.2146 | 0.1078 |

体一个假设适应度值,然后从最优非劣等级开始,提取前 N 个个体作为新的种群.本文基于 NSGA-II 的非劣等级排序规则,仅将子代和父代的第一前沿解集进行混合后,重新进行非劣等级排序,得到子代的第一前沿解,结合自适应改变交叉算子和变异算子^[21]的遗传算法,构造出了多目标自适应非劣分类遗传算法^[22].使用小生境技术保证 Pareto 最优解集的均匀性,避免所有的 Pareto 解收敛到局部最优解.目前,常用的遗传算法编码方式为实数编码和二进制编码,实数编码在变异操作时能够更好的保持种群多样性,而二进制编码具有更强的搜索能力,由于小生境技术能够较好的保证种群多样性,为增强算法的搜索能力,本文使用的单目标遗传算法与多目标遗传算法均采用 22 位二进制编码方式.

进化过程中交叉概率和变异概率的自适应变化公式^[23]为

$$P_c(x) = \begin{cases} P_{c1} - \frac{(P_{c1} - P_{c2})(f' - f_{avg})}{f_{max} - f_{avg}}, & f' \geq f_{avg} \\ P_{c1}, & f' < f_{avg} \end{cases} \quad (11)$$

$$P_m(x) = \begin{cases} P_{m1} - \frac{(P_{m1} - P_{m2})(f_{max} - f)}{f_{max} - f_{avg}}, & f \geq f_{avg} \\ P_{m1}, & f < f_{avg} \end{cases} \quad (12)$$

其中 P_c, P_m 分别为交叉概率和变异概率, f_{max}, f_{avg} 分别为本代种群中最大的适应度函数值和平均适应度函数值, f' 为需要交叉的两个个体中较大的适应度函数值, f 为需要变异的个体的适应度函数值.

根据非劣解的等级设定的种群中个体 i 适应度函

数为

$$fit_i(\mathbf{x}) = \frac{1}{[1 + \phi(\mathbf{x}) + \psi(\mathbf{x})] \sum_j^N Sh(d_{ij})}, \quad (13)$$

其中

$$\phi(\mathbf{x}) = (d - 1)/D_{\text{rank}} \quad (14)$$

为第 d 级个体的距离惩罚函数, D_{rank} 为本代最大等级数, 可见, 同一等级的距离惩罚函数值相同, 保证了相同等级非劣解个体之间的距离相等;

$$\psi(\mathbf{x}) = \sum_{i=1}^l \alpha_i |\min\{0, g_i(\mathbf{x})\}|^r, \quad (15)$$

$$g_i(\mathbf{x}) \leq 0, \quad i = 1, \dots, l \quad (16)$$

为约束惩罚函数, (16) 式为不等式约束表达式, 本文只有体积约束条件, l 为不等式约束的个数, α_i 为惩罚因子系数, 取值为 1, r 为惩罚因子尺度, 取值为 2;

$$Sh(d_{ij}) = \begin{cases} 1 - \frac{d_{ij}}{\sigma_{\text{share}}}, & d_{ij} \leq \sigma_{\text{share}}, \\ 0, & d_{ij} > \sigma_{\text{share}} \end{cases} \quad (17)$$

为小生境技术中使用的共享函数, d_{ij} 为个体 i 和个体 j 之间的距离, σ_{share} 为小生境半径, 本文定义为

$$\sigma_{\text{share}} = \frac{\sum_{i=1}^N \sum_{j=1}^N d_{ij}}{N \times N}, \quad d_{ij} = \sqrt{\sum_{k=1}^m (x_{i,k} - x_{j,k})^2}, \quad (18)$$

其中 m 为设计变量的个数, $x_{i,k}$ 为个体 i 归一化后的第 k 个设计变量。

5 Kriging 代理模型的构造和预测精度分析

5.1 采样方法及样本点的选取

本文以 CRH380A 型高速列车三辆编组总气动阻力和尾车气动升力为优化目标, 给定约束条件为: 优化后头车流线型部分的体积不能小于原始外形的 95%。在满足约束条件的情况下, 获取目标函数的 Pareto 最优解集。为便于对头车流线型部分的参数化, 将 1:1 几何外形沿列车长度方向单位化, 使流线型部分的长度为 1 m, 计算流场时, 再将单位化后的外形放大到真实外形, 从而消除缩比外形对流场计算结果的影响。本文提取的 5 个设计参数的约束范围(长

度单位为 mm) 分别是: 鼻锥引流: $-5 \leq w_1 \leq 5$, 鼻锥高度: $-15 \leq w_2 \leq 10$, 车体宽度: $-5 \leq w_3 \leq 20$, 司机室视角: $-10 \leq w_4 \leq 4$, 排障器外形: $-60 \leq w_5 \leq 10$ 。

构建 Kriging 模型的基础是样本信息, 均匀分布的样本可以提供设计全空间的信息, 使所构建的模型能够捕捉到真正对象函数的趋势和变化。拉丁超立方采样方法能够确保产生的样本点代表设计空间中的所有部分, 而且无需考虑问题的维数, 样本数目可以是任意整数, 但其随机性导致算法有一定的不稳定性, 为避免随机性导致的采样不均匀, 本文使用基于迭代局部搜索算法的带有极大极小准则的中心拉丁超立方采样方法^[24, 25]。

