

基于 GA-GRNN 的高速列车头型三维优化设计

姚拴宝*, 郭迪龙, 杨国伟

中国科学院力学研究所, 水动力学与海洋工程重点实验室, 北京 100190

* E-mail: ysbao566@163.com

收稿日期: 2012-01-13; 接受日期: 2012-05-11

国家科技支撑计划项目(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

摘要 针对 CRH380A 型高速列车头部外形的气动减阻问题, 设计了一种新型的基于自由曲面变形的局部型函数参数化方法, 提出了一套基于实数编码遗传算法的变光滑因子广义回归神经网络响应面模型(GA-GRNN)的气动外形优化方法. 优化结果表明: 局部型函数参数化方法操作简单、实现方便, 使用少量的设计参数可以控制较大变形区域, 且能保证变形的平顺性和不同变形区域间的光滑过渡; 使用同样的样本点进行训练, GA-GRNN 比 GRNN 的预测精度高, 更容易得到全局最优解; 优化后, CRH380A 三辆编组简化外形气动阻力减小 8.7%, 本文提出的优化设计方法简单、高效, 为高速列车气动外形的工程优化设计提供了新思路.

关键词
气动阻力
GA-GRNN
参数化
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, 其空气阻力特性变得更为复杂^[1-3], 而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]. 可见, 气动减阻问题十分突出, 成为高速列车头型优化的关键问题之一. 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优化设计方法的文献比较少, 已有的研究成果大都针对列车的二维型线或使用效率较低的优化算法, 很难应用到大规模、多参数的工程实际问题中. 文献[5]提出了结合遗传算法和任意网格变形技术的优化方法, 在设计参数较少的情况下, 这种方法能在一定程度上减少流场计算次数, 缩短设计周期, 找到几个设计参数与优化目标之间的非线性关系, 但是当设计参数的数量增加时, 这种方法需要的 CFD 计算量成几何级数上升, 在工程上难以

英文版发表信息: Yao S B, Guo D L, Yang G W. Three-dimensional aerodynamic optimization design of high-speed train nose based on GA-GRNN. Sci China Tech Sci, 2012, 55: 3118-3130, doi: 10.1007/s11431-012-4934-2

忍受. 文献[6-8]针对列车纵剖面型线, 以减小微气压波为目标, 进行了列车气动外形的优化设计, 其中, 文献[6]提出了一种可用于模式分类和非线性回归的支持向量机响应面模型与连续二次规划方法相结合的优化方法, 这种方法需要选取一定数量的样本点训练支持向量机模型, 使其达到要求的拟合精度, 然后以训练好的模型为基础, 使用连续二次规划优化算法寻找最优目标值. 样本点的选取对支持向量机模型的构造极为重要, 少量的样本点训练的模型很难达到要求的精度, 文献[6]中的设计变量为 9 个, 选取了 100 样本点, 至少需要计算 100 次流场, 可见, 这种方法的计算量仍然偏大. 本文在上述文献工作的基础上, 首先针对高速列车流线型外形, 设计了一种基于自由曲面变形的局部型函数参数化方法; 然后以减少高速列车气动阻力和 CFD 计算量为目标, 提取 5 个关键设计变量, 初始试验设计出 16 个样本点, 使用交叉验证方法设计出了用于寻找最优光滑因子的目标函数, 使用最小化响应面加点准则逐渐增加训练样本点的数量, 经过 4 次加点, 构造出了满足工程精度要求的基于遗传算法的变光滑因子广义回归神经网络响应面(General Regression Neural Network Based on Genetic Algorithm, GA-GRNN), 结合基于实数编码的遗传优化算法, 提出了一套更为高效的气动外形优化设计方法, 使用该方法得到了 CRH380A 三辆编组简化外形的优化外形, 并将优化外形改造成真实外形与 CRH380A 三辆编组真实外形的气动阻力进行了对比分析.

1 GA-GRNN 响应面模型

经典广义回归神经网络是径向基神经网络的一种, 建立在数理统计的基础上, 不需要事先确定方程形式, 以概率密度函数替代固有的方程形式, 具有很强的非线性映射能力和柔性网络结构以及高度的容错性和鲁棒性, 即使样本数量稀少, 网络的输出结果也能收敛于最优回归面, 适用于解决非线性问题. GRNN 将各个神经元的光滑因子 σ 设置为同一个值, 网络的训练过程是对光滑因子的单值寻优过程, 没有考虑不同光滑因子对输出结果的影响, 在一定程度上降低了网络的预测精度. 本文将每个神经元的光滑因子作为一个独立的变量, 根据不同神经元对输出结果的影响程度不同, 使用遗传算法寻找每个

神经元对应的最优光滑因子值, 构造出 GA-GRNN 模型, 消除了使用同一个光滑因子对网络预测精度的影响.

GRNN 的理论基础^[9-12]是非线性回归分析, 设随机向量 \mathbf{x} 和随机变量 y 的联合概率密度函数为 $f(\mathbf{x}, y)$, \mathbf{x} 的取值为 \mathbf{x}_0 , y 对 \mathbf{x}_0 的回归值为

$$E(y / \mathbf{x}_0) = \hat{y}(\mathbf{x}_0) = \frac{\int_{-\infty}^{+\infty} y f(\mathbf{x}_0, y) dy}{\int_{-\infty}^{+\infty} f(\mathbf{x}_0, y) dy}. \quad (1)$$

应用 Parzen 非参数估计, 可由样本数据集 $\{\mathbf{x}_i, y_i\}_{i=1}^n$ 按 (2) 式估算密度函数 $f(\mathbf{x}_0, y)$,

$$f(\mathbf{x}_0, y) = \frac{1}{n(2\pi)^{\frac{p+1}{2}} \prod_{i=1}^n \sigma_i^{p+1}} \sum_{i=1}^n e^{-d(\mathbf{x}_0, \mathbf{x}_i)} e^{-d(y, y_i)}, \quad (2)$$

其中 $d(\mathbf{x}_0, \mathbf{x}_i) = \sum_{j=1}^p [(x_{0j} - x_{ij}) / \sigma_j]^2$, $d(y, y_i) = [y - y_i]^2$,

n 为样本容量, p 为 \mathbf{x} 的维数, σ_i 为每个神经元的高斯函数的宽度系数, 即为光滑因子. 当 σ_i 相同时, 构造的模型为 GRNN, 当 σ_i 不同时, 构造的模型为 GA-GRNN^[9].

