

基于高斯过程回归和遗传算法的 翼型优化设计

常林森^{1,2}, 张倩莹^{1,2}, 郭雪岩^{1,2}

(1. 上海理工大学 能源与动力工程学院, 上海 200093;

2. 上海理工大学 上海市动力工程多相流动与传热重点实验室, 上海 200093)

摘 要: 针对高升阻比风力机翼型前缘曲率半径较大的问题,传统的翼型参数化方法前缘控制能力不足,且基于面元法 XFOIL 预测精度差的问题,利用增强类函数/形函数转换(CST)参数化方法控制翼型的形状变化、拉丁超立方实验设计、计算流体力学(CFD)流场计算模块、高斯过程回归模型和遗传算法,提出了基于高可信度 Reynolds average Navier-Stokes(RANS)和高斯回归模型辅助遗传算法的翼型优化设计方法。结果表明:基于高斯回归模型的翼型优化方法,可以将优化所用 CFD 计算次数降低一阶,从而大幅度提升优化设计效率。由标准算例超临界翼型 RAE2822 的降阻设计表明,在百次量级的 CFD 次数阻力降低 43.16%,激波被削弱且升力、力矩和面积严格满足约束。由风力机翼型 NACA64618 的最大化升阻比优化设计表明,所设计翼型不仅在设计攻角和副设计攻角处升阻比大大增加,在整个小攻角范围内其气动性能都得到了提升,且两个主设计点,无不良阻力的产生。

关 键 词: 高斯过程回归(GPR); CST 参数化方法; 遗传算法; 贝叶斯优化; 翼型设计

中图分类号: V211.3; TK83

文献标志码: A

Airfoil optimization design based on Gaussian process regression and genetic algorithm

CHANG Linsen^{1,2}, ZHANG Qianying^{1,2}, GUO Xueyan^{1,2}

(1. School of Energy and Power Engineering,

University of Shanghai for Science and Technology, Shanghai 200093, China;

2. Shanghai Key Laboratory of Multiphase Flow and Heat Transfer in Power Engineering,

University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: In view of the problems that the leading edge curvature of the wind turbine airfoil with high lift-to-drag ratio has large radius, the traditional airfoil parameterization method has insufficient leading edge control ability, and there exists poor prediction accuracy based on the panel method XFOIL, an enhanced class function/shape function transformation (CST) parameterized method was used to control the shape change of airfoil, Latin hypercube experimental design, computational fluid dynamics (CFD) flow field calculation module, Gaussian process regression model and genetic algorithm, based on high-confidence Reynolds average Navier -

收稿日期:2020-09-21

作者简介:常林森(1994-),男,硕士生,主要从事计算流体力学与气动外形设计。

通信作者:郭雪岩(1964-),男,教授,博士,主要从事计算流体力学及应用、空气动力学和气动优化,化学反应器的多尺度流动与反应耦合。E-mail:xyguo@usst.edu.cn

引用格式:常林森,张倩莹,郭雪岩. 基于高斯过程回归和遗传算法的翼型优化设计[J]. 航空动力学报,2021,36(11):2306-2316.

CHANG Linsen, ZHANG Qianying, GUO Xueyan. Airfoil optimization design based on Gaussian process regression and genetic algorithm[J]. Journal of Aerospace Power, 2021, 36(11): 2306-2316.

Stocks (RANS) and Gaussian regression model-assisted genetic algorithm for airfoil optimization design method. The results showed that the airfoil optimization method based on the Gaussian regression model can reduce the number of CFD calculations for optimization by one order, thereby greatly improving the optimization design efficiency. The resistance reduction design of the supercritical airfoil RAE2822 of the standard calculation example showed that the resistance of the CFD frequency in the order of hundreds of times was reduced by 43.16%, the shock wave was weakened and the lift, moment and area could strictly meet the constraints. The maximum lift-to-drag ratio of the wind turbine airfoil NACA64618 showed that the designed airfoil not only greatly increased the lift-to-drag ratio at the design angle of attack and the secondary design angle of attack, but also improved its aerodynamic performance in the entire range of the small angle of attack. And there were two main design points, without bad resistance.

Key words: Gaussian process regression (GPR); CST parameterization method; genetic algorithm; Bayesian optimization; airfoil design

水平轴风力机是当前最有效的风力发电装置,目前占全部风力发电装置的 97% 以上,在世界各地得到了广泛的应用。它是依靠叶片吸收风能,而叶片翼型的气动性能将直接影响到风力机的风能利用效率,因此叶片翼型的气动性能便显得尤为重要。自 20 世纪 80 年代以来,国外相继发展了 NREL(美国可再生能源实验室)、RISO(丹麦国家实验室)、DU(荷兰代尔夫特大学)和 FFA-W(瑞典宇航研究院)系列翼型。而国内水平轴风力机机型主要为 600kW 和 750kW,而国外已经发展到兆瓦级以上。其主要原因在于,西方先进风力机翼型数据严格保密,使得我国风力机发展水平较为缓慢。自 2007 年以来,国家将先进风力机翼型族的设计列为 863 计划(国家高技术研究发展计划),自此以后国内学者纷纷开始做风力机叶片的改型优化设计。叶片优化有基于叶片压力分布的反设计方法和直接数值优化方法。优秀的压力分布,需要丰富的设计经验和良好的流动机理直觉,通过改变叶片局部区域的压力分布,从而提高叶片整体性能。例如,安启蒙等^[1]基于变分有限元方法进行了叶片的反设计,从而增强了叶片的做功能力。何磊等^[2]基于深度学习方法进行了翼型的反设计工作。而基于叶片压力的反设计方法,其适用于航空翼型的巡航单攻角设计,对于风力机翼型设计应考虑多攻角多工况,且难以得到良好的压力分布,从而限制其在风能领域的应用。直接数值优化方法指将叶片优化描述为数学语言,通过结合最优化理论求解该问题。最优化理论中包括梯度法和进化类算法,具体在工程应用中,梯度信息获得代价过高或者需要发展

