



基于深度置信网络与多目标粒子群算法的通用飞机机翼优化设计

吴涌钊 孙刚 陶俊

Optimization design on the wing of a general aviation airplane based on deep belief network and multi-objective particle swarm optimization algorithm

WU Yongchuan, SUN Gang, TAO Jun

引用本文:

吴涌钊, 孙刚, 陶俊. 基于深度置信网络与多目标粒子群算法的通用飞机机翼优化设计[J]. 空气动力学学报, 2023, 41(12): 16–27. DOI: 10.7638/kqdlxxb-2023.0005

WU Yongchuan, SUN Gang, TAO Jun. Optimization design on the wing of a general aviation airplane based on deep belief network and multi-objective particle swarm optimization algorithm[J]. Acta Aerodynamica Sinica, 2023, 41(12): 16–27. DOI: 10.7638/kqdlxxb-2023.0005

在线阅读 View online: <https://doi.org/10.7638/kqdlxxb-2023.0005>

您可能感兴趣的其他文章

Articles you may be interested in

飞翼翼型高维目标空间多学科综合优化设计

Multidisciplinary optimization design of high dimensional target space for flying wing airfoil

空气动力学学报. 2017, 35(4): 587–597 <https://doi.org/10.7638/kqdlxxb-2017.0079>

CSRT与CST气动外形参数化方法对比

Comparison of the CSRT and the CST parameterization methods

空气动力学学报. 2014, 32(2): 228–234 <https://doi.org/10.7638/kqdlxxb-2012.0092>

工程翼型气动特性数据挖掘与建模

Modeling and data mining of engineering airfoil aerodynamic characteristics

空气动力学学报. 2021, 39(6): 175–183 <https://doi.org/10.7638/kqdlxxb-2021.0219>

基于熵产理论设计方法的多目标翼型优化

Entropy generation theory based design methodology for multi-objective airfoil shape optimization

空气动力学学报. 2019, 37(5): 827–833 <https://doi.org/10.7638/kqdlxxb-2017.0055>

自然层流机翼气动外形优化研究

Study of aerodynamic shape optimization for natural laminar wing

空气动力学学报. 2015, 33(6): 812–817 <https://doi.org/10.7638/kqdlxxb-2014.0054>

民机飞发集成构型中机翼多目标优化设计

Multi-objective wing optimization of civil aircrafts in engine-aircraft integration configuration

空气动力学学报. 2018, 36(6): 941–948 <https://doi.org/10.7638/kqdlxxb-2016.0126>

地址: 四川省绵阳市二环路南段8号11信箱9分箱

电话: 0816-2463375

Email: kqdlxxb@163.com

网址: <http://kqdlxxb.xml-journal.net/>



关注微信公众号
获得更多资讯信息

文章编号: 0258-1825(2023)12-0016-12

基于深度置信网络与多目标粒子群算法的 通用飞机机翼优化设计

吴涌钊, 孙刚, 陶俊^{*}
(复旦大学 航空航天系, 上海 200433)

摘要:采用主成分分析技术对基于型函数/类函数变换(CST)参数化方法进行改进,以减少机翼的设计变量。建立了机翼的数据库,以数据库中机翼的几何参数和气动参数为训练样本,建立并训练了深度置信网络作为气动优化设计的代理模型。为了提高标准多目标粒子群算法的收敛速度和全局搜索能力,发展了基于 α -stable分布函数的改进型多目标粒子群算法。将深度置信网络代理模型嵌入改进的多目标粒子群算法,开展了某通用飞机机翼的多目标气动优化设计。优化结果表明,采用主成分分析技术可大幅减少计算量。对优化所得机翼构型开展数值模拟验证,结果表明,在阻力系数不增加的条件下,优化机翼构型在多个工作状态下的升力系数显著提升。

关键词:机翼设计;多目标优化设计;深度置信网络;多目标粒子群优化算法;主成分分析

中图分类号:V244 文献标识码:A doi: 10.7638/kqdlxxb-2023.0005

Optimization design on the wing of a general aviation airplane based on deep belief network and multi-objective particle swarm optimization algorithm