初始试验设计样本点为 21 个, 选取前 20 个作为训练样本点, 剩余 1 个作为测试样本点, 如表 3 所示。从表 3 可以看出: 与整车阻力系数相比, 尾车的升力系数对于设计参数的变化更为敏感, 波动范围更大, 最大波动幅度为 31.35%, 而在整个设计空间内的波动幅度会更大, 因此, 对 Kriging 模型的预测能力要求更高。

5.2 Kriging 代理模型的构造和预测精度分析

由于 CFD 流场计算量巨大, 在不影响寻优结果的前提下, 为尽量减少训练样本点的数量, 本文使用基于最小化响应面加点准则^[13]的序列优化设计方法^[14], 对 Kriging 模型进行动态训练, 根据初始设计的 20 个训练样本点构造出基准 Kriging 模型, 以此模型为基础, 使用多目标自适应遗传算法得到 Pareto 最优解集, 从中任意选出其中两个解进行 CFD 计算验证, 如果预测精度达不到要求, 将得到准确值的设计点加入训练样本集, 重新构造 Kriging 模型, 如果预测精度达到要求, 迭代终止。设计空间内, 整车气动阻力变化范围较小, 而尾车气动升力的变化范围较大, 使用相同的训练样本点, 得到的 Kriging 模型对尾车气动升力的预测能力较差, 因此, 本文要求 Kriging 模型对整车气动阻力的预测误差在 1% 以内, 对尾车气动升力的预测误差在 5% 以内。

Kriging 模型的训练过程实质是寻找 θ_k 值的最优化的过程, 即实现(6)式的最优化问题, 该问题可以通过最大似然估计^[26]或模式搜索方法^[27]实现, 最大似然估计方法容易陷入局部最优解, 模式搜索方法对起始点的依赖程度很高, 为此, 本文将(5)式作为目标函数, 使用自适应 22 位二进制编码遗传算法得

表3 初始训练样本点和测试样本点

| Type | Number | w_1 (mm) | w_2 (mm) | w_3 (mm) | w_4 (mm) | w_5 (mm) | Cd | Cl |
|-----------------|--------|------------|------------|------------|------------|------------|--------|--------|
| Training points | 1 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.1971 | 0.0546 |
| | 2 | -2.75 | -5.625 | 11.875 | 0.85 | -23.25 | 0.2004 | 0.0668 |
| | 3 | -1.25 | -9.375 | 4.375 | -8.95 | -44.25 | 0.1946 | 0.0563 |
| | 4 | -4.75 | -10.625 | 9.375 | -2.65 | -9.25 | 0.1996 | 0.0600 |
| | 5 | -4.25 | -11.875 | 0.625 | -0.55 | -37.25 | 0.1941 | 0.0548 |
| | 6 | -2.25 | -0.625 | -1.875 | -3.35 | -26.75 | 0.1941 | 0.0519 |
| | 7 | -0.75 | -1.875 | -0.625 | -1.25 | -51.25 | 0.1924 | 0.0524 |
| | 8 | 0.75 | -8.125 | 15.625 | -4.05 | -33.75 | 0.1999 | 0.0714 |
| | 9 | -3.25 | -14.375 | 16.875 | -9.65 | 1.25 | 0.2022 | 0.0756 |
| | 10 | 3.75 | -4.375 | 6.875 | -8.25 | -54.75 | 0.1941 | 0.0575 |
| | 11 | 4.75 | 0.625 | 18.125 | -4.75 | -40.75 | 0.2013 | 0.0709 |
| | 12 | -0.25 | 4.375 | 13.125 | -1.95 | -47.75 | 0.1991 | 0.0611 |
| | 13 | -3.75 | 3.125 | 1.875 | -7.55 | -16.25 | 0.1965 | 0.0543 |
| | 14 | 2.75 | -6.875 | 5.625 | 2.95 | -30.25 | 0.1983 | 0.0599 |
| | 15 | -1.75 | -3.125 | 3.125 | 3.65 | 8.25 | 0.1992 | 0.0572 |
| | 16 | 1.75 | 6.875 | -3.125 | -6.85 | 4.75 | 0.1964 | 0.0521 |
| | 17 | 1.25 | -13.125 | 10.625 | 2.25 | -5.75 | 0.2015 | 0.0643 |
| | 18 | 4.25 | 5.625 | 8.125 | 0.15 | -19.75 | 0.2015 | 0.0618 |
| | 19 | 2.25 | 8.125 | -4.375 | -6.15 | -12.75 | 0.1958 | 0.0515 |
| | 20 | 0.25 | 9.375 | 14.375 | -5.45 | -58.25 | 0.1960 | 0.0597 |
| Test points | 21 | 3.25 | 1.875 | 19.375 | 1.55 | -2.25 | 0.1970 | 0.0603 |

到 θ_k 的最优值. 由于每个目标对应一个方差 σ_z^2 , 因此, (6)式的最优化问题是一个无约束、多目标、多变量优化问题, 在不影响 Kriging 模型预测精度的情况下, 为简化问题的复杂度, 本文将多目标优化问题通过简单加权方法转化为单目标优化问题, 将两个目标的权重值均赋为0.5. 种群数量为500, 最大进化代数为1000, 选择算子使用轮盘赌法, 初始交叉概率为 $P_{c1}=0.9$, $P_{c2}=0.6$, 初始变异概率为 $P_{m1}=0.1$, $P_{m2}=0.001$. 图6给出了进行第一次加点时的最优解适应度值随进化代数的收敛曲线, 在进化600代后, 适应度值收敛到一个稳定值, 说明将多目标优化问题转化为单目标优化问题的方法可行, 存在一个最优解值.