复杂的 CFD 代码和伴随代码,2009 年世界第一个风力机叶片伴随优化才诞生^[3],目前梯度类算法应用较少。进化类算法因其鲁棒性较好,应用较广泛。其中涉及叶片参数化方法、流场计算和目标函数评价。流场计算占据绝大部分的计算时间,通常要几千次流场计算。流场计算分为高可信度计算和低可信度计算。高可信度计算如 direct numerical simulation(DNS)、large eddy simulation(LES)和 RANS 其通常以小时为单位。低可信度计算如基于不可压缩势流方程的 XFOIL 软件和基于欧拉方程和附面层方程的 MSES 软件,通常以秒和分钟为单位。目前,国内外绝大部分的风力机叶片优化都是基于面元法的 XFOIL 软件进行。白井艳等^[4]基于 XFOIL 进行了 CAS-W1-XXX 族翼型优化设计。陈进等^[5]基于 RFOIL 进行了考虑表面粗糙度的叶片优化设计。汪泉等^[6]基于 RFOIL 进行了翼型的多攻角优化设计。而 Barrett 和 Ning^[7]指出,基于高可信度和低可信度的优化,对优化结果有很大影响,其强调了基于高可信度 RANS 优化的重要性。此外基于 XFOIL 的叶片气动性能计算只能进行二维优化,且失速区和最大升力系数精度较差。基于高可信度的叶片优化,国内的学者也进行了这方面的努力。闵新勇^[8]基于多学科优化设计软件 Hyperworks 和 Fluent 软件进行了叶片最大升阻比优化设计。余莉等^[9]基于 Isight 集成平台和 Fluent 软件进行了最大化升力优化。而以上的计算都过多调用了 CFD 软件,分别为 950 次和 2 000 次流场计算。评价基于高可信度叶片的优化有 2 个标准,即优化质量和优化效率。优化质量即目标的

百分比提升;优化效率为流场计算次数。以上的优化为了缓和计算量,都用了较少的网格数量和较低的残差收敛标准,这无疑与高可信度相矛盾。

近些年来,基于地理插值的函数近似和基于机器学习的模型预测引来不少关注。其目的是通过学习大量的数据规律,去预测未知的数据规律。而寻优过程大量的高可信度计算,如果可以通过已知数据插值计算得到,或者通过机器学习模型预测出来,而插值和预测时间成本很低,此时基于地理插值和机器学习的函数近似便占据了重要的地位。例如,在气动领域翼型形状系数与翼型气动性能的函数关系近似精度较高时,可以在这个近似模型上寻求最优解。理论上,初始样本越多,函数近似精度越高。而初始样本需要用CFD去计算气动参数,海量样本面对着大量的计算量。如何在预测精度和计算成本取得平衡,一直是学者们努力的方向。据亚平和张楚华^[10]进行了基于神经网络和遗传算法的风力机优化设计。黄靛等^[11]进行了基于响应面方法的风力机翼型气动优化设计。杨硕和程珩^[12]进行了基于径向基函数的风力机翼型多目标优化设计。王邦祥等^[13]进行了基于径向基神经网络的风力机优化设计。以上方法称为第一代近似模型,优化结果存在一定的误差,且对多极值优化问题,例如超临界翼型的降阻优化设计,此类方法优化质量较低和收敛速度较缓。而近些年来提出的动态改进型的近似模型,通过结合一些填充设计空间的加点策略,按加点序列逐步找到全局最优解。节点序列类似于梯度类算法中的每一代,只不过其依靠历史数据来驱动优化方向,而不是局限于当前最优解附近的局部梯度或者海瑟矩阵。其和第一代近似模型的区别在于,第一代模型追求设计空间整体近似能力达到最佳,而动态近似模型只需要最优解附近的精度足够高即可。为了追求优化效率,样本数量也不能过多,需要样本数量较小和预测能力较强的机器学习方法,因此本文选择小样本监督式学习方法高斯过程回归模型。高斯过程回归模型的预测精度已得到了验证^[14-16]。其孪生兄弟Kriging插值模型在韩忠华^[17]教授的14年的发展下,已经十分成熟,已经得到国际同行的广泛认可。发展高效的Kriging代码十分不易,然而高斯过程回归模型在机器学习领域发展较为成熟,大批量的开源包可以调用,模型训练方面更加完善,工程化应用更加高效简洁。

基于以上论述,本文通过高斯过程回归模型作为预测模型,辅助遗传算法进行翼型的优化设计,然后通过文献[17-19]提出的加点策略,提高优化质量。本文介绍了高斯过程回归模型、参数化方法以及曲线拟合、优化的整体框架、流场所用网格和气动参数计算,流场批量计算自动实现过程和遗传算法。然后用American Institute of Aeronautics and Astronautics(AIAA)标准算例超临界翼型RAE2822降阻优化验证了此方法的全局寻优能力、优化质量和优化效率。最后进行了双攻角下的风力机翼型NACA64618的最大化升阻比优化设计。

1 高斯过程回归

高斯过程可以看作是有限维随机向量的分布向无穷维函数空间分布的推广,高斯过程回归(GPR)利用空间中已有样本点的输入输出对组成的样本集合 (x_i, y_i) ,去预测得出新的样本点中 (x', y') 的 y' ,这里 x' 为预测输入。与传统插值方法不同的是,这里引入空间关联度,认为 x 、 x' 不是独立变量,空间关联度用协方差函数来计算,在GPR中用核函数来计算协方差函数。以径向基函数为例,其假设空间中两个不同的点 x 、 x' 距离越近,它们所对应的 y 、 y' 也就越相似。因此,GPR是基于相似性的机器学习方法,不需要显式的指定函数的具体形式,而是假设其服从某个指定均值函数和协方差函数的高斯过程,函数的后验分布是通过拟合训练数据时自动学习得到的^[16]。