WU Yongchuan, SUN Gang, TAO Jun^{*}
(Department of Aeronautics & Astronautics, Fudan University, Shanghai 200433, China)

Abstract: For the purpose of reducing the number of the design variables of the wing, the PCA (principal component analysis) technique is employed to improve the CST parameterization method. A database of the wings is established, including geometrical parameters and aerodynamic parameters. Based on the database, the DBN (deep belief network) is established and trained as the surrogate model in the aerodynamic optimization. In order to improve the convergence rate and global searching ability of the standard MOPSO (multi-objective particle swarm optimization) algorithm, an improved MOPSO algorithm is developed based on the α -stable distribution functions. By embedding the DBN surrogate model into the improved MOPSO algorithm, the multi-objective aerodynamic optimizations are performed for the wing of a general aviation airplane. The optimization results indicate that, the computation amount is decreased dramatically by introducing the PCA technique. Numerical validation is conducted for the designed wing configuration, and the results indicate that, comparing with the baseline configuration, the lift coefficients of the designed configuration are increased obviously under multiple states with the drag coefficients not increased.

Keywords: wing design; multi-objective optimization; deep belief network; multi-objective particle swarm optimization algorithm; principal component analysis

收稿日期:2023-01-02; 修订日期:2023-03-13; 录用日期:2023-03-14; 网络出版时间:2023-05-09

基金项目:旋翼空气动力学重点实验室开放课题(RAL20200101-2); 翼型、叶栅空气动力学国家级重点实验室开放课题(614220121020219)

作者简介:吴涌钊(1997—), 广东潮州人, 硕士研究生, 研究方向:飞行器设计. E-mail: 20210290012@fudan.edu.cn

通信作者:陶俊^{*}, 副研究员, 研究方向:空气动力学、飞行器设计. E-mail: juntao@fudan.edu.cn

引用格式: 吴涌钊, 孙刚, 陶俊. 基于深度置信网络与多目标粒子群算法的通用飞机机翼优化设计[J]. 空气动力学学报, 2023, 41(12): 16–27.

WU Y C, SUN G, TAO J. Optimization design on the wing of a general aviation airplane based on deep belief network and multi-objective particle swarm optimization algorithm[J]. Acta Aerodynamica Sinica, 2023, 41(12): 16–27(in Chinese). doi: 10.7638/kqdlxxb-2023.0005

0 引言

通用飞机是民用航空工业中重要的组成部分,在工业、农业、林业等领域有重要的应用,在医疗卫生、抢险救灾、气象探测等方面也有不可替代的作用。升力的提升可以提高通用飞机的载货量、载油量,从而提升飞机的整体性能,因此,升力的优化对通用飞机的设计有重要意义。

国内外研究人员对机翼的设计进行了大量的研究。Benaouali^[1]应用代理模型方法对 ONERA M6 进行机翼外形优化。马晓永^[2]应用集成序列二次规划(sequential quadratic programming, SQP)优化算法对 NAX880 V2.0 轻中型高速涡扇公务机机翼进行多点优化设计研究。周志强^[3]开展了基于遗传算法的飞机机翼结构拓扑优化设计方法研究。郝璇^[4]采用雷诺平均 N-S(Reynolds average Navier-Stokes, RANS)方程实现阻力的精确求解并建立响应面模型,对不同升力系数、马赫数的多个飞行状态进行变弯度减阻优化。

对于传统的机翼优化设计问题,如果在优化过程的每步迭代中都通过 CFD 数值模拟来评估目标函数,会消耗大量的计算资源。为了提高优化效率,减少资源的消耗,可以使用代理模型取代 CFD 在优化中的计算过程。反向传播(back propagation, BP)神经网络^[5]是一种由误差反向传播算法训练得到的多层前馈神经网络,是当前被应用最广泛的神经网络模型之一。吕小龙等^[6]利用本征正交分解(proper orthogonal decomposition, POD)提取本征向量,并使用径向基函数(radical basis function, RBF)方法进行插值,建立了具有较好反演精度和泛化性能的 POD-RBF 代理模型。此外,还有一种 Kriging 模型^[7],是依据协方差函数对随机过程/随机场进行空间建模和预测(插值)的回归算法。