图7给出了 Kriging 模型对测试样本点和 Pareto 最优解集的预测误差, 可以看出, Kriging 模型对 Cl 的预测能力明显低于对 Cd 的预测能力, 随着加点次数的增大, Kriging 模型在设计空间内的预测精度变化不大, 但在 Pareto 前沿解附近的预测精度显著提高,

经过第一次加点, 测试样本点的预测误差接近于设计要求, 而 Pareto 前缘解的预测误差很大, 尾车气动升力的误差约为70%, 经过第二次加点, Kriging 模型的预测精度有了较大的提高, 测试样本点的预测误差已经达到了设计要求, 而 Pareto 前缘解的预测误差仍然较大, 经过4次加点, 测试样本点和 Pareto 前缘解的预测精度达到本文的要求.




图6 最优解适应度值随进化代数的收敛曲线

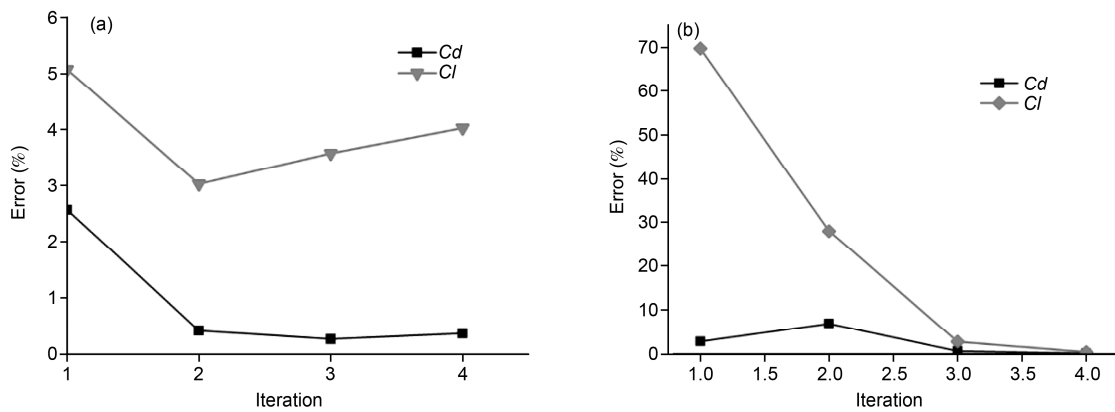


图 7 Kriging 代理模型的预测精度

(a) Kriging 代理模型对测试样本点的预测误差; (b) Kriging 代理模型对 Pareto 前缘解的预测误差

5.3 优化流程

本文设计的整体优化流程如图 8 所示, 首先使用拉丁超立方采样方法在设计空间内采样, 然后通过 CFD 流场计算获取准确的初始样本点的目标函数值, 选取一定数量的初始样本点, 使用遗传算法训练 Kriging 代理模型; 在得到了满足一定精度的代理模型之后, 调用多目标自适应遗传算法对设计参数值进行寻优, 得到 Pareto 最优解集之后, 选取其中两个

解进行 CFD 计算验证, 判断得到的预测优化解的精度是否达到了设计要求, 如果没有, 将选取的优化解添加到训练样本中, 对 Kriging 代理模型进行新一轮的训练, 从而使 Kriging 代理模型在 Pareto 最优解集区域的预测精度不断提高; 如果得到的预测精度达到了设计要求, 则响应面构建完成, 使用构造的 Kriging 代理模型和多目标自适应遗传算法在设计空间内寻优, 得到设计空间内的 Pareto 最优解集, 优化流程结束。