将 (2) 式代入 (1) 式, 并交换积分与求和的顺序, 将有

$$\hat{y}(\mathbf{x}_0) = \frac{\sum_{i=1}^n \left(e^{-d(\mathbf{x}_0, \mathbf{x}_i)} \int_{-\infty}^{+\infty} y e^{-d(y, y_i)} dy \right)}{\sum_{i=1}^n \left(e^{-d(\mathbf{x}_0, \mathbf{x}_i)} \int_{-\infty}^{+\infty} e^{-d(y, y_i)} dy \right)}. \quad (3)$$

由于 $\int_{-\infty}^{+\infty} z e^{-z^2} dz = 0$, 故对 (3) 式的两个积分进行计算后可得

$$\hat{y}(\mathbf{x}_0) = \frac{\sum_{i=1}^n y_i e^{-d(\mathbf{x}_0, \mathbf{x}_i)}}{\sum_{i=1}^n e^{-d(\mathbf{x}_0, \mathbf{x}_i)}}. \quad (4)$$

可见, (4) 式的预测值 $\hat{y}(\mathbf{x}_0)$ 为所有训练样本的因变量值 y_i 的加权值, 其权重为 $e^{-d(\mathbf{x}_0, \mathbf{x}_i)}$.

GA-GRNN 由 4 层网络构成, 分别为输入层、模式层、求和层和输出层, 如图 1 所示. 输入层各单元是简单的线性单元, 每个单元对应一个样本点. 模式层的每个单元以高斯函数 $e^{-d(\mathbf{x}_0, \mathbf{x}_i)}$ 为活化核函数, \mathbf{x}_i 为各单元核函数的中心矢量, σ_i 为各单元的光滑因子, 共有 n 个单元. 求和层有两个单元, 一个单元计算模




图1 GA-GRNN 结构示意图

式层各单元输出的加权和, 权值为各训练样本的 y_i , 称为分子单元, 另一个单元计算模式层各单元的输出之和, 称为分母单元. 输出层是将求和层的分子和分母单元的输出相除, 计算得到 y 的估计值, 即预测值.

2 局部型函数参数化方法

2.1 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.

CRH380A 三辆编组车型的几何参数: 头车、中间车和尾车长度均为 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 m^2 , 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 2 所示.

2.2 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. 目前常用的三维曲面参数化方法有: 基于曲面的自由变形法、样条曲面法、网格点法等. 网格点法虽然可以描述任意外形, 但较容




图2 CRH380A 三辆编组简化外形的几何参数

易产生非流线型型面, 从而导致病态流动, 而且对设计变量的数量和网格点梯度求解要求苛刻; 自由变形法^[13]和样条曲面法是性能良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. 本文借鉴自由变形法和样条曲面法的基本思想, 设计了一种局部型函数曲面参数化方法.

实现步骤为:

- 1) 对于给定的几何外形, 划分出需要变形的区域;
- 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;
- 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;
- 4) 为每个型函数设置一个权重因子 W_i , W_i 的值决定曲面的最大变形量;
- 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, 得到变形后外形的坐标值;
- 7) 根据变形后外形的坐标值重新拟合出变形后的曲面, 完成一次变形.

步骤 3) 是参数化过程的核心, 不同的变形函数会产生完全不同的变形, 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 5 个变形区域, 如图 3 所示. 鼻锥区域控制鼻锥处的引流, 设置一个控制点 Point1, 提取两个设计参数, 分别是鼻锥长度 W_1 , 鼻锥高度 W_2 ; 过

渡区、司机室区域和底部侧板共同控制车体宽度, 提取一个设计参数为控制点 Point2 沿车宽方向的坐标值 W_3 ; 司机室区域控制司机室的视角, 提取一个设计参数为控制点 Point3 沿车高方向的坐标 W_4 ; 排障器区域控制鼻锥底部导流, 提取一个设计参数为控制点 Point4 沿车长方向的坐标 W_5 . 为便于操作, 本文所有变形区域均使用的变形函数为三角函数, 图 4 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

3.1 CFD 流场计算方法

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心格式有限体积法的三维定常可压缩雷诺平均 N-S 方程^[14], 空间离散格式采用 Roe 格式, 时间离




图 3 头车流线型部分的变形区域和控制点



图 4 鼻锥处和排障器处的变形

散采用 LU-SGS 离散方法, 湍流模型采用 $k-\omega$ SST 模型^[15], 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。

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 $1L$, 宽度取 $2L$, 如图 5 所示. 来流速度为 $V=83.333$ m/s, 远场压力取为 1 个大气压, 温度取为 $T_\infty=288$ 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 Riemann 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。

3.2 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, 共划分了四套网格, 网格量分别为 840, 1030, 1270 和 4490 万. 空间网格的整体分布及局部分布如图 6 所示。

四套网格的计算结果如图 7 所示, 可以看出, 网格量的不同对计算结果的影响并不明显, 各节车阻力系数变化很小, 整车的阻力系数的变化均在 1% 以内, 而且压差阻力与摩擦阻力的浮动也很小, 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 840 万量级的网格。