在机翼的优化问题中,优化变量往往是高维数据,如果用原数据去进行训练和优化,则会造成较大的计算资源消耗,增加计算时间成本。因此,许多研究会采用数据降维方法对原数据进行处理。独立分量分析(independent component analysis, ICA)^[8]基于信息理论,是使用最广泛的降维技术之一,可用于将多元信号分离为加性子分量。POD^[9]则可以把多维随机过程进行低维近似描述并提取复杂随机过程的本质特征,从而达到数据降维的目的,可用于外形气动设计。线性识别分析(linear discriminant analysis, LDA)^[10]使用统计学、模式识别和机器学习方法,在

两类物体或事件的特征中找到一个线性组合,从而能够特征化或区分它们,所得的组合可用来为后续的分类做降维处理。

飞机通常在多个工况下飞行,这就使得机翼的气动优化成为多目标、多约束问题。多目标多约束问题的求解依赖优化算法,为此,许多研究人员对优化算法进行了研究。多目标遗传算法(multi-objective genetic algorithm, MOGA)^[11]是一种模拟大自然中生物进化规律的自然选择和遗传学机理的生物进化过程的计算模型,对于一个优化问题,使一定数量候选解(个体)的抽象表示(染色体)的种群向更好的解进化。模拟退火算法(simulated annealing, SA)^[12-13]的思想来源于热力学中对固体退火过程的模拟,其将温度 T 模拟为控制参数,将内能模拟为目标函数值 f ,对于控制参数 T 的每一个取值,算法持续进行“产生——新解——判断——接受或舍弃”的迭代过程,并逐步衰减 T 值,算法终止时的当前解记为所得近似最优解。多目标蚁群算法(multi-objective ant colony optimization, MOACO)^[14-15]是模拟蚂蚁的觅食行为与旅行商问题(traveling salesman problem, TSP)的相似性提出的,用蚂蚁的路径表示待优化问题的可行解,路径较短的蚂蚁释放的信息素量较多,随着时间的推进,较短的路径上累积的信息素浓度逐渐增高,选择该路径的蚂蚁个数也愈来愈多,最终蚁群集中到最优路径,即优化问题的最优解。

综上所述,机翼在多工况下的空气动力学优化作为一个多目标、多约束的问题,具有重要意义。本文提出了一种基于深度置信网络代理模型和多目标粒子群算法的多目标优化框架。首先,利用基于型函数/类函数变换参数化方法(class function/shape function transformation, CST)得到的几何参数,利用 CFD 模拟得到空气动力参数,然后对机翼的几何参数进行主成分分析(principal component analysis, PCA)降维处理,建立起机翼的数据库,在此基础上训练深度置信网络(deep belief network, DBN)代理模型,以准确预测机翼的气动参数;其次,通过将优化算法与代理模型耦合,建立起多目标粒子群优化框架;最后,通过该框架对机翼进行多工况下的气动优化,在不增加其阻力系数的情况下提升其升力系数。

1 数值模拟方法与验证

1.1 RANS 方法

通过求解 RANS 方程,可得到机翼的气动参数:

$$\begin{aligned}
\frac{\partial W}{\partial t} + \frac{\partial F_1}{\partial x} + \frac{\partial F_2}{\partial y} + \frac{\partial F_3}{\partial z} &= \frac{\partial G_1}{\partial x} + \frac{\partial G_2}{\partial y} + \frac{\partial G_3}{\partial z} \\
W &= [\rho, \rho u, \rho v, \rho w, \rho E]^T \\
F_1 &= [\rho u, \rho u^2 + p, \rho uv, \rho uw, \rho uH]^T \\
F_2 &= [\rho v, \rho uv, \rho v^2 + p, \rho vw, \rho vH]^T \\
F_3 &= [\rho w, \rho uw, \rho wv, \rho w^2 + p, \rho wH]^T \\
G_1 &= [0, \tau_{xx}, \tau_{xy}, \tau_{xz}, \beta_x]^T \\
G_2 &= [0, \tau_{xy}, \tau_{yy}, \tau_{yz}, \beta_y]^T \\
G_3 &= [0, \tau_{zx}, \tau_{zy}, \tau_{zz}, \beta_z]^T
\end{aligned} \quad (1)$$