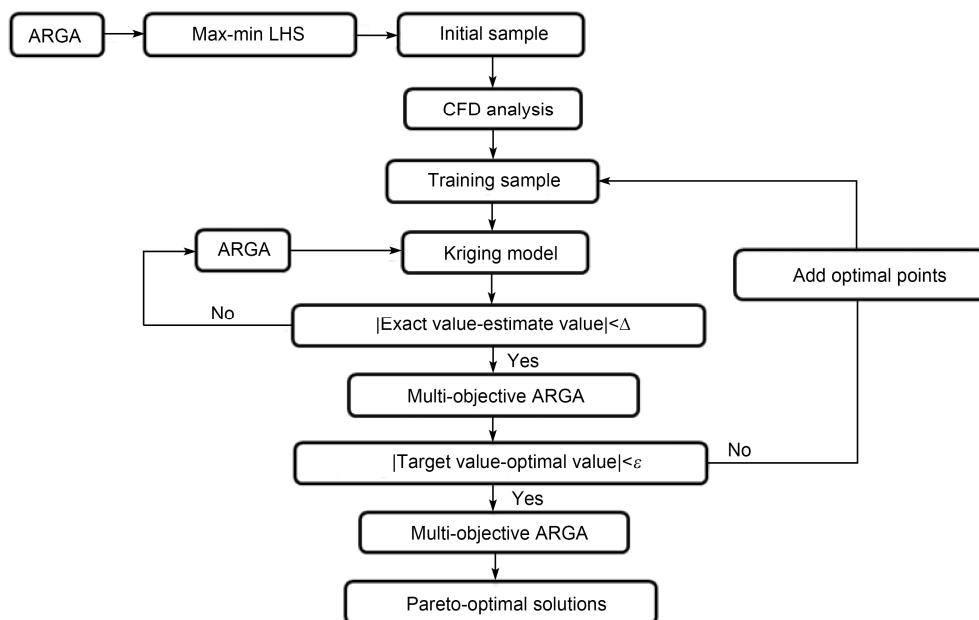


图 8 多目标优化设计流程

6 结果与分析

6.1 优化外形与原始外形的对比分析

以三辆编组列车气动阻力和尾车气动升力为优化目标, 使用采用 22 位二进制编码自适应遗传算法, 种群数量为 500, 进化代数 3000 代, 选择算子使用轮盘赌法, 初始交叉概率为 $P_{c1}=0.9$, $P_{c2}=0.6$, 初始变异概率为 $P_{m1}=0.1$, $P_{m2}=0.001$. 图 9 给出了两个目标的 Pareto 最优解集, 可以看出, 在本文选取的设计空间内, 目标函数的收敛区域较为一致, 最优解集的变化范围较小, 得到的 Pareto 最优解集中的个体差异不是很大, 所有个体的目标值均优于原始外形的目标值, 选取图 9 中的个体作为典型设计点.

优化后, 鼻锥引流处的中心点下移 0.0149 m, 鼻锥高度下降 0.024 m, 流线型部分车体宽度最大减幅为 0.1165 m, 司机室玻璃的倾角减小了 1.99°, 排障器底部顶点位置后移了 0.569 m, 流线型部分的体积由原来的 89.7178 m³ 变为 87.7824 m³, 减小 2.16%, 满足约束条件的要求, 可以看出, 优化后的列车鼻锥更接近于梭型, 更有利于列车周围的气流流动. 表 4 给出了典型设计点的气动力系数, 可以看出, Kriging 模型的预测值与 CFD 计算值一致, 优化后, 整车气动阻力系数减小 3.2%, 尾车气动升力系数减小 8.24%, 优化前后的整车摩擦阻力基本不变, 压差阻力减小了 10.02%.

图 10 给出了优化前后头车表面及纵剖面压力云图, 可以看出, 鼻端和排障器区域存在较大的高压区, 鼻锥与司机室玻璃的过渡区域存在一个次高压区, 排障器底部存在一个明显的低压区; 优化后, 排障器

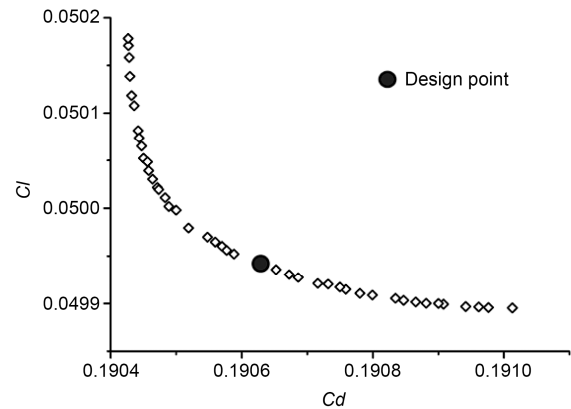


图 9 整车气动阻力与尾车气动升力的 Pareto 最优解集

表 4 优化前后的列车气动力系数和 Kriging 代理模型的预测值

| Model type | Total Cd | Tail Cl | Pressure drag | Shear drag |
|----------------|----------|---------|---------------|------------|
| Original shape | 0.1971 | 0.0546 | 0.0659 | 0.1312 |
| Optimal shape | 0.1908 | 0.0501 | 0.0593 | 0.1315 |
| Reduction | 3.20% | 8.24% | 10.02% | -0.23% |
| Kriging model | 0.1906 | 0.0499 | - | - |




图 10 优化前后头车表面及纵剖面压力云图

前端位置后移, 气流加速过程变缓, 致使该处附近的高压区减小, 鼻锥高度下降幅度与司机室玻璃倾角减小幅度相适应, 使区域 1 处的过渡减缓, 从而使该处的高压区略有减小, 两种因素导致头车的压差阻力在一定程度上减小。

从图 11 可以看出, 优化前后头车上表面纵剖面型线的压力系数基本不变, 只有鼻锥和司机室的连接处、司机室和过渡区的连接处有略微的变化; 由于排障器前端后移, 导致排障器附近的低压区后移, 且该区域的压力峰值有所减小; 尾锥完全浸润在边界层内部, 其纵剖面型线的压力系数变化不大。

为更加清楚的了解优化后列车的气动性能, 得

到流线型部分气动外形的改变对其他车体部分的影响, 本文给出了优化前后列车各部分的气动阻力系数和升力系数, 从表 5 可以看出, 压差阻力主要存在于鼻锥和尾锥, 尾锥的压差阻力约占总压差阻力的 55%, 车体截面积不变的部分压差阻力为 0; 列车底部各部分的气动升力均为负值, 对车体有一个垂直向下的拉力, 其余部分均为正值, 对车体有一个向外的拉力。优化后, 鼻锥和尾锥的压差阻力减小幅度很大, 且均减小 0.003, 其余各部分的气动阻力系数基本不变; 尾锥的升力减小最为明显, 尾车车体的升力有所增大, 尾车底板的负升力减小, 尾锥升力减小幅度最大, 为 0.0057, 而尾锥底板和转向架的升力基本不变。