1.1 预测

在GPR中,通常假设输入输出对 (x, y_i) ,其中 x 为输入矢量,其为行向量, y 为观测变量,其为标量。模型方程为

$$y = f(x) + \epsilon \quad (1)$$

式中 $f(x)$ 为信号项; ϵ 为噪声, $\epsilon \sim N(0, \sigma_{\text{noise}}^2)$ 其表示噪声满足正态分布。并且,假设信号项与噪声相互独立且信号项是一个满足特定分布的随机变量。主观意义上,这个分布反应了关于函数的不确定度。随着训练数据越来越多,这种不确定度会逐渐减少。噪声项 ϵ 反应了 y 固有的随机性。从函数空间角度讲,高斯过程可以被看作为在 $f(x)$ 的分布,其中

$$f(x) \sim G(m(x), k(x, x')) \quad (2)$$

式中 G 为高斯过程, $m(x)$ 为 x 处的期望值

$m(x) = E(f(x))$, 通常, 为了避免昂贵的后验计算, 假设均值为 0, 而是对协方差函数做出推论。方差函数 $k(x, x')$ 刻画了不同输入点处 x, x' 对应函数值的关联度。

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (3)$$

通常函数 k 称为高斯过程的核, 关于核函数, 请参考文献[20]。一旦均值和核函数确定了, 就可以通过高斯过程计算先验函数值(训练集的拟合值)和后验函数值(验证集的预测值)。

由先验观测值组成的列向量 $Y = [y_1, y_2, \dots, y_n]^T$, 协方差矩阵

$$K(X, X) = \begin{bmatrix} k(x_1, x_1) & \cdots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \cdots & k(x_n, x_n) \end{bmatrix} \quad (4)$$

其中 $X = [x_1 \cdots x_n]^T$ 。

Y 先验概率分布为

$$Y \sim N(0, K(X, X) + \sigma_{\text{noise}}^2 I_n) \quad (5)$$

令测试点即预测点为 x^* , 预测无噪声为 f^* ,

则有

$$\begin{pmatrix} f_1^* \\ \vdots \\ f_m^* \end{pmatrix} = N \left[\begin{bmatrix} k(x_1^*, x_1^*) & \cdots & k(x_1^*, x_m^*) \\ 0 & \vdots & \vdots \\ k(x_m^*, x_1^*) & \cdots & k(x_m^*, x_m^*) \end{bmatrix}, \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix} \right] \quad (6)$$

写成紧致形式为

$$f^* \sim N(0, K(x^*, x^*)) \quad (7)$$

通过定义, 训练数据 Y 和函数值 f^* 满足一个多元联合高斯分布

$$\begin{bmatrix} Y \\ f^* \end{bmatrix} \sim N \left(\begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} K(X, X) + \sigma_{\text{noise}}^2 I_n & K(X, X^*) \\ K(X^*, X) & K(X^*, X^*) \end{bmatrix} \right) \quad (8)$$

$$K(X, X^*) = K(X^*, X)^T$$

由贝叶斯公式得 f^* 的条件概率密度为^[20]

$$f^* | X, Y, X^* \sim N(u^*, \Sigma^*) \quad (9)$$

式中

$$u^* = K(X^*, X)(K(X, X) + \sigma_{\text{noise}}^2 I_n)^{-1} Y$$

$$\Sigma^* = K(X^*, X^*) - K(X^*, X) \cdot$$

$$(K(X, X) + \sigma_{\text{noise}}^2 I_n)^{-1} K(X, X^*)$$

为计算后验均值 u^* 和方差 Σ^* , 首先需计算 4 个方差矩阵, 再进行结合, 最后得到 u^*, Σ^* 。

1.2 训练

GPR 可以选择不同的协方差函数, 不同的协方差函数还可以相互组合, 从这点看, GPR 预测可能比 Kriging 插值精度更高。常用的协方差函

数如 matern 5/2, 其数学定义为

$$k_{\text{matern } 5/2}(x, x') = \sigma_f^2 \left[1 + \sqrt{\frac{5}{2l^2}} (x - x')^2 + \frac{5}{3} \frac{(x - x')^2}{2l^2} \right] \exp \left(-\sqrt{\frac{5}{2l^2}} (x - x')^2 \right) \quad (10)$$

式中 l^2 为方差尺度, σ_f^2 为信号方差, 参数集合 $\theta = \{l^2, \sigma_f^2, \sigma_{\text{noise}}^2\}$ 为超参数。训练模型等价于求解超参数, 通常用极大似然法求解超参数^[14, 16]。

多元高斯分布的边际属性

$$p(Y|X) = N(0, K(X, X) + \sigma_{\text{noise}}^2 I_n) \quad (11)$$

负对数边际似然函数为

$$L(\theta) = -\ln p(Y|X) = \frac{1}{2} y^T C^{-1} y + \frac{1}{2} \ln |C| + \frac{n}{2} \ln 2\pi \quad (12)$$

式中 $C = K(X, X) + \sigma_{\text{noise}}^2 I_n$; $|C|$ 为 C 的行列式。

解 $L(\theta)$ 可以调用一些最优化的包, 如 matlab 的 `fminunc`、python 的 `scipy.optimize` 模块。有关超参数初值的选择, 请参考文献[16]。