数值模拟中,空间离散采用 Roe-FDS^[16]方法,时间推进采用隐式 LU-SGS^[16]方法,湍流模型为方程 S-A (Spalart-Allmaras)^[17]湍流模型。

1.2 算例验证

为了验证 RANS 方法的精准度和可靠性,使用 DLR 翼身组合体进行验证,图 1 展示了该翼身组合体的网格结构,网格单元数为 6.34×10^6 。




图 1 DLR-F6 翼身组合体网格

Fig. 1 Grid of DLR-F6 wing-body assembly

数值模拟计算结果如表 1 所示。可以看出,数值模拟计算结果与实验所得结果误差较小,说明 RANS 具有较高的精确度。

表 1 DLR-F6 翼身组合体的数值模拟结果 ($Re = 3.0 \times 10^6$)
Table 1 Numerical simulation results of the DLR-F6 wing-body assembly ($Re = 3.0 \times 10^6$)

工况	C_L	C_D
算例 1: AOA = 0.52°, Ma = 0.75		
计算值	0.4966	0.0290
实验值	0.5000	0.0295
误差	0.68%	1.69%
算例 2: AOA = 0.47°, Ma = 0.76		
计算值	0.4981	0.0293
实验值	0.5000	0.0298
误差	0.38%	1.68%
算例 3: AOA = 0.41°, Ma = 0.77		
计算值	0.4962	0.0296
实验值	0.5000	0.0300
误差	0.76%	1.33%

2 优化问题

2.1 CST 参数化

在对机翼进行优化时,需要对机翼的几何数据进行处理,用尽量少的特征参数描述机翼的几何特征,以降低计算量,同时必须具有足够高的精度,以确保参数对几何特性描述的准确性及计算的可信度。

本研究所优化的机翼半翼展长为 8.305 m,翼根弦长为 2.180 m,翼梢弦长为 0.910 m。选取机翼在翼根、翼尖梢以及 1/2 半展长处的剖面翼型(分别记为剖面翼型 1、剖面翼型 2、剖面翼型 3),以其几何数据作为机翼的几何数据。图 2 为机翼的平面形状图,图 3 为选取的三个剖面的示意图。




图 2 机翼的平面形状示意图

Fig. 2 Schematic figure of the plane shape of the wing




图 3 机翼三个剖面的示意图

Fig. 3 Schematic figure of the three sections of the wing

使用 CST 参数化方法^[18]处理几何数据。CST 方法是一种用类别函数和形状函数表示翼型几何形状的参数化方法。类别函数表示的是要描述的几何体的类型,形状函数是在类别函数的基础上对几何特性进行修正。翼型用 CST 参数化方法进行表示的公式如下:

$$\xi(\varphi) = C(\varphi)S(\varphi) + \varphi\xi_{\tau} \quad (2)$$

其中, $\varphi = x/c$, $\xi = z/c$, $\xi_{\tau} = \Delta\xi_{te}/c$, $C(\varphi)$ 是类型函数, $S(\varphi)$ 是形状函数。在研究中,可以用伯恩斯坦多项式代替形状函数。采用 6 阶伯恩斯坦多项式即可进行高精度拟合。经过 CST 参数化,翼型几何形状可以用 14 个参数表示。现用翼型 NACA 23012 对 CST 参数化方法进行验证,图 4 为 CST 参数化翼型与原始翼型的对比,图 5 为参数化翼型在每个 x 坐标上的拟合残差,其中 x/c 的范围从 -1 到 0 代表上表面,从 0 到 1 代表下表面。可以看出, CST 方法的参数化翼

型与原始翼型基本一致,残差均小于 1×10^{-2} ,说明采用的 CST 方法在描述翼型几何形状方面具有很高的可靠性。经过 CST 参数化后,机翼的几何特性可以用 42 个参数表示。