4 GA-GRNN 响应面的构造及精度分析

4.1 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




图 5 CFD 流场计算域




图6 空间网格的整体分布和局部分布图




图7 不同网格量时的流场计算结果

力为优化目标, 给定相应的约束条件, 在满足约束条件的情况下, 寻找使列车总气动阻力最小的最优设计参数值. 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: 鼻锥长度: $0 \leq W_1 \leq 83.333$, 鼻锥高度: $-15 \leq W_2 \leq 10$, 车体宽度: $-30 \leq W_3 \leq 0$, 司机室视角: $-10 \leq W_4 \leq 4$, 排障器外形: $-60 \leq W_5 \leq 10$. 考虑到鼻锥长度和车体宽度对列车气动阻力的影响, 鼻锥长度的最小边界设置为初始外形的尺寸, 而车体宽度的最大边界设置为初始外形的尺寸. 为较好的表达设计空间与优化目标之间的关系, 样本点的选取至关重要; Sobol 采样方法^[16]是一种伪随机算法, 相对于随机采样方法, 其生成的初始样本点在设计空间分布的更为均匀, 因此, 本文使用该方法作为采样方法. 初始设计样本点为 16 个, 选取前 14 个作为训练样本点, 其余 2 个作为测试样本点, 如表 1 所示, 可以看

出, 设计点的 Cd 值均好于初始外形的 Cd 值, 主要反映了设计空间的选取情况, 在一个存在较多优化解的设计空间内寻找最优解, 不仅可以减少设计样本点的数量, 也有利于使用相同数量的样本点构造出精度更高的响应面模型, 在较短的时间内得到全局最优解.

4.2 遗传算法效率验证

GA-GRNN 的训练过程是使用基于实数编码的遗传优化算法对各神经元光滑因子 σ_i 的多参数寻优过程. 为了验证遗传算法的全局寻优能力, 本文选用 Shaffer's F_2 函数作为测试函数, 其表达式为

$$F_2 = 0.5 - \frac{\sin^2 \sqrt{x_1^2 + x_2^2} - 0.5}{(1 + 0.001(x_1^2 + x_2^2))^2},$$

$$-10.0 < x_1 < 10.0, -10.0 < x_2 < 10.0.$$

此函数有无限个局部极大值点, 只有在 $(x_1, x_2) = (0.0, 0.0)$ 处, 有全局最大值 $F_2(x_1, x_2) = 10$. 使用基于实数编码的遗传算法, 初始种群 $n_p = 150$, 选择算子使用轮盘赌法, 交叉概率 $p_c = 0.6$, 变异概率 $p_m = 0.3$, 进化代数为 100 代. 适应度函数设计为 $f = 1/F_2(x_1, x_2)$. 遗传寻优得到的最优值为 $F_2(x_1, x_2) = 1.0000$, 此时 $(x_1^*, x_2^*) = (0.0001, 0.0001)$, 从图 8 中可以看出, 平均适应度值可以较快的收敛到全局最优解, 可见本文设计的遗传算法具有较强的全局寻优能力.

4.3 GA-GRNN 的构造及精度分析

由于初始训练样本点只有 14 个, 为充分利用每个样本点的信息, 本文将遗传算法与交叉验证方法相结合对神经网络进行训练. 对于初始的 14 个样本点, 以每个训练样本点为一个小组, 共有 14 组, 选取其中 13 组作为训练样本点, 其余一组作为检验样本点, 依次循环, 使每组样本点都有一次作为检验样本点. 将所有检验样本点的相对误差的平均值作为遗传算法的目标函数值进行寻优.

对于 GRNN 响应面模型, 所有的光滑因子取相同的值, 属于单值寻优过程, 而对于 GA-GRNN 响应面模型, 由于每个训练样本点对应一个神经元, 故由 13 个训练样本点构造的 GA-GRNN 有 13 个神经元, 也就需要对 13 个光滑因子 $\sigma_i (i = 1, \dots, 13)$ 进行寻优. 使用初始给出的训练样本点难以构造出满足精度要求的响应面模型, 为此, 使用最小响应面加点准则^[17],

表 1 训练样本点与测试样本点

Type of sample points	W_1 (mm)	W_2 (mm)	W_3 (mm)	W_4 (mm)	W_5 (mm)	Cd	
Training points	1	0.000	0.000	0.000	0.000	0.000	0.15091
	2	-41.667	-2.500	-15.000	-3.000	-25.000	0.14411
	3	-62.500	-8.750	-22.500	-6.500	-42.500	0.14034
	4	-20.833	3.750	-7.500	0.500	-7.500	0.14822
	5	-52.083	0.625	-18.750	-4.750	-33.750	0.14265
	6	-10.417	-11.875	-3.750	2.250	1.250	0.14797
	7	-72.916	6.875	-26.250	-8.250	-51.250	0.13992
	8	-31.250	-5.625	-11.250	-1.250	-16.250	0.14533
	9	-57.291	8.438	-1.875	-2.125	-3.125	0.15014
	10	-15.625	-4.063	-16.875	-9.125	-38.125	0.14241
	11	-78.125	2.188	-9.375	1.375	-20.625	0.14638
	12	-36.458	-10.313	-24.375	-5.625	-55.625	0.13923
	13	-67.708	-7.188	-13.125	3.125	-11.875	0.14505
	14	-26.042	5.313	-28.125	-3.875	-46.875	0.13965
Test points	15	-46.875	-13.438	-5.625	-0.375	5.625	0.14675
	16	-5.208	-0.938	-20.625	-7.375	-29.375	0.14202