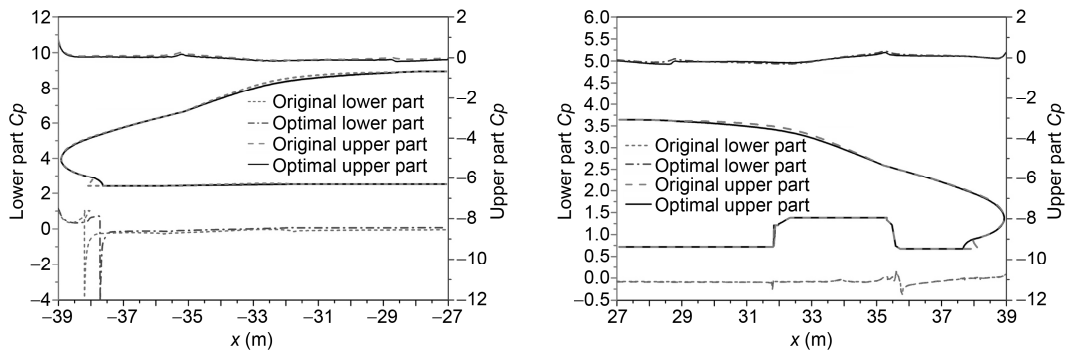


图 11 优化前后头尾车纵剖面压力系数分布

(a) 头车纵剖面压力系数; (b) 尾车纵剖面压力系数

表 5 优化前后列车各部分的气动阻力系数和升力系数

| Train part | Original shape | | Optimal shape | | Original shape | Optimal shape |
|-------------|----------------|---------------|---------------|---------------|----------------|----------------|
| | pressure | shear | pressure | shear | tail C_l | tail C_l |
| Nose | 0.0060 | 0.0156 | 0.0030 | 0.0156 | - | - |
| Nose-down | 0.0020 | 0.0045 | 0.0017 | 0.0047 | - | - |
| Head-body | 0.0000 | 0.0218 | 0.0000 | 0.022 | - | - |
| Head-down | 0.0000 | 0.0064 | 0.0000 | 0.0064 | - | - |
| Middle-body | 0.0000 | 0.0346 | 0.0000 | 0.0348 | - | - |
| Middle-down | 0.0000 | 0.0099 | 0.0000 | 0.0097 | - | - |
| Tail-body | 0.0000 | 0.0195 | 0.0000 | 0.0196 | 0.0800 | 0.0835 |
| Tail-down | 0.0000 | 0.0052 | 0.0000 | 0.0052 | -0.0783 | -0.0803 |
| Wake | 0.0366 | 0.0112 | 0.0336 | 0.011 | 0.1820 | 0.1763 |
| Wake-down | 0.0115 | 0.0019 | 0.0111 | 0.0019 | -0.1179 | -0.1179 |
| Bogie | 0.0098 | 0.0006 | 0.0099 | 0.0006 | -0.0112 | -0.0115 |
| Total | 0.0659 | 0.1312 | 0.0593 | 0.1315 | 0.0546 | 0.0501 |

6.2 真实外形优化前后的对比分析

由于本文是针对高速列车头车流线型部分进行的气动外形优化设计,为减少网格生成时间和流场计算时间,对CRH380A真实外形(安装真实的风挡与转向架)进行了适当简化,只保留了尾锥底部的转向架,舍弃了列车的其他附属部件。然而,附属部件对真实外形的气动性能有很大影响^[2],为充分考虑列车附属部件对整车气动性能的影响,进一步研究优化外形整车气动阻力和尾车气动升力的优劣,本文将对CRH380A真实外形的原型车与优化车进行对比分析,真实几何外形如图12所示。

真实外形的CFD计算方法与简化外形完全一致,流场计算网格仍然使用物面附近布置三棱柱网格和空间布置切割正交六面体网格相结合的混合网格,为得到较为细致的流场信息,对附属部件区域进行局部网格加密,最小空间网格尺寸为6 mm,边界层为6层,第一层边界层高度为0.45 mm,增长比为1.2,整体网格量为2230万。

表6给出了CRH380A原型车与优化车的气动力分布情况,可以看出,真实外形的压差阻力远大于简化外形的压差阻力,摩擦阻力比简化外形的小;头车第一个转向架压差阻力较大,主要原因是:地面与车体底板间的截面积很小,空气经过鼻锥区域的压缩,流动速度很大,当气流到达鼻锥底部转向架前端处,速度迅速减小,形成较强的高压区,流过转向架之后,气流再次加速,最终第一个转向架附近形成较大的压差阻力,由于鼻锥底板包括第一个转向架仓,其压差阻力与简化外形相比增加幅度也比较大;车体连接处没有完全封闭,气流在两个风挡之间形成漩涡,使得背风侧的风挡Shield-1和Shield-3存在较大的气动推力,迎风侧的风挡Shield-2和Shield-4存在较大的气动阻力,但四个风挡的代数和较小,说明车体连接处对每节车的气动力分布有较大影响,对列车总的气动力影响不大;尾车气动升力仍然是由于沿车