图 4 原翼型曲线和 CST 拟合翼型曲线

Fig. 4 Original airfoil curve and CST fitted airfoil curve




图 5 CST 参数化拟合翼型残差

Fig. 5 Fitting residuals of the CST parameterized airfoil

2.2 PCA (主成分分析)

参数化后的机翼几何参数有 42 个变量,这对于

后续的代理模型训练以及优化过程是偏高的,容易造成较大的计算资源损耗。为了让计算更加高效便捷,对数据进行降维处理。

PCA^[19]是一种基础的数据降维方法,其作用是用较少的变量来代替较多的变量,并反映出原来多个变量的大部分信息,被广泛应用在数据分析、机器学习等方面。

对于一个变量数量为 p 、数据数量为 n 的样本 $\mathbf{X}$,可计算出协差阵,然后可根据协差阵求出 p 个特征值 $(\lambda_1, \lambda_2, \dots, \lambda_p)$ 及相应的特征向量 $(\mathbf{T}_1, \mathbf{T}_2, \dots, \mathbf{T}_p)$,则第 i 个主成分 $\mathbf{Y}_i$ 为 $\mathbf{Y}_i = \mathbf{X}\mathbf{T}_i$, $1 \leq i \leq p$ 。

原样本有 p 个成分,依据特征值,可计算出每个成分的贡献率 $\varphi_i = \lambda_i / \sum_{k=1}^p \lambda_k$ 。一个成分的贡献率越大,则说明其保存了越多的原数据信息。当前 m 个主成分的贡献率累计大于 90% 时,可以认为这些主成分已经包含了原数据中的大部分信息。

原机翼包含了 3 个翼型的几何数据,每个翼型数据为 14 维,共 42 维。现对每一个翼型进行 PCA 降维处理,当每个翼型取前 10 个主成分时,累计贡献率分别达到了 93.9%、93.4%、94.04%,则可以认为处理后所得的 30 维机翼几何数据包含了绝大多数原机翼的数据。图 6 展示了三个剖面翼型的 14 维参数贡献率。

2.3 优化问题描述

本研究要优化的是机翼在多种工作状态下的升力系数。选取其在马赫数为 0.4 时的状态作为优化工况 1,在马赫数为 0.45 时的状态作为优化工况 2,迎角均为 4° ,工况 1 和工况 2 的雷诺数分别为 $Re_1 = 9.83 \times 10^6$ 和 $Re_2 = 1.11 \times 10^7$ 。

基于 5 套网格对原机翼开展了网格无关性验证,5 套网格单元数分别为 2.0×10^6 、 2.5×10^6 、 3.0×10^6 、 3.5×10^6 、 4.0×10^6 ,计算结果如表 2 所示,其中,各参数的下标 1 和 2 分别对应工况 1 和工况 2。由计算结果可得,伴随网格数增长,计算结果呈收敛趋势,从计算精度和计算资源考虑,选用网格单元为 3.5×10^6 的网格作为计算网格,网格如图 7 所示。




图 6 3 个剖面翼型的 14 维参数的贡献率

Fig. 6 Contribution rates of the 14 dimensional parameters of the three airfoils

表 2 原机翼气动参数在不同网格数量下计算结果

Table 2 Simulation results of aerodynamic parameters of original wing under different numbers of grids

网格数量	C_{L1}	C_{D1}	C_{L2}	C_{D2}
2.0×10^6	0.4432	0.02190	0.4519	0.02084
2.5×10^6	0.4519	0.02107	0.4609	0.02065
3.0×10^6	0.4629	0.02029	0.4724	0.02051
3.5×10^6	0.4628	0.02027	0.4725	0.02050
4.0×10^6	0.4629	0.02030	0.4725	0.02052




图 7 机翼的网格

Fig. 7 Grid of the wing

以两种工况下的机翼升力系数作为优化目标,约束条件为优化后机翼阻力系数小于或等于原机翼阻力系数。优化问题可以描述为:

$$\begin{aligned} & \text{find } X = \{x_1, x_2, \dots, x_n\} \\ & \max \{C_{L1}, C_{L2}\} \\ & \text{s.t.} \begin{cases} 0.8x_i \leq x_i \leq 1.2x_i, i = 1, 2, \dots, n \\ C_{D1} \leq C_{D01} \\ C_{D2} \leq C_{D02} \end{cases} \end{aligned} \quad (3)$$