图 8 测试函数平均适应度值随着进化代数的收敛曲线

将基于初始构造的响应面模型得到的最优解加入训练样本集中, 从而在尽量不影响设计空间内整体预测精度的条件下最大限度的提高最优解附近区域的预测精度。

GRNN 响应面模型构造过程中寻找光滑因子最优值的遗传算法参数设置为: 初始种群 $n_p=60$, 选择算子使用轮盘赌法, 交叉概率 $p_c=0.9$, 变异概率 $p_m=0.2$, 进化代数为 650 代; 寻找最优设计点的遗传算法参数设置为: 初始种群 $n_p=50$, 选择算子使用轮盘赌法, 交叉概率 $p_c=0.9$, 变异概率 $p_m=0.5$, 进化代数为 2500 代. GA-GRNN 响应面模型构造过程中寻找光滑因子最优值的遗传算法参数设置为: 初始种群 $n_p=60$, 选择算子使用轮盘赌法, 交叉概率 $p_c=0.95$, 变异概率 $p_m=0.3$, 进化代数为 500 代; 寻找最优设计点的遗传算法参数设置为: 初始种群 $n_p=40$, 选择算子使用轮盘赌法, 交叉概率 $p_c=0.9$, 变异概率 $p_m=0.2$, 进化代数为 500 代。

图 9 给出了 GRNN 和 GA-GRNN 的预测误差随

着迭代次数的变化情况, 可以看出: 随着训练样本点数量的增加, 两种模型在最优解附近区域的预测精度逐渐提高, GRNN 在设计空间内其他区域的预测精度基本不变, GA-GRNN 在设计空间内其他区域的预测精度略有提高; GA-GRNN 的预测精度明显好于 GRNN 的预测精度, 经过 12 次加点, GRNN 在最优解区域的预测精度仍然高于 1%, 而 GA-GRNN 仅加了两个点, 其预测精度就减小到了 1% 以内, 可以较好的映射设计参数与优化目标之间的非线性关系, 因此, 本文使用 GA-GRNN 模型寻找最优解。

4.4 头型气动优化流程

本文设计的整体优化流程如图 10 所示, 首先使用 Sobal 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 GA-GRNN 模型; 在得到了满足一定精度的响应面模型之后, 再次调用遗传算法对设计参数值进行寻优, 得到优化解之后, 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, 将得到的优化解添加到训练样本中, 对 GA-GRNN 进行新一轮的训练, 从而使 GA-GRNN 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 GA-GRNN 和遗传算法在设计空间寻优, 得到设计空间内的全局最优解. 在整个优化流程中, CFD 流场计算是基础, GA-GRNN 的构造和预测精度是核心, 其

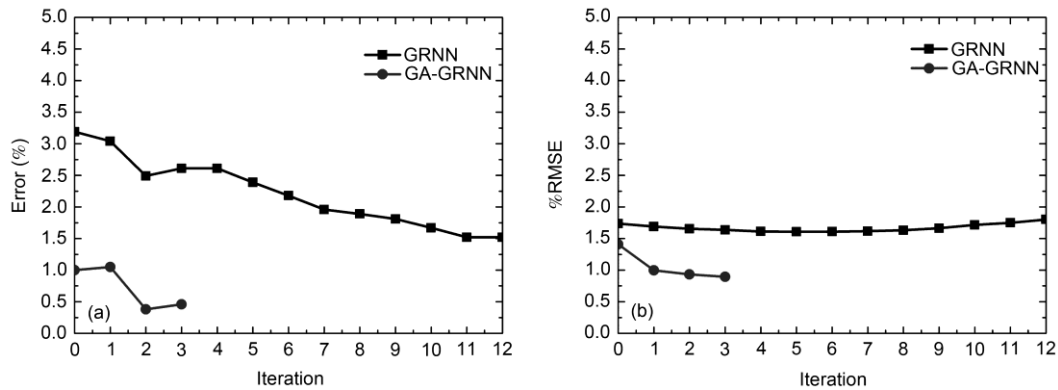


图9 (a) GRNN 和 GA-GRNN 预测最优值与真实值之间的相对误差; (b) GRNN 和 GA-GRNN 对测试样本点的预测值与真实值的平均误差($\%RMSE = 100 \sqrt{\frac{1}{n_s} \sum_{i=1}^{n_s} (y_i - y_i^{(p)})^2} / \frac{1}{n_s} \sum_{i=1}^{n_s} y_i}$, 其中 n_s 为测试样本点数, y_i 为准确值, $y_i^{(p)}$ 为预测值)

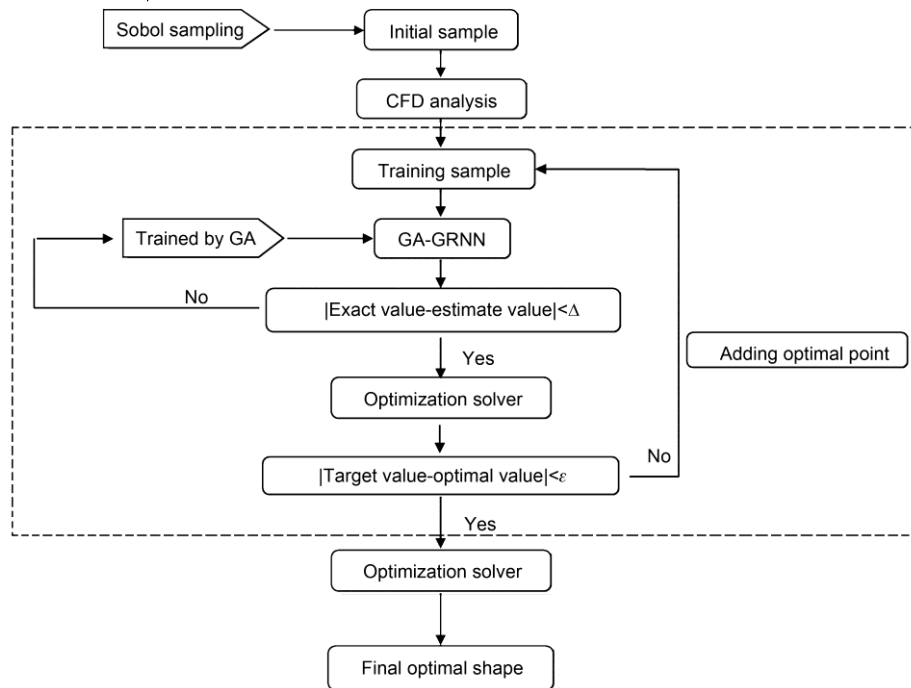


图10 高速列车气动头型优化流程

所需的样本点数量直接关系到流场计算次数, 使用尽可能少的样本点构造出预测精度尽可能高的 GA-GRNN 是本文的核心工作, 而基于实数编码的遗传算法是寻找全局最优解的基本手段, 贯穿于整个优化流程.