2 参数化方法

2.1 CST 参数化方法

翼型参数化方法对优化质量和优化效率有重要影响。目前常用的参数化方法有, Hicks-Henne 参数化方法, Parsec 参数化方法, Bezier/B-spline 参数化方法。Parsec 参数化方法通常假定上下表面前缘半径相等, Bezier 参数化方法需要假定前缘不变, 而高升力风力机翼型前缘半径间断且前缘半径需要变化, 此 2 类方法控制能力不足。如何用少量的设计变量, 探索足够大的设计空间, 一直是气动优化领域研究的热点。CST 参数化方法^[21]由 Kulfan 和 Bussoletti 提出, 用类函数和形函数唯一确定翼型。类函数决定翼型的类别, 如亚声速翼型分类于圆头尖尾翼型, 超音速翼型分类于尖头尖尾翼型。确定类函数以后, 再由形函数系数的唯一性确定翼型。CST 参数化方法能够良好地控制翼型前缘、尾缘、厚度以及尾缘厚度, 使其广泛应用于航空领域^[15, 22-23]。由于其前缘大弯度翼型表达能力不足, 原作者在 2009 年提出改进^[24], 在原有表达式基础上, 增加了一项基函数, 以增强对前缘大弯度翼型的拟合和对设计空间的探索。

增强 CST 参数化表达式为

$$b = a^{N_1} \cdot (1-a)^{N_2} S(a) + A_{n+1} (1-a)^{n+0.5} a + \Delta Y \cdot a \quad (13)$$

$$S(a) = \sum_{i=0}^n A_i B_n^i (1-a)^{n-i} a^i \quad (14)$$

式中 N_1 、 N_2 为类函数系数, 对于圆头尖尾翼型有 $N_1 = 0.5$ 、 $N_2 = 1$; $S(a)$ 为形函数; ΔY 为尾缘厚度; A_i 为形函数系数, $B_n^i = \frac{n!}{(n-i)!i!}$, $!$ 为阶乘符号; n 为参数化方法的阶数; $A_{n+1} (1-a)^{n+0.5} a$ 提供前缘弯度。这里选择伯恩斯坦基函数, 其相对于幂基函数, 舍入误差更低^[25]。

$$\begin{bmatrix} \sqrt{a_1} (1-a_1) \cdot C_3^0 (1-a_1)^3 & \cdots & \sqrt{a_1} (1-a_1) \cdot C_3^3 (1-a_1)^0 \\ \vdots & \ddots & \vdots \\ \sqrt{a_n} (1-a_n) \cdot C_3^0 (1-a_n)^3 & \cdots & \sqrt{a_n} (1-a_n) \cdot C_3^3 (1-a_n)^0 \end{bmatrix}_{n \times 4} \begin{bmatrix} A_0 \\ A_1 \\ A_2 \\ A_3 \end{bmatrix} = \begin{bmatrix} b_1 \\ \vdots \\ b_n \end{bmatrix} \quad (16)$$

即简化为

$$BA = b \quad (17)$$

由于系统矩阵 B 超定, 因此需要用线性最小二乘法来求解。

$$B^T BA = B^T b \quad (18)$$

可调用线性最小二乘的包 (matlab lsqin 或者 python scipy.optimize lsqstsq) 进行求解, 只需要提供 B 和 b 即可, 矩阵 B 的分量用式 (19) 计算。

$$B_{ij} = \sqrt{a_i} (1-a_i) \cdot C_n^j (1-a_i)^{n-j} \cdot (a_i)^j \quad (19)$$

3 翼型气动优化设计

3.1 优化流程

首先选择较好的初始翼型, 拟合翼型得到初始 CST 系数, 继而确定 CST 系数变量范围, 然后通过拉丁超方实验设计^[26]生成空间均匀分布的样本。整个优化流程如下:

1) 选择基准翼型, 选择参数化方法和对应阶数 (Parsec/CST/H-H/Bezier/B-spline) 然后拟合曲线得到初始设计变量, 并在设计空间中生成一定数量的样本, 最后调用 CFD 求解器计算样本翼型的气动数据。

2) 设定优化目标、气动约束和几何约束, 将工程问题转化为数学语言。

3) 分别建立样本几何系数和气动数据之间的 GPR 模型 (目标函数/约束函数)。

4) 选择加点策略和约束函数处理方式, 然后用梯度类或进化类算法寻找更新模型所需要的下一个样本点。

5) 所加样本点经过 CFD 计算后得到气动数

2.2 曲线拟合

为了得到翼型代表的形系数, 通常要进行曲线拟合。以 3 阶 CST 参数化方法拟合圆头尖尾翼型为例, 简要叙述曲线拟合流程。翼型 x 、 y 坐标轴方向所有坐标点组成的列向量为 (a, b) , 对于每一个坐标点 (a_i, b_i) 都有

$$b_i = \sqrt{a_i} (1-a_i) \cdot (A_0 C_3^0 (1-a_i)^3 + A_1 C_3^1 (1-a_i)^2 \cdot a_i + A_2 C_3^2 (1-a_i) \cdot a_i^2 + A_3 C_3^3 a_i^3) \quad (15)$$

写成矩阵形式为

据, 然后将样本几何系数和气动系数加入样本集中, 更新模型。

其流程示意图如图 1 所示, 其中 X 、 Y 为初始样本集合, LHS 为拉丁超立方设计 (Latin hypercube sampling, LHS), CEI 为期望改善准则, CMSP 为最小化概率准则。





图1 优化流程图

Fig.1 Optimization flow chart


3.2 翼型流场求解和网格生成

本文采用二维 RANS 方程作为翼型流场的控制方程, 采用空间离散的有限体积法, 利用密度基求解流场, 通量差分选用 Roe 格式, 湍流模型选用 Spalart-Allmaras (S-A) 模型, 空间离散格式选用 2 阶精度的迎风格式, 选用压力远场作为边界