其中: x_i 表示设计变量, $[0.8x_i, 1.2x_i]$ 为其设计空间; C_{D01} 、 C_{D02} 分别为工况 1、2 下的原机翼阻力系数;在不采用 PCA 方法的情况下, $n = 42$; 在采用 PCA 方法的情况下, $n = 30$ 。

3 优化方法

3.1 深度置信网络

本研究使用的代理模型 DBN^[20]是一种概率生成模型,这种模型通过训练调整神经元之间的权重,可以用来进行数据生成,常用于回归分析、类型识别等。

深度置信网络的基本构成元件是受限玻尔兹曼机(restricted Boltzmann machines, RBM)^[21],其典型网络结构如图 8 所示。一个 RBM 由两层神经元构成,一层是可视层,由可视神经元组成,用于数据的输入;一层是隐藏层,由隐藏神经元组成,用于特征检测。RBM 两层神经元之间对称连接,同层之间的神经元相互独立。

对于输入样本 $X=(x_1, x_2, \dots, x_n)$, 隐藏神经元开启的概率为 $P(h_i = 1) = 1/(1 + e^{-w^x})$, 从 0~1 的均匀分布中抽取一个随机值,与开启概率进行比较,决定该神经元是否开启。经过预训练,可求得最佳的权重值,使得其产生训练样本的概率最大。

将多层 RBM 进行串联,以上一层 RBM 的隐藏层作为下一层 RBM 的可视层,在最后一层加上 softmax 分类器,即形成了深度置信网络。这种网络将 RBM 的训练作为神经网络的预训练,在最后一层加入 BP 算法。深度置信网络典型结构如图 9 所示。




图 8 RBM 结构

Fig. 8 Structure of RBM




图 9 DBN 结构

Fig. 9 Structure of DBN

3.2 改进多目标粒子群优化算法

粒子群优化(particle swarm optimization, PSO)算法^[22]是一种通过模拟鸟群捕食行为设计的优化算法。假设区域里只有一块食物(即优化问题中的最优解),鸟群的任务是找到这个食物源。在整个搜索过程中,群体中的鸟会互相传递位置信息,判断是否找到了食物源(最优解),同时将食物源(最优解)的信息传递给整个鸟群,最后,整个鸟群可以收敛在食物源周围。

把鸟个体简化为一个粒子,把粒子的位置作为目标问题的候选解,把候选解对应的目标函数值作为适应度,把粒子群中适应度最高/最低的粒子位置作为

群体最优位置,把单个粒子历史适应度最高的位置作为粒子历史最优位置,粒子的飞行过程即对应个体的搜索过程。粒子的飞行速度以粒子历史最优位置和群体最优位置为参考进行调整,此即为进化迭代过程。经过多轮迭代,可以求出问题的最优解。粒子的速度和位置的进化方程如下:

$$\begin{aligned} V_i(k+1) &= wV_i(k) + b_1r_1(\mathbf{P}_{\text{best}}[i] - \mathbf{A}_i) + \\ &\quad b_2r_2(\mathbf{P}_{\text{best}}[g] - \mathbf{A}_i) \\ \mathbf{A}_i(k+1) &= \mathbf{A}_i(k) + KV_i(k+1) \end{aligned} \quad (4)$$

式中, w 为惯性权值; b_1 、 b_2 为学习因子; r_1 、 r_2 为 $[0,1]$ 之间的随机数; K 为压缩因子,用于对粒子的飞行速度进行约束; $\mathbf{P}_{\text{best}}[i]$ 为单个粒子历史最优位置, $\mathbf{P}_{\text{best}}[g]$ 为所有粒子迄今为止所找到的最佳位置; $\mathbf{A}_i$ 为第 i 个粒子所在位置; V_i 为第 i 个粒子的速度。

多目标粒子群优化 (multi-objective particle swarm optimization, MOPSO)^[23] 算法旨在将只能用于单个对象的粒子群算法 (PSO) 应用于多目标。在其基础上, Raquel^[24] 将粒子拥挤距离、储存非支配解的仓库等引入其中, 来提高粒子群的多样性。拥挤距离是估计一个解周围其他解的密度的参数。对于每个目标函数, 根据目标函数的值对外部精英解集中的解进行分类, 然后计算与每个解相邻的两个粒子形成的立方体的平均边长, 如图 10 所示, 计算的结果就是该解的拥挤距离, 粒子的拥挤距离可以反映解的多样性。该种算法即为拥挤距离多目标粒子群优化 (crowding distance multi-objective particle swarm optimization, CDMOPSO) 算法^[25]。