5 结果与分析

5.1 优化外形与原始外形的对比分析

以 CRH380A 三辆编组简化外形总气动阻力系数 C_d 为优化目标, 适应度函数取为 $f=C_d$. 初始种群

$n_p=40$, 选择算子使用轮盘赌法, 交叉概率为 $p_c=0.9$, 变异概率为 $p_m=0.2$, 进化代数 500 代. 图 11 给出了优化目标的平均值随进化代数的收敛曲线, 平均适应度值较快的收敛到了一个稳定值.

表 2 给出了 GA-GRNN 响应面模型的预测值与 CFD 计算结果, 预测误差仅为 0.38%, 进一步说明本文构造的响应面模型是可行的.

由于 CRH380A 三辆编组简化外形没有考虑转向架、风挡、受电弓等列车附属部件, 导致列车的压差阻力小于摩擦阻力. 表 3 给出了 CRH380A 三辆编组




图 11 平均适应度值随进化代数的收敛曲线

表 2 GA-GRNN 得到的优化真实值与预测值

Actual value	GA-GRNN	Prediction error
0.13778	0.13831	0.38%

简化外形的原始外形与优化外形的阻力系数分布, 可以看出: 摩擦阻力基本不变, 压差阻力减幅达到了 53.85%; 中间车阻力系数基本不变, 头车和尾车阻力减小幅度基本相同, 而且减小的均为压差阻力, 摩擦阻力基本不变, 可见, 压差阻力对列车气动外形的变化更为敏感, 是气动减阻的主要目标。

优化后, 头车流线型部分长度增长了 0.436 m, 鼻锥高度下降 0.178 m, 流线型部分车体宽度最大减幅为 0.715 m, 司机室玻璃的倾角减小了 0.95°, 排障器底部顶点位置后移了 0.716 m。优化外形与原始的对比如图 12 所示。

优化前, 头尾车的摩擦阻力分别为: 0.04593, 0.03851, 压差阻力分别为: 0.01061, 0.01088; 优化后, 头尾车的摩擦阻力分别为: 0.04503, 0.0375, 压差阻力分别为: 0.00424, 0.00567。可以看到, 优化前后头尾车的摩擦阻力变化很小, 优化后, 头车压差阻力减

小了 60.03%, 尾车压差阻力减小了 47.89%。图 13 给出了 CRH380A 原始外形与优化外形的表面压力分布, 纵剖面速度分布和中轴线的速度型, 可以看出: 优化后, 列车顶部边界层的发展基本不变, 但鼻锥和尾锥处流场有明显的不同。由于鼻锥变尖, 导致鼻锥处的高压区域减小, 司机室倾角的减小致使过渡区的气流变化更为平稳; 尾锥的变尖、变长导致尾流的分离趋于平缓, 尾流场的混乱程度降低, 促使列车前后端压力梯度减小, 头尾车压差阻力减小。

从图 14 可以看出, 优化后, 排障器形状由前倾变为后倾, 排障器处的小涡 Vc1 和 Vc2 在优化后只存在 Vc2, 且 Vc2 的强度有所减弱。排障器与车体底部的光滑过渡减小了对此处流场的扰动, 气流加速过程变的更为平稳, 从而使排障器处高压区明显减弱, 在一定程度上减小了列车前后的压差, 使头车压差阻力减小。

图 15 给出了 CRH380A 优化前后尾锥处的涡核变化情况, 可以看出: 尾锥鼻锥处发展出两个定常涡 Vc1 和 Vc2, 在排障器处脱出另外两个强度更大的定

表 3 CRH380A 原始外形与优化外形的阻力系数及减阻百分比

	Total	Viscid	Inviscid	Head	Middle	Tail
Original shape	0.15091	0.12937	0.02154	0.05654	0.04498	0.04939
Optimal shape	0.13778	0.12784	0.00994	0.04927	0.04534	0.04317
Drag reduction	8.7%	1.18%	53.28%	12.86%	-0.8%	12.59%