体向外的拉力引起的,附属部件均表现出指向地面的拉力,导致真实外形的尾车气动升力比简化外形的小。优化前后,列车附属部件的气动力基本不变,鼻锥和尾锥的气动阻力变化较大,尾锥的气动升力变化明显;优化后,整车气动阻力减小2.26%,压差阻力减小3.78%,摩擦阻力增加0.74%;尾车气动升力减小19.67%,与简化外形相比差别较大,主要是由附属部件(包括风挡和转向架)的影响引起的,说明尾车的气动升力对于附属部件对尾车周围流场的扰动较为敏感,对列车进行简化方法要求较高。虽然简化外形与真实外形优化前后的气动力变化有所不同,但趋势相同,且均能反映出气动外形的变化对列车气动力的影响,因此,可以认为本文的简化方法较为合适,在对优化结果影响不大的情况下,减小了流场计算量,提高了优化效率。

6.3 横风条件下优化前后列车气动性能分析

高速列车在横风条件下运行是较为常见的运行工况,且此时的列车气动性能与无风条件相比有很大的不同,对列车运行的安全性有较大的影响。为进一步研究优化外形的设计稳健性,本文将对优化前后列车真实外形在横风条件下运行时的气动性能进行对比分析。

本文针对计算工况为:运行速度为300 km/h,横风速度为15 m/s,横风侧偏角为90°。CFD计算方法与无风条件时的完全一致,流场计算网格使用物面附近布置三棱柱网格和空间布置切割正交六面体网格相结合的混合网格,为更加准确的模拟背风侧的涡结构,本文对列车背风侧进行了网格加密,最小空间网格尺寸为6 mm,边界层为6层,第一层边界层高度为0.45 mm,增长比为1.2,整体网格量为2620万。

表7给出了横风条件下优化前后列车各部件的气动阻力和升力系数,可以看出,与无横风条件相比,横风条件下列车的气动阻力和尾车气动升力都有很




图12 CRH380A 真实几何外形

表 6 CRH380A 真实外形优化前后各部件的气动阻力和升力

| Train part | Original shape | | Optimal shape | | Original shape | Optimal shape |
|-------------|----------------|---------------|----------------|---------------|----------------|----------------|
| | pressure | shear | pressure | shear | tail <i>Cl</i> | tail <i>Cl</i> |
| Nose | 0.0147 | 0.0145 | 0.0115 | 0.0145 | - | - |
| Nose-down | 0.0353 | 0.0023 | 0.0308 | 0.0023 | - | - |
| Head-body | 0.0000 | 0.0207 | 0.0000 | 0.0209 | - | - |
| Head-down | 0.0102 | 0.0026 | 0.0097 | 0.0025 | - | - |
| Bogie 1 | 0.0322 | 0.0011 | 0.0331 | 0.0012 | - | - |
| Bogie 2 | 0.0075 | 0.0004 | 0.0081 | 0.0004 | - | - |
| Shield-1 | -0.0332 | 0.0001 | -0.0343 | 0.0001 | - | - |
| Middle-body | 0.0000 | 0.0320 | 0.0000 | 0.0325 | - | - |
| Middle-down | 0.0113 | 0.0022 | 0.0122 | 0.0023 | - | - |
| Bogie 3 | 0.0087 | 0.0004 | 0.0091 | 0.0004 | - | - |
| Bogie 4 | 0.0053 | 0.0002 | 0.0043 | 0.0002 | - | - |
| Shield-2 | 0.0485 | 0.0002 | 0.0496 | 0.0002 | - | - |
| Shield-3 | -0.0279 | 0.0001 | -0.0287 | 0.0001 | - | - |
| Tail-body | 0.0000 | 0.0180 | 0.0000 | 0.0182 | 0.0833 | 0.0832 |
| Tail-down | 0.0042 | 0.0011 | 0.0057 | 0.0011 | -0.1194 | -0.1187 |
| Wake | 0.0433 | 0.0107 | 0.0391 | 0.0106 | 0.1896 | 0.1813 |
| Wake-down | 0.0081 | 0.0008 | 0.0046 | 0.0007 | -0.0899 | -0.0890 |
| Bogie 5 | 0.0042 | 0.0003 | 0.0047 | 0.0003 | -0.0061 | -0.0059 |
| Bogie 6 | 0.0043 | 0.0002 | 0.0035 | 0.0002 | -0.0062 | -0.0061 |
| Shield-4 | 0.0423 | 0.0002 | 0.0432 | 0.0002 | -0.0147 | -0.0154 |
| Total | 0.2143 | 0.1081 | 0.2062 | 0.1089 | 0.0366 | 0.0294 |