图 10 拥挤距离示意图

Fig. 10 Schematic figure of the crowding distance

为了提高收敛速度和全局搜索能力, 引入了 α -stable 函数族^[26] 来改进标准的 MOPSO 算法。在 α -stable 函数族中, 稳定系数 α 是描述分布状态的一个重要参数, 它决定了所生成的随机数的分布范围。图 11 显示了不同 α 值下的 α -stable 分布。通过引入 α -stable 分布, MOPSO 在迭代过程中生成随机数, 使

粒子进行突变, 避免过早陷入局部最优。该种算法即为 α -stable 多目标粒子群优化 (α -stable multi-objective particle swarm optimization, ASMOPSO) 算法。多目标粒子群算法如图 12 所示。




图 11 不同 α 值下的 α -stable 分布示意图

Fig. 11 Schematic figure of the α -stable distribution under different α




图 12 MOPSO 结构

Fig. 12 Structure of MOPSO

为了比较 CDMOPSO 和 ASMOPSO 的性能,采用目标函数 ZDT3 进行测试。利用反世代距离(inverted generation distance, IGD)^[27]对算法的性能进行了综合评价。IGD 不仅可以评估多目标解集的收敛性,还可以评估解集的分布特性,见式(5):

$$A_{IGD} = \frac{\sum_{o \in P^*} d(o, P)}{P^*} \quad (5)$$

$d(o, P)$ 是近似解集 P 中的个体与精确解集 P^* 中的个体 o 之间的最小欧氏距离。该算法得到的最优解集用 p 表示。IGD 的值越低,优化结果越好,算法的性能也越好。ZDT3 函数可以描述为:

$$\begin{cases} \min f_1(x) = x_1 \\ \min f_2(x) = g \left(1 - \sqrt{\frac{f_1}{g}} - \left(\frac{f_1}{g} \right) \sin(10\pi f_1) \right) \\ g(x) = 1 + 9 \sum_{i=2}^n \frac{x_i}{n-1} \end{cases} \quad (6)$$

x 是一个 30 维变量,其范围为 $[0, 1]$, $n = 30$ 。ZDT3 由 CDMOPSO 算法和 ASMOPSO 算法独立评估 30 次。IGD 值的统计数据如表 3 所示,可以看出 ASMOPSO 的 IGD 值明显低于 CDMOPSO,因此 ASMOPSO 算法的性能优于 CDMOPSO 算法。

表 3 CDMOPSO 和 ASMOPSO 算法所得 IGD 的比较
Table 3 Comparison of IGD values between the CDMOPSO algorithm and ASMOPSO algorithm

	均值	方差
CDMOPSO	5.661×10^{-2}	2.946×10^{-3}
ASMOPSO	3.300×10^{-2}	1.623×10^{-3}

3.3 EI 加点准则

在优化过程中,每次迭代均采用期望改进(expected improvement, EI)^[28]加点准则对代理模型进行更新。将 EI 作为代理优化的适应度函数,在每次迭代中将 EI 最大的点添加到样本中,在每次迭代中更新代理模型。多目标 EI 的定义为

$$EI(x) = \int_{y \in R^m} I(x) \prod_{i=1}^m \frac{1}{s_i} \varphi \left(\frac{y_i - \hat{y}_i}{s_i} \right) dy_i \quad (7)$$

式中, $\hat{y}_i$ 和 s_i 为相关点 x 的预测和方差值的平方根, φ 为高斯概率密度函数, R^m 为目标空间。

子优化问题可描述为:

$$\begin{cases} \max EI(x) \\ \text{s.t.} \begin{cases} C_{D1} \leq C_{D01} \\ C_{D2} \leq C_{D02} \\ 0.8x_i \leq x_i \leq 1.2x_i, \quad i = 1, 2, \dots, n \end{cases} \end{cases} \quad (8)$$