图 12 CRH380A 原始外形与优化外形

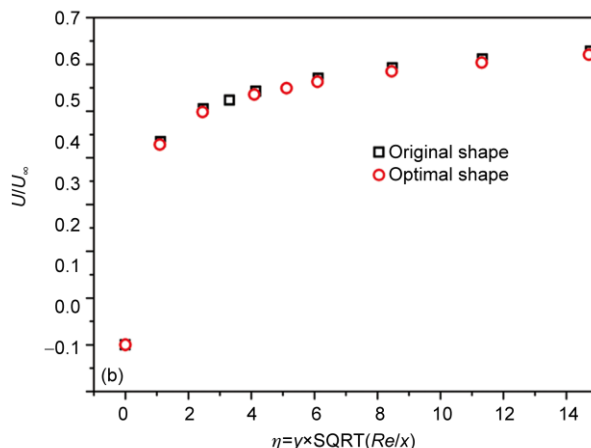



图 13 (a)CRH380A 原始外形与优化外形的表面压力云图和纵剖面速度云图; (b)列车中轴线的速度型

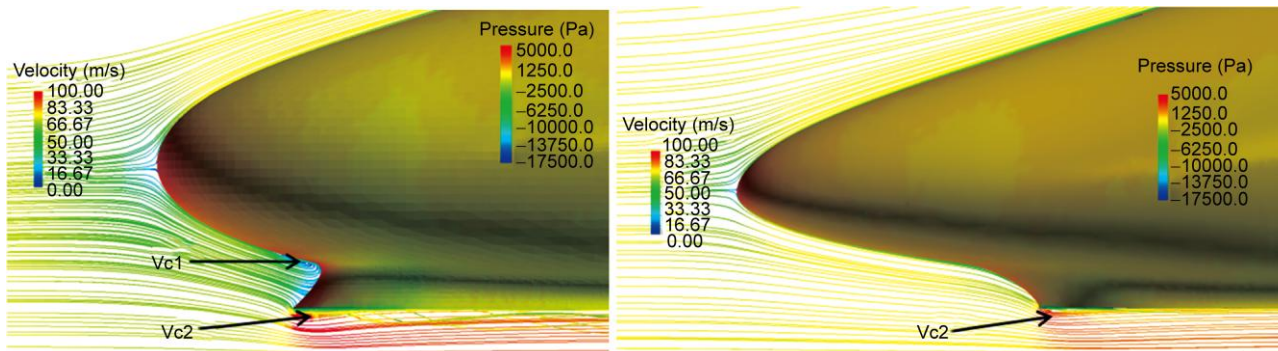


图 14 CRH380A 原始外形与优化外形鼻锥处的表面压力云图和流线图

常涡 $Vc3$ 和 $Vc4$, 这些涡的强度决定了尾锥区域的负压强度. 头型优化之后, 尾锥处的四个涡 $Vc1$, $Vc2$, $Vc3$ 和 $Vc4$ 的强度明显减小, 从而导致尾流区的负压减弱, 列车前后压差减小, 压差阻力也就随着减小.

图 16 给出了 CRH380A 原始外形与优化外形头尾车的纵剖面型线压力系数分布, 可以看出, 优化前后车身直线段表面压力系数变化很小; 优化后, 头尾车排障器处的压力系数变化最为明显. 头车排障器区域的正压减小, 尾车排障器区域的负压减小, 从而使头尾车压差减小, 气动压差阻力减小.

当列车车厢最大横截面积一定时, 流线型部分的截面变化率不仅关系到鼻部和司机室内部容积的分布, 而且影响到鼻锥处流场的变化. 图 17 给出了 CRH380A 原始外形与优化外形截面变化率的变化曲线, 图中 L 为流线型部分的长度, A_{ref} 为列车的最大横截面积; 可以看出: 优化外形流线型部分的截面积比原始外形的截面积有较大的缩减, 导致鼻部区域的迎风面积减小, 在一定程度上减弱了头部的高压

区; 鼻锥引流区域和司机室区域的截面变化更加平缓, 而在流线型部分与直线段车厢连接区域的截面变化较为剧烈, 使得来流在鼻部前端有一个均匀加速的过程, 减少了外形对气流的扰动, 在过渡区气流速度迅速增加, 导致该区域出现一个较大的低压区, 进一步减小头车前后端的压差, 压差阻力随之减小.

5.2 CRH380A 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的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)进行了简化, 舍弃了列车的附属部件. 然而, 附属部件对真实外形的气动阻力有很大影响^[2], 为进一步研究优化外形的减阻效率, 本文将对 CRH380A 真实外形的原型车与优化车进行对比分析.

为了与风洞试验数据进行比较, 将计算条件设置的与风洞试验条件相同, 计算模型与试验模型完全相同, 为 1:8 缩比模型. 流场计算采用压力耦合方程组的




图 15 CRH380A 原始外形与优化外形尾锥处 $Q=100$ 的等值面图

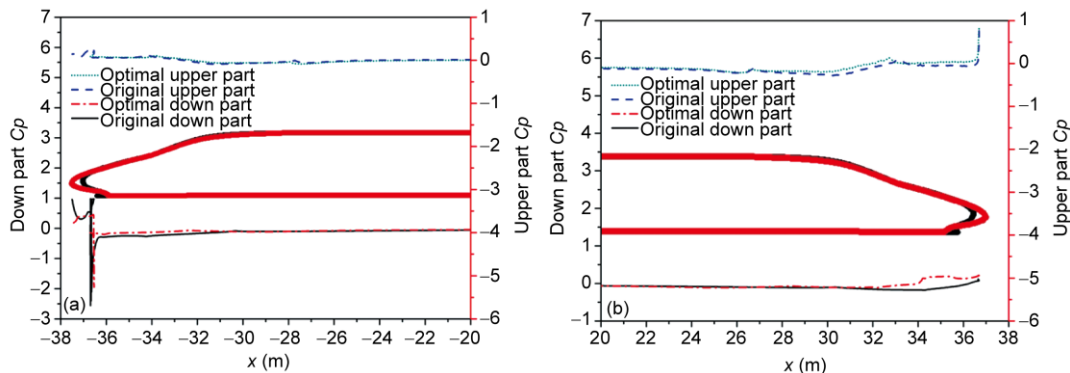


图 16 CRH380A 原始外形与优化外形头尾车纵剖面型线压力系数分布

(a) 头车纵剖面型线压力系数分布; (b) 尾车纵剖面型线压力系数分布

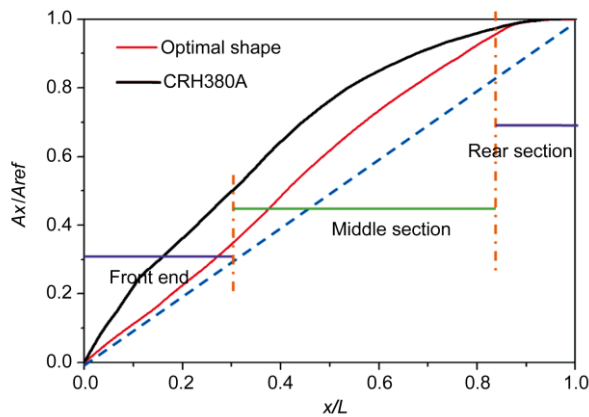


图 17 CRH380A 原始外形与优化外形截面变化率

半隐式方法(SIMPLE 算法), 湍流模型采用 $k-\omega$ SST 模型, 车体壁面处使用了标准壁面函数. 来流速度为 60 m/s, 地面为静止壁面, 进口为速度入口边界, 出口为压力出口边界, 远场为滑移壁面. 空间网格为任意多面体网格, 车体表面布置了三棱柱边界层网格, 整体网格量为 2840 万, 局部网格划分如图 18 所示.