表 7 CRH380A 真实外形横风条件下优化前后各部件的气动阻力和升力

| Train part | Original shape | | Optimal shape | | Original shape | Optimal shape |
|-------------|----------------|---------------|----------------|---------------|----------------|----------------|
| | pressure | shear | pressure | shear | tail <i>Cl</i> | tail <i>Cl</i> |
| Nose | -0.0342 | 0.0154 | -0.0372 | 0.0153 | - | - |
| Nose-down | 0.0287 | 0.0021 | 0.0299 | 0.0020 | - | - |
| Head-body | 0.0000 | 0.0230 | 0.0000 | 0.0226 | - | - |
| Head-down | 0.0237 | 0.0039 | 0.0234 | 0.0039 | - | - |
| Bogie 1 | 0.0202 | 0.0008 | 0.0198 | 0.0008 | - | - |
| Bogie 2 | 0.0131 | 0.0007 | 0.0124 | 0.0007 | - | - |
| Shield-1 | -0.0370 | 0.0000 | -0.0370 | 0.0000 | - | - |
| Middle-body | 0.0001 | 0.0382 | 0.0001 | 0.0383 | - | - |
| Middle-down | 0.0383 | -0.0060 | 0.0389 | 0.0059 | - | - |
| Bogie 3 | 0.0114 | 0.0006 | 0.0107 | 0.0006 | - | - |
| Bogie 4 | 0.0159 | 0.0008 | 0.0146 | 0.0008 | - | - |
| Shield-2 | 0.0528 | 0.0002 | 0.0526 | 0.0002 | - | - |
| Shield-3 | -0.0317 | 0.0001 | -0.0320 | 0.0001 | - | - |
| Tail-body | 0.0000 | 0.0212 | 0.0000 | 0.0215 | 0.3389 | 0.3391 |
| Tail-down | 0.0194 | 0.0039 | 0.0179 | 0.0037 | -0.1663 | -0.1701 |
| Wake | 0.0784 | 0.0128 | 0.0763 | 0.0129 | 0.2962 | 0.2741 |
| Wake-down | 0.0175 | 0.0026 | 0.0158 | 0.0024 | -0.1461 | -0.1500 |
| Bogie 5 | 0.0129 | 0.0007 | 0.0127 | 0.0007 | -0.0126 | -0.0116 |
| Bogie 6 | 0.0206 | 0.0011 | 0.0213 | 0.0010 | -0.0209 | -0.0206 |
| Shield-4 | 0.0479 | 0.0002 | 0.0488 | 0.0002 | -0.0048 | -0.0057 |
| Total | 0.2980 | 0.1343 | 0.2890 | 0.1336 | 0.2844 | 0.2552 |

大幅度的提高; 鼻锥的气动阻力为负值, 即为向前的拉力, 而整个头车的气动阻力为正值; 尾车的气动升力仍然是由于各部件向外的拉力引起的. 优化后, 鼻锥和尾锥的气动力变化明显, 其他部件的气动力基本不变, 整车气动阻力减小 2.24%, 其中, 压差阻力减小 3.02%, 摩擦阻力基本不变, 尾车气动升力减小 10.27%. 可见, 优化外形在横风条件下的气动性能也有较大幅度的提高, 与无横风条件下的提高幅度趋势一致, 表明本文得到优化外形具有一定的设计稳健性.

6.4 设计参数对优化目标的影响

设计参数的提取是否合理对优化结果有较大影响, 为此, 本文将对设计参数作进一步的讨论. 对于构建好的 Kriging 代理模型, θ_k 值的相对大小意味着其相对应的设计变量对目标函数响应值的影响程度的大小^[13], 可以衡量设计变量对目标函数的重要性. 图 13 给出了每个设计变量对应的 θ_k 值的相对值, 可以看出, 五个设计变量对应的 θ_k 值有较大的不同, 由于鼻锥引流和司机室视角的设计空间较小, 其微小变化引起的几何变形对流场扰动较小, 因此, w_1 和 w_4 对应的 θ_1 和 θ_4 的值较小, 这也反映出 CRH380A 原型车的鼻锥引流和司机室视角设计的较为合理; 车体宽度 w_3 对应的 θ_3 值和控制鼻锥底部排障器引流的设计参数 w_5 对应的 θ_5 值较大, 主要是因为车体宽度控制着鼻锥的迎风面积, 对头车的压差阻力影响较大, 排障器的引流不仅对列车气动阻力有较大影响, 而且对尾涡脱落的方式和强度有较大影响, 进而对尾车气动升力的影响较大. 本文提取的设计参数对目标函数值均有一定的影响, 在保证列车原始外形基

本特征的情况下, 所选设计参数能够充分描述列车外形的关键特征, 说明提取的设计参数比较合理.

7 结论

本文针对 CRH380A 三辆编组简化外形进行了以车体流线型部分的容积为约束条件的多目标优化设计, 得到以下结论.

1) 本文提出的基于自适应非劣分类遗传算法的高速列车头型多目标有约束气动外形优化设计方法具有较高的优化效率, 在一定程度上能够解决实际的工程优化问题, 为大规模、多参数、多目标复杂气动外形优化设计提供了参考方法.

2) 使用数量较少的训练样本点可以构造出满足工程精度要求的基于自适应遗传算法和最小化响应面加点准则的 Kriging 代理模型, 且该模型可以较好的应用于需要大规模 CFD 计算量的多目标工程优化设计问题, 提高优化效率.

3) 优化后 CRH380A 三辆编组简化外形的整车气动阻力减小 3.20%, 摩擦阻力基本不变, 压差阻力减小 10.02%, 尾车气动升力减小 8.24%, 车体流线型部分体积减小 2.16%, 真实外形的整车气动阻力减小 2.26%, 摩擦阻力基本不变, 压差阻力减小 3.78%, 尾车气动升力减小 19.67%, 两种外形的气动力变化主要集中在鼻锥和尾锥的变形区域; 简化外形与真实外形的优化结果有所不同, 但趋势相同, 且均能反映出气动外形的变化对列车气动力的影响.