条件,翼型壁面采用无滑移边界条件。网格采用 C 型网格,网格量约为 65 000,第 1 层网格高度为 1×10^{-5} ,来流区域为 25 倍弦长,尾流区域为 50 倍弦长,网格细节如图 2 所示。自动实现过程为首先通过几何系数 x 生成 Pointwise 可读的 dat 文件,其次调用 Pointwise 的脚本文件生成 Fluent 可读的 case 文件,然后调用 Fluent 的脚本文件算出气动系数,最后从生成的文件中提取所需气动系数。



(a) 计算域整体网格



(b) 近壁面网格

图 2 RAE2822 翼型计算网格及示意图

Fig.2 Schematic diagram of computational grid for RAE2822 airfoil

3.3 遗传算法

遗传算法是较为经典的全局类优化方法,其优点为不需要函数连续可导等性质,易于并行计算适应度等优点。首先随机生成一定数量的种群,在种群的进化过程中,大自然会不断地淘汰适应力差的个体,同时适应力强的个体得以存活,最后适应度最强的个体便是最优解。本文将遗传算法应用于翼型的气动优化中,希望可以得到较好的全局最优解,设计遗传算法的流程如图 3,图中 q 为初始种群数量。

4 算例与结果分析

针对超临界翼型 RAE2822 和 NERL 5MW




图 3 遗传算法流程图

Fig.3 Flow chart of genetic algorithm

风力机叶尖处 NACA64618 翼型,以提高翼型在设计状态的典型气动参数为目标,如最大化升阻比、最小化阻力系数等,同时施加几何约束和气动约束,进行翼型的几何外形设计。而超临界翼型 RAE2822 的降阻优化是标准算例,可方便和前人进行对比全局寻优能力、优化质量和优化效率,进而说明该方法的有效性。

4.1 算例一

选择 AIAA 气动研讨组发布的第 2 个标准算例:跨声速黏性条件 RAE2822 翼型减阻优化设计。优化工况为 $Ma=0.734$, $Re=6.5 \times 10^6$,固定迎角 α 为 3.015° ,优化模型数学描述为

$$\begin{aligned} & \min C_d \\ & \text{s.t.} \begin{cases} C_l \geq 0.824 \\ C_m \geq -0.092 \\ A \geq A_0 \end{cases} \end{aligned} \quad (20)$$

式中 A_0 为原翼型面积; C_l 为升力系数; C_d 为阻力系数, C_m 为力矩系数。

采用 4 阶增强 CST 参数化方法控制翼型的形状,共 12 个设计变量,拟合效果图如图 4。

本算例选择文献[17-19]提供的加点策略和概率性约束处理,即最小化代理模型(MSP)和最大化 EI(expected improvement)准则。加点策略即不断地驱动加入新样本点,使得模型预测精度越来越高。理论上,随着新样本点不断加入 GPR 模型,模型的精度会越来越高,那么在模型上寻找的




图4 翼型参数化拟合效果图

Fig.4 Effect diagram of airfoil parameterization fitting

最优翼型也会越来越接近真实的最优翼型。加点序列可以理解为梯度类算法迭代的每一代,只不过其依靠当前样本趋势,而不是依靠梯度和海瑟

$$E(I(x)) = \begin{cases} [y_{\min} - \hat{y}(x)] \Phi \left[\frac{y_{\min} - \hat{y}(x)}{s(x)} \right] + s \phi \left[\frac{y_{\min} - \hat{y}(x)}{s(x)} \right] & s > 0 \\ 0 & s = 0 \end{cases} \quad (21)$$

式中 $\hat{y}$ 为模型上的近似值, s 为标准差, $y_{\min}$ 为当前样本中的最小值, Φ 为标准正态累积分布函数, ϕ 为准正态概率密度函数。

$$F_{\text{CEI}}(x) = E(I(x)).$$

$$\left[1 - \Phi \left(\frac{0.824 - \hat{g}_{C_1}(x)}{s_{C_1}(x)} \right) \right] \cdot \left[1 - \Phi \left(\frac{-0.0926 - \hat{g}_{C_m}(x)}{s_{C_m}(x)} \right) \right] \cdot \left[1 - \Phi \left(\frac{0.077749 - \hat{g}_A(x)}{s_A(x)} \right) \right] \quad (22)$$

式中 $\hat{g}_{C_1}(x)$ 、 $s_{C_1}(x)$ 为升力约束的均值和标准差; $\hat{g}_A(x)$ 、 $s_A(x)$ 为面积约束的均值和标准差。注意

CEI为EI与当前样本点满足约束的概率相乘。CEI函数如下:

此式中, $y_{\min}$ 变更为满足约束的最小值。最小化代理模型的适应度函数为

$$f_{\text{fitness}} = \begin{cases} C_d, & C_l > 0.824 \text{ 且 } A > 0.077749 \\ C_{d \max} + A_{\text{bs}, \min}(0, 0.824 - C_l) + A_{\text{bs}, \min}(0, -0.0926 - C_m) + A_{\text{bs}, \min}(0, 0.077749 - A), & \text{其他} \end{cases} \quad (23)$$

式中 $C_{d \max}$ 为当前样本中的最大值, $A_{\text{bs}, \min}$ 为最小绝对值函数。

最后选择遗传算法,需要确定设计变量范围: $x_0 - \delta \leq x \leq x_0 + \delta$ 。 δ 太大会增加寻优的难度,且会生成不切实际的翼型几何,导致网格生成失败或翼型流场计算发散,从而使优化中止; δ 太小会造成寻优范围太小,优化质量过低。因此,应选择合适的 δ ,本文令 $\delta = 0.02$ 。综上,该算例的数学优化命题为

$$\begin{aligned} & \min C_d(x) \\ & \text{s.t.} \begin{cases} x_0 - 0.02 \leq x \leq x_0 + 0.02 \\ C_l(x) \geq 0.824 \\ C_m(x) \geq -0.092 \\ A(x) \geq A_0 \end{cases} \end{aligned} \quad (24)$$