表 4 给出了 CRH380A 真实外形优化前后的气动

阻力分布, 可以看出: 真实外形的压差阻力略大于摩擦阻力, 整车气动阻力数值计算结果与风洞试验数据误差不到 1%, 说明数值计算结果可靠. 优化后, 三辆编组真实外形整车减阻 8.86%, 摩擦阻力基本不变, 压差阻力减幅较大, 与简化外形减阻效率一致, 而且各节车气动阻力均比优化前小; 但是各节车的减阻效率与简化外形相比有较大差别, 尤其是中间车, 简化外形基本没有减阻, 而真实外形减阻达到了 12.55%, 考虑到中间车的气动阻力较小, 阻力减小的绝对值并不是很大. 图 19 给出了列车各部件的气动阻力分布, 由于气流在排障器处经过二次压缩, 以较大的速度流向头车第一个转向架, 从而导致该转向架处产生一个较大的高压区, 压差阻力比其它转向架的明显偏大; 为更细致的研究车体连接处对列车的气动阻力的分布影响, 将车体连接处分为前后两个部分, 分别为 shield1, shield2, shield3 和 shield4, 从图 14 可以看出: shield1 和 shield3 受到较大的推力, shield2 和 shield4 受到较大的阻力. shield2 和 shield3 是中间车的附属部件, 优化前, shield2 和 shield3 所受的气动阻力的代数和为 0.03227, 优化后, shield2 和




图 18 真实外形局部网格图

表 4 CRH380A 真实外形优化前后的气动阻力系数及减阻百分比

	Total	Viscid	Inviscid	Head	Middle	Tail
Wind tunnel test	0.32612	—	—	—	—	—
Original shape	0.32822	0.15088	0.17734	0.11519	0.0889	0.12413
Error	0.64%	—	—	—	—	—
Optimized shape	0.29914	0.14836	0.15078	0.10965	0.07774	0.11175
Drag reduction	8.86%	1.67%	14.98%	4.81%	12.55%	9.97%

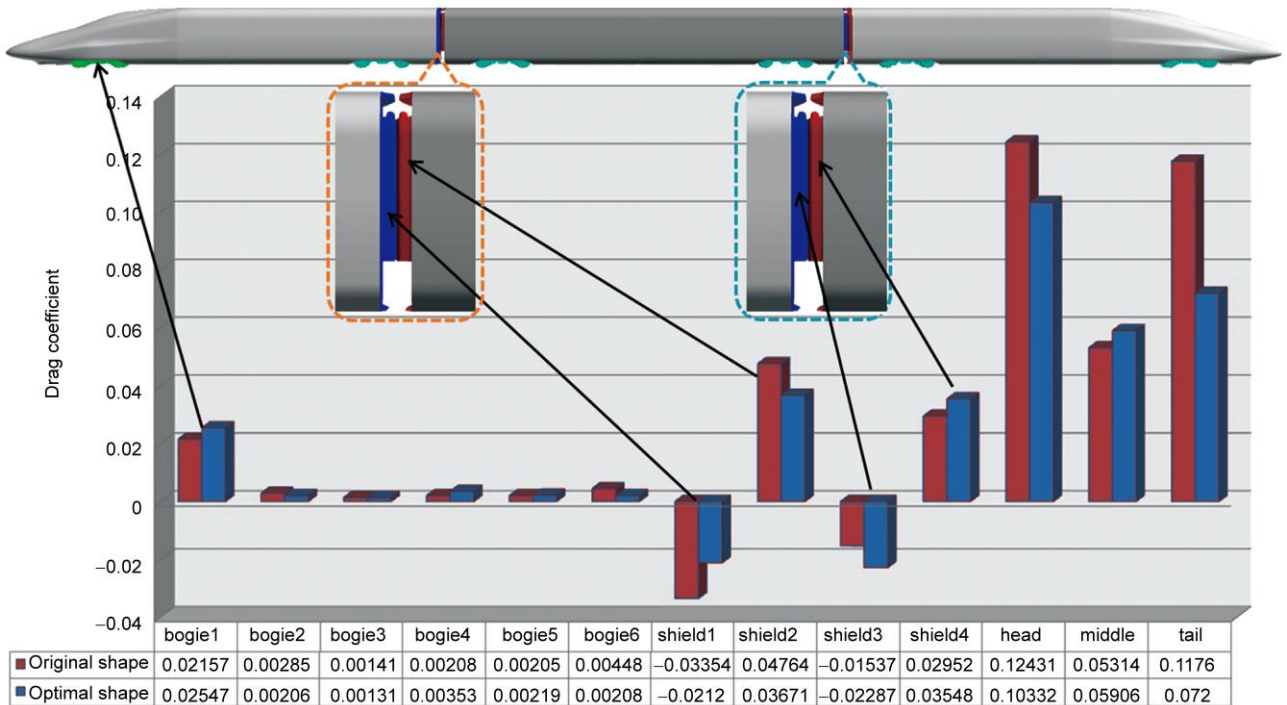


图 19 列车各部件气动阻力系数

shield3 所受的气动阻力的代数和为 0.01384, 而中间车其它部件的气动阻力变化不大, 导致中间车的气动阻力有所减小. 头车和尾车车身的气动阻力在优化后也有了较大幅度的减小, 而头尾车其他附属部件气动阻力变化不大. 可见, 附属部件对列车的气动阻力分布有较大影响, 但是简化外形在一定程度上能够反映真实外形的减阻效果, 而且可以明显提高优化效率, 因此, 合适的简化外形可以应用于高速列车的气动外形优化设计.