4) 附属部件对列车的气动性能的影响较大, 车体连接处对每节车厢的气动力分布影响很大, 但对




图 13 构建好的 Kriging 代理模型的 θ_k 值的相对值

整车气动阻力影响不大, 尾车的气动升力是由于沿车体向外的拉力引起的, 附属部件均表现出指向地面的拉力, 尾锥表现出垂直于地面向上的拉力.

5) 优化外形在横风条件下的气动性能也有较大

幅度的提高, 整车气动阻力减小 2.24%, 其中, 压差阻力减小 3.02%, 摩擦阻力基本不变, 尾车气动升力减小 10.27%; 与无横风条件下的提高幅度趋势一致, 优化外形具有一定的设计稳健性.

参考文献

- 1 Raghathan S, Kim H D, Setoguchi T. Aerodynamics of high-speed railway train. *Progr Aerosp Sci*, 2002, 8(6): 469–514
- 2 Baker C. The flow around high speed trains. *J Wind Eng Indus Aerodyn*, 2010, 98(6-7): 277–298
- 3 Tian H Q. Formation mechanism of aerodynamic drag of high-speed train and some reduction measures. *J Cent South Univ Technol*, 2009, 16: 166–171
- 4 Tian H Q. *Train Aerodynamics*. Beijing: China Railway Publishing House, 2007. 160–161
- 5 Ku Y C, Kwak M H, Park H I, et al. Multi-objective optimization of high-speed train nose shape using the vehicle modeling function. In: 48th AIAA Aerospace Sciences Meeting, 2010, Orlando, USA
- 6 Sun Z X, Song J J, An Y R. Optimization of the head shape of the CRH3 high speed train. *Sci China Tech Sci*, 2010, 12: 3356–3364
- 7 Ku Y C, Rho J H, Su-Hwan, et al. Optimal cross-sectional area distribution of a high-speed train nose to minimize the tunnel micro-pressure wave. *Struct Multidisc Optim*, 2010, 42: 965–976
- 8 Lee J S, Kim J H. Approximate optimization of high-speed train nose shape for reducing micropressure wave. *Indust Appl*, 2008, 35: 79–87
- 9 Kwon H B, Jang K H, Kim Y S, et al. Nose shape optimization of high-speed train for minimization of tunnel sonic boom. *Jpn Soc Mech Eng*, 2001, 4: 890–899
- 10 Lida M, Matsumura T, Nakatani K, et al. Effective nose shape for reducing tunnel sonic boom. *QR of RTRI*, 1997, 38(4): 206–211
- 11 Noel C. The origins of Kriging. *Math Geol*, 1990, 22(3): 239–252
- 12 Donald R J, Matthias S, William J W. Efficient global optimization of expensive black-box functions. *J Global Optim*, 1998, 13: 455–492
- 13 Donald R J. A taxonomy of global optimization methods based on response surfaces. *J Global Optim*, 2001, 21: 345–383
- 14 Gao Y H, Wang X C. An effective warpage optimization method in injection molding based on kriging model. *Int J Adv Manuf Technol*, 2008, 37(9): 953–960
- 15 Koehler J R, Owen A B. Computer experiments. In: Ghosh S, Rao C R, eds. *Handbook of Statistics*. New York: Elsevier Science, 1996. 261–308
- 16 Welch W J, Yu T K, Kang S M, et al. Computer experiments for quality control by parameter design. *J Qual Technol*, 1990, 22(1): 15–22
- 17 Jamshid A S. Aerodynamic shape optimization based on free-form deformation. AIAA 2004–4630, 2004
- 18 Kulfan B M, Bussoletti J E. Fundamental parametric geometry representations for aircraft component shapes. In: 11th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference, Portsmouth, VA, 2006. 1–42
- 19 Rho J H, Ku Y C, Yun S H, et al. Development of vehicle modeling function for 3-dimensional shape optimization. *J Mech Design*, 2009, 131(12): 121004-1–121004-10
- 20 Blazek J. *Computational Fluid Dynamics Principles and Applications*. Oxford: Elsevier Ltd., 2005. 16–17
- 21 Pratab A, Deb K. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. Kan-GAL report 200001, Indian Institute of Technology, Kanpur, India, 2000
- 22 Yang G W, Chen D W, Cui K. Response surface technique for static aeroelastic optimization on a high-aspect-ratio wing. *J Aircr*, 2009, 46(4): 1444–1450
- 23 Srinivas M, Patnaik L M. Adaptive probabilities of crossover and mutations in GAs. *IEEE T SMC*, 1994, 24(4): 656–667
- 24 Roshan V J. Orthogonal-maximin Latin hypercubes designs. *Stat Sin*, 2008, 18(1): 171–186
- 25 Grosso A. Finding maximin Latin hypercube designs by iterated local search heuristics. *Eur J Oper Res*, 2009, 197(2): 541–547
- 26 Eziol T. Influence of parameter estimation uncertainty in Kriging part I-theoretical development. *Hydrol Earth Syst Sci*, 2001, 5(2): 215–223
- 27 Lophaven S N, Nielsen H B, Sondergaard J. DACE-A Matlab Kriging toolbox, version 2.0. <http://www.imm.dtu.dk/~hbn/pub1/TR0212.ps>