矩阵。MSP准则即当前模型预测均值最小的点,这里需要用优化器得到模型上的最小点。EI准则为目标函数改善期望最大所对应的点。MSP准则局部收敛性良好,EI准则探索整个设计空间,两种准则配合既保证了优化质量,全局收敛性也得到保障。概率约束处理,即引入统计思想处理约束函数。有关MSP准则、EI准则和概率性约束处理详情请参考^[17]。只要求出最小化MSP对应的 x^* 和最大化EI对应的 x^* 即可,此处这2个 x^* 为样本序列,然后调用CFD算出其气动系数,最后将输入输出对加入原样本集合中更新原模型,反复以上操作直到达到最大迭代次数。EI函数如下:


表1 优化前后翼型升力、阻力、面积

Table 1 Lift, drag, area of baseline and optimum airfoils


翼型	C_m	C_d	C_l	A
基准翼型	-0.092 6	0.021 553	0.824	0.077 749
优化翼型	-0.088 1	0.012 250	0.824	0.077 750

数从基准翼型的 0.021 553 降低到优化后翼型的 0.012 250,翼型升力约束和翼型面积约束都严格满足。压力系数 C_p (coefficient of pressure, C_p) 是描述翼型气动性能的重要参数。图 5 和图 6 中,其 c 为弦长, x/c 为无量纲参数。由图可知,基准翼型的强激波,优化后激波被削弱,因此波阻大大降低。经过百次的流场计算,在气动约束和几何约束同时满足的情况下,阻力系数降低 93.03×10^{-4} 。与伴随梯度类算法进行了比较^[27],其阻力降低 84×10^{-4} ,因此本文方法优化质量大大提高。较文献[28-31]相比,优化效率和优化质量都得到了提高。其中文献[29]基于神经网络模型的 RAE2822 翼型优化求解 Navier-Stokes(NS)方程 265 次和基于标准遗传算法的 RAE2822 优化求解 NS 方程 3 000 次。较文献[31]相比,优化质量相当,优化效率得到了提高,其求解 NS 方程 300 次,而本文 142 次。因此,该方法极大地降低了时间开销。从优化收敛过程样本数据知,即使初始样本集中没有满足约束的样本翼型,依然可以通过当前的样本趋势泛化出优化方向,第 128 次流场阻力系数为 123.570×10^{-4} ,第 132 次流场阻力系数为 122.495×10^{-4} ,下降约为 1×10^{-4} ,故认为其充分收敛。

需要说明的是,上述优化过程实现自动化,无




(a) 优化前后翼型轮廓对比图




(b) 优化前后翼型表面压力分布对比图

图 5 优化前后翼型轮廓和压力曲线对比图

Fig.5 Comparison of pressure distributions and geometries for baseline and optimum airfoils



(a) RAE2822



(b) Opt2822

图 6 优化前后翼型流场压力云图

Fig.6 Comparison of flow field pressure cloud for baseline and optimum airfoils

论是生成网格,还是计算流场都无需人为干涉。在 8 核个人计算机上进行计算,一次流场计算约 30 min,整个优化过程约为 3 d。

4.2 算例二

选择 NREL 系列叶片的叶尖处翼型 NACA64618 作为基准翼型,以升阻比为目标函数,对设计攻角和副设计点进行优化设计。设计工况为 $v=14.61$ m/s, $Re=1.0 \times 10^6$ 。对原翼型数值模拟后发现,攻角为 6° 时其升阻比最大。综合考虑后,对风力机翼型 NACA64618 进行双攻角的气动优化设计。通过线性加权法,将设计点攻角 1° 和 6° 的升阻比转化为单目标最大化升阻比,数学描述如下:

$$\max [0.7(C_l/C_d)_{\alpha=6^\circ} + 0.3(C_l/C_d)_{\alpha=1^\circ}] \quad (25)$$

约束条件分为几何约束与气动约束,其中几何约束为最大厚度不减,即 $T \geq T_0$,气动约束 1° 和 6° 攻角下最大升力系数不减,即: $C_l \geq C_{l\alpha=1^\circ}^0$ 和 $C_l \geq C_{l\alpha=6^\circ}^0$ 。

$C_1 \geq C_{1\alpha=6^\circ}$, T_0 与 $C_{1\alpha=6^\circ}$ 分别为基准翼型的厚度和升力系数。此算例中,共加入 24 个样本点,加上初始构建模型的 50 个样本点,共计 148 次流场计算。综上,该算例的数学命题为

$$\begin{aligned} &\max [0.7(C_1/C_d)_{\alpha=6^\circ} + 0.3(C_1/C_d)_{\alpha=1^\circ}] \\ &\text{s.t.} \begin{cases} x_0 - 0.02 \leq x \leq x_0 + 0.02 \\ C_{1\alpha=6^\circ}(x) \geq 1.0739 \\ C_{1\alpha=1^\circ}(x) \geq 0.57665 \\ T \geq T_0 \end{cases} \end{aligned} \tag{26}$$

表 2 给出了优化前后升阻比、升力、厚度数据

对比。

由表 2 知,优化后设计点处升阻比大大增加,阻力略微减少,厚度较基准翼型几乎不变,因此结构兼容性得到了保障。由翼型轮廓图 7(a) 知,上表面前缘半径增大,而下表面前缘半径减少,和高升阻比风力机翼型特征相似。由图 7(b) 知,整个小攻角范围内,升阻比都比基准翼型大。图 8 为不同攻角下压力系数 C_p 随弦长分布,由图可知,优化后压力曲线图较基准翼型变得更加饱满,做功能力增大。与文献[10-13]相比,本文优化质量较高,CFD 计算次数较少,计算结果无预测误差。