5.3 设计参数对高速列车气动阻力的影响

设计参数选取的是否合理直接影响到优化的最终结果, 图 20 给出了本文选用的设计参数对高速列车气动阻力变化梯度的影响系数, 可以看出: 控制鼻锥长度的参数 W_1 对目标函数梯度的影响最小, 这是因为 CRH380A 原始外形的细长比已经达到了 3.55, 更大的细长比对气动减阻的效果不在那么明显, 因此, 不能为了减小气动阻力而一味的增大列车的细




图 20 设计参数对目标函数梯度的影响系数

长比; 其他 4 个设计参数对目标函数梯度的影响都比较大, 列车流线型部分的宽度控制着该部分的横截面积, 进而影响到列车的截面变化率, 而控制车头流线型部分宽度的设计参数 W_3 对列车气动阻力的影响最大, 表明截面变化率的改变对列车的气动减阻至关重要. 设计参数 W_5 控制排障器的外形, 对列车气动阻力的影响很大, 目前, 国内外高速列车的排障器均设计为前倾型, 本文优化结果表明, 后倾型排障器更有利于气动减阻, 因此, 在不影响排障器功能的情况下, 为提高高速列车的气动性能, 排障器的设计可以考虑使用后倾型排障器.

本文提取的所有设计参数对目标函数值的梯度均有影响, 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, 而且相应的参数化方法可以较好的应用于高速列车的头型优化设计.

参考文献

- Raghuathan S, Kim H D, Setoguchi T. Aerodynamics of high-speed railway train. *Prog Aerosp Sci*, 2002, 8: 469-514
- Baker C. The flow around high speed trains. *J Wind Eng Industr Aerodynam*, 2010, 98: 277-298
- Tian H Q. Formation mechanism of aerodynamic drag of high-speed train and some reduction measures. *J Cent South Univ Technol*, 2009, 16: 0166-0171
- 田红旗. 列车空气动力学. 中国铁道出版社, 2007. 160-161
- 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
- Jongssoo L J K. Approximate optimization of high-speed train nose shape for reducing micropressure wave. *Industr Appl*, 2008, 35: 79-87
- Kwon H B, Jang K H, Kim Y S, et al. Nose shape optimization of high-speed train for minimization of tunnel sonic boom. *Japan Soc Mech Eng*, 2001, 4: 890-899
- Ku Y C, Rho J H, Su H W, et al. Optimal cross-sectional area distribution of a high-speed train nose to minimize the tunnel micro-pressure wave. *Struct Multid Optim*, 2010, 42: 965-976
- Lee S J, Kim B, Baik S W. Neural network modeling of inter-characteristics of silicon nitride film deposited by using a plasma-enhanced chemical vapor deposition. *Expert Syst Appl*, 2011, 38: 11437-11441
- Kim B, Kwon M, Kwon S H. Modeling of plasma process data using a multi-parameterized generalized regression neural network. *Microelectr Eng*, 2009, 86: 63-67
- Specht D F. A general regression neural network. *IEEE T Neural Network*, 1991, 2: 568-576
- Leszek R. Generalized regression neural networks in time-varying environment. *IEEE T Neural Network*, 2004, 15: 576-596
- Jamshid A S. Aerodynamic shape optimization based on free-form deformation. *AIAA J*, 2004, 2004-4630
- Blazek J. *Computational Fluid Dynamics Principles and Applications*. New York: Elsevier Ltd., 2005. 16-17
- 阎超. 计算流体力学方法及应用, 北京: 北京航空航天大学出版社, 2006. 236-237
- Sobol I M, Shukman B V. Random and quasi-random sequences: Numerical estimates of uniformity of distribution. *Math Comp Model*, 1993, 18: 39-45
- Donald R J. A taxonomy of global optimization methods based on response surfaces. *J Global Optim*, 2001, 21: 345-383

6 结论

本文针对 CRH380A 三辆编组简化外形, 提取 5 个设计参数, 进行了气动头型的减阻优化设计, 得到以下结论.

1) 本文提出的局部型函数曲面参数化方法实现简便、操作灵活, 使用较少的设计参数就可以控制较大的变形区域, 且能够保证变形曲面的光顺性和不同变形区域的光滑过渡, 可以较好的应用于高速列车气动外形的优化设计.

2) 使用相同数量样本点进行训练, GA-GRNN 模型的预测精度明显优于 GRNN 模型的预测精度, 在满足精度要求的情况下, 使用 GA-GRNN 模型更容易得到全局最优解.

3) 优化后 CRH380A 三辆编组简化外形的气动阻力减小了 8.7%, 其中摩擦阻力减小 1.18%, 压差阻力减小 53.85%, 压差阻力对气动外形的改变更为敏感, 是气动减阻的主要对象; 头车气动阻力减小 12.86%, 中间车基本不变, 尾车减小 12.59%, 气动减阻效果明显, 说明本文提出的气动外形优化方法简单、高效, 可以很好的应用于高速列车气动外形的工程优化设计.

4) 附属部件对列车的气动阻力有较大的影响, 尤其是车体连接处对列车的气动阻力分布影响很大, 但本文使用的简化外形在一定程度上能够反映真实外形的减阻效果, 可以应用于高速列车的气动外形优化设计.