表 2 优化前后翼型升力系数、阻力系数和面积

Table 2 Lift coefficient,drag coefficient and area of baseline and optimum airfoils

参数	初始翼型		优化后翼型	
	$\alpha=1^\circ$	$\alpha=6^\circ$	$\alpha=1^\circ$	$\alpha=6^\circ$
C_l	0.576 7	1.073 9	0.648 8	1.162 2
C_d	0.014 126	0.019 078	0.014 109	0.019 058
C_l/C_d	40.82	56.29	45.98	60.98
$T/\%$	17.96	17.96	18.01	18.01
C_l/C_d 相对变化率			11.22	8.33




图 7 优化前后升阻比和翼型几何对比图

Fig.7 Comparison of lift-to-drag ratio and geometries for baseline and optimum airfoils




图 8 优化前后翼型压力曲线对比图

Fig.8 Comparison of pressure distributions for baseline and optimum airfoils

5 结 论

本文介绍了 GPR 模型,结合气动优化中两种典型优化目标,并施加了气动约束和几何约束,说明了高斯过程回归可以应用于翼型优化设计,总结如下:

1) 利用增强 CST 方法进行了参数化建模,可以用较少的设计变量控制翼型的几何形状,尤其是增强了对前缘大弯度翼型的设计空间的探索,这对超临界翼型和高升力风力机翼型参数化建模是非常有必要的。

2) 利用计算流体力学、GPR 模型辅助遗传算法、拉丁超立方实验设计方法和填充空间的加点策略对标准算例 RAE2822 翼型进行了降阻优化。结论表明:本文方法拥有较强的全局寻优能力,优化质量和优化效率也都得到了提高。

3) 基于高可信度 RANS 求解器,对风力机翼型 NACA64618 进行了设计点处最大化升阻比优化设计,并且考虑了非设计点处的性能。由结果可知,在百次的 CFD 次数量级,整个小攻角范围内升阻比均有提高,且在两个设计点处都无不良阻力的产生。

4) 完善了计算工具链条,实现了从几何建模,到网格生成,再到气动分析和优化一体化设计。从算例二可知,该方法拓展到多工况优化是可行的。并且,有理由相信在三维风力机叶片优化的工作中,本文所用优化框架依然有一定的应用前景。

参考文献:

- [1] 安启蒙,黄典贵,吴国庆.基于变分有限元方法的 S809 翼型的改进设计[J].工程热物理学报,2011,32(5):779-782.
AN Qimeng, HUANG Dianguai, WU Guoqing. Improved design of a S809 airfoil based on variable-domain variational finite element method[J]. Journal of Engineering Thermophysics, 2011, 32(5):779-782. (in Chinese)
- [2] 何磊,钱炜祺,刘涛,等.基于深度学习的翼型反设计方法[J].航空动力学报,2020,35(9):1909-1917.
HE Lei, QIAN Weiqi, LIU Tao, et al. Inverse design method of airfoil based deep learning [J]. Journal of Aerospace Power, 2020, 35(9):1909-1917. (in Chinese)
- [3] RITLOP R, NADARAJAH S. Design of wind turbine profiles via a preconditioned adjoint-based aerodynamic shape optimization[R]. AIAA 2009-1547, 2009.
- [4] 白井艳,杨科,李宏利,等.水平轴风力机专用翼型族设计[J].工程热物理学报,2010,31(4):589-592.
BAI Jingyan, YANG Ke, LI Hongli, et al. Design of the horizontal axis wind turbine airfoil family[J]. Journal of Engineering Thermophysics, 2010, 31(4):589-592. (in Chinese)
- [5] 陈进,张石强,王旭东,等.基于粗糙度敏感性研究的风力机专用翼型设计[J].空气动力学学报,2011,29(2):142-149.
CHEN Jin, ZHANG Shiqiang, WANG Xudong, et al. Dedicated wind turbine airfoil design based on the roughness sensitivity considerations[J]. Acta Aerodynamica Sinica, 2011, 29(2):142-149. (in Chinese)
- [6] 汪泉,王君,陈进,等.基于多点攻角的风力机翼型优化设计[J].哈尔滨工程大学学报,2016,37(11):1580-1585.
WANG Quan, WANG Jun, CHEN Jin, et al. Wind turbine airfoil optimal design based on a multipoint angle of attack[J]. Journal of Harbin Engineering University, 2016, 37(11):1580-1585. (in Chinese)
- [7] BARRETT R, NING A. Comparison of airfoil precomputational analysis methods for optimization of wind turbine blades[J]. IEEE Transactions on Sustainable Energy, 2016, 7(3):1081-1088.
- [8] 闵新勇.风力机翼型的气动性能模拟与优化设计[D].上海:上海交通大学,2010.
MIN Xinyong. Aerodynamics simulation and optimal design of wind turbine airfoil[D]. Shanghai: Shanghai Jiao Tong University, 2010. (in Chinese)
- [9] 余莉,呼政魁,程涵,等.风力机翼型的多学科设计优化[J].南京航空航天大学学报,2011,43(5):697-700.
YU Li, HU Zhengkui, CHENG Han, et al. Multidisciplinary design optimization for wind turbine airfoil[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2011, 43(5):697-700. (in Chinese)
- [10] 琚亚平,张楚华.利用试验设计法建立翼型气动特性的人工神经网络模型[J].航空学报,2010,31(5):893-898.
JU Yaping, ZHANG Chuhua. Artificial neural network model of airfoil aerodynamic performance using design of experiments[J]. Acta Aeronautica et Astronautica Sinica, 2010, 31(5):893-898. (in Chinese)
- [11] 黄靓,李景银,高远.基于响应面法的风力机翼型气动优化设计[J].流体机械,2011,39(2):21-24.
HUANG Jing, LI Jingyin, GAO Yuan. Aerodynamics optimization of wind turbine airfoils using response surface techniques[J]. Fluid Machinery, 2011, 39(2):21-24. (in Chinese)
- [12] 杨硕,程珩.基于径向基函数模型的风力机翼型多目标优化设计[J].现代制造工程,2016(3):54-58.
YANG Shuo, CHEN Hang. Multiobjective optimization design for wind turbine airfoil based on radial function model[J]. Modern Manufacturing Engineering, 2016(3):54-58. (in Chinese)
- [13] 王邦祥,陆金桂,王京涛.神经网络在风力机翼型气动性能优化中的应用[J].机械设计与制造,2020,349(3):236-240.
WANG Bangxiang, LU Jingui, WANG Jingtao. Application of neural network to aerodynamics performance optimization of wind turbine[J]. Machinery Design and Manufacture, 2020, 349(3):236-240. (in Chinese)

- [14] 单志辉,刘学军,吕宏强.高斯过程回归在翼型气动性能快速评估中的应用[C]//第4届中国航空学会青年科技论坛文集,沈阳:中国航空学会,2010:159-166.
- [15] 徐亚峰.基于CST参数化方法的飞机翼型快速设计研究[D].南京:南京航空航天大学,2013.
XU Yafeng.Fast airfoil design based on CST parameterization[D].Nanjing:Nanjing University of Aeronautics and Astronautics,2013.(in Chinese)
- [16] 高赫,刘学军,郭晋,等.基于高斯过程回归的连续式风洞马赫数控制[J].空气动力学学报,2019,37(3):480-487.
GAO He,LIU Xuejun,GUO Jin,et al.Mach number control of continuous wind tunnel based on Gaussian process regression[J].Acta Aerodynamica Sinica,2019,37(3):480-487.(in Chinese)
- [17] 韩忠华.Kriging模型及代理优化算法研究进展[J].航空学报,2016,37(11):3197-3225.
HAN Zhonghua.Kriging surrogate model and its application to design optimization: a review of recent progress[J].Acta Aeronautica et Astronautica Sinica,2016,37(11):3197-3225.(in Chinese)
- [18] GARDNER J R,KUSNER M J,XU Z E,et al.bayesian optimization with inequality constraints[R].Beijing:International Conference on Machine Learning,2014:937-945.
- [19] GELBART M A.Constrained Bayesian optimization and applications[D].Boston:Harvard University,2015.
- [20] RASMUSSEN C E,WILLIAMS C K I.Gaussian processes for machine learning[M].Cambridge,US:Massachusetts Institute of Technology Press,2005.
- [21] KULGAN B M.Universal parametric geometry representation method[J].Journal of aircraft,2008,45(1):142-158.
- [22] 李静,高正红,黄江涛,等.基于CST参数化方法气动优化设计研究[J].空气动力学学报,2012,30(4):443-449.
LI Jing,GAO Zhenghong,HUANG Jiangtao.Aerodynamic optimization system based on CST technique[J].Acta Aerodynamica Sinica,2012,30(4):443-449.(in Chinese)
- [23] 卜月鹏,宋文萍,韩忠华,等.基于CST参数化方法的翼型气动优化设计[J].西北工业大学学报,2013,31(5):829-836.
BU Yuepeng,SONG Wenping,HAN Zhonghua,et al.Aerodynamic optimization design of airfoil based on CST parameterization method[J].Journal of Northwestern Polytechnical University,2013,31(5):829-836.(in Chinese)
- [24] KULFAN B M.Modification of CST airfoil representation methodology[EB/OL].[2020-09-01].https://brendakulfan.com/docs/CST8.pdf.
- [25] PIEGL L,TILLER W.The NURBS book[M].Berlin Heidelberg:Springer,1997.
- [26] 刘俊.基于代理模型的高效气动优化设计方法及应用[D].西安:西北工业大学,2015.
LIU Jun.Efficient surrogate-based optimization method and its application in aerodynamic design[D].Xi'an:Northwestern Polytechnical University 2015.(in Chinese)
- [27] GRAMANZINI J R.Adjoint-based airfoil shape optimization in transonic flow[D].Missouri,US:Missouri University of Science and Technology,2015.
- [28] 陈立立,郭正,侯中喜.自由变形技术在RAE2822翼型优化设计中的应用[J].国防科技大学学报,2018,40(5):45-53.
CHEN Lili,GUO Zheng,HOU Zhongxi.Application of free-form deformation technique for RAE2822 airfoil optimization design[J].Journal of National University of Defense Technology,2018,40(5):45-53.(in Chinese)
- [29] 朱莉.基于神经网络的翼型优化设计方法研究[D].西安:西北工业大学,2007.
ZHU Li.Research on optimal design method of airfoil based on neural network[D].Xi'an:Northwestern Polytechnical University,2007.(in Chinese)
- [30] 苏伟,白俊强.一种代理模型方法及其在气动优化设计中的应用[J].弹箭与制导学报,2008,28(3):199-202.
SU Wei,BAI Junqiang.A surrogate-based optimization algorithm and its application to aerodynamic optimization design[J].Journal of Projectiles Rockets Missiles and Guidance 2008,28(3):199-202.(in Chinese)
- [31] 王超,高正红,张伟,等.自适应设计空间扩展的高效代理模型气动优化设计方法[J].航空学报,2018,39(7):45-63.
WANG Chao,GAO Zhenghong,ZHANG Wei,et al.Efficient surrogate-based aerodynamic design optimization method with adaptive design expansion[J].Acta Aeronautica et Astronautica Sinica,2018,39(7):45-63.(in Chinese)

(编辑:张 雪)