在每次迭代中,选择 EI 最大的点进行 CFD 数值模拟,获得空气动力学参数,添加到样本中,并更新替代模型。

4 计算结果与分析

4.1 代理模型训练结果

基于原机翼的 CST 参数,通过拉丁超立方采样方法(latin hypercube sampling, LHS)^[29],在原机翼参数 $[0.8, 1.2]$ 的倍数范围内,生成 980 组 CST 参数,并通过数值模拟获得一个包含 980 个机翼的几何参数和气动参数的数据库。

DBN 由 4 层 RBM 组成,以几何参数为输入、气动参数为输出进行训练。预训练后,初始化权值,将最后一层 RBM 的输出作为最后两层 BP 神经网络的输入。

在数据库中选取 882 个机翼作为训练样本,98 个机翼作为测试样本,将样本输入模型进行训练,得到的代理模型记为代理模型 1。在数据库中随机选取 450 个机翼作为训练样本,50 个机翼作为测试样本,为了降低后续的训练和优化计算量,对机翼几何数据进行 PCA 降维处理,降维后的几何参数为 30 维,将 PCA 降维处理后的样本输入模型进行训练,得到的代理模型记为代理模型 2。

图 13 为 DBN 代理模型的训练结果,其中 Y 为期望输出, T 为 DBN 输出。可以看出,代理模型 1 的相关系数 R 为 0.995 16,代理模型 2 的相关系数 R 为 0.974 02,均接近于 1,两个模型都取得了较为精确的结果。

图 14 和图 15 分别展示了测试样本的计算值与训练所得代理模型预测值的对比。从图中可看出,绝大多数预测值与计算值基本吻合。

DBN 模型预测的升力系数和阻力系数的平均误差如表 4 所示。由表可以看出,代理模型 1 的升力系数与阻力系数的平均误差小于 1%,代理模型 2 平均误差小于 2%,说明 DBN 模型的预测具有较高的精度。代理模型 1 的误差明显小于代理模型 2,由此可得,代理模型 1 具有更高的精准度,原因是代理模型 1 的训练样本更多且保留了更多原数据的信息。

表 4 升力系数和阻力系数的平均预测误差

	平均误差			
	C_{L1}	C_{D1}	C_{L2}	C_{D2}
代理模型 1	0.69%	0.64%	0.70%	0.67%
代理模型 2	1.22%	1.15%	1.26%	1.13%




图 13 DBN 代理模型的训练结果

Fig. 13 Training results of the DBN surrogate model




图 14 机翼气动参数代理模型 1 的预测值与计算值

Fig. 14 Surrogate model 1 prediction values and calculation values of the aerodynamic parameters of wings




图 15 机翼气动参数代理模型 2 的预测值与计算值

Fig. 15 Surrogate model 2 prediction values and calculation values of the aerodynamic parameters of wings

4.2 多目标粒子群优化结果

将训练得到的无 PCA 处理和有 PCA 处理的代理模型嵌入多目标粒子群优化算法中, 分别记为优化 1 和优化 2。

将粒子数设置为 500, Pareto 解数设置为 10, 突变率设置为 0.8。优化的终止条件是最近 10 代的适应度值的最大差异均小于 0.01%。在每次迭代中, 如果满足终止准则, 则优化结束, 否则迭代将继续。

优化 1 与优化 2 分别经过 91 步与 102 步迭代后, 收敛得到最优解。优化 1 与优化 2 的优化过程对比如图 16 所示, 优化得到的 Pareto 解集如图 17 所示。

为了在每次迭代的 Pareto 解集中选出一个最优解, 现定义一个函数:


$$f_{op} = \omega_1 \frac{(C_{L1} - C_{L1}^{\min})}{(C_{L1}^{\max} - C_{L1}^{\min})} + \omega_2 \frac{(C_{L2} - C_{L2}^{\min})}{(C_{L2}^{\max} - C_{L2}^{\min})} \quad (9)$$

其中 ω_1 、 ω_2 是权重系数, 在此处设为 [0.5, 0.5]。对

Pareto 解集中的所有解计算出对应的 f_{op} 值, f_{op} 值最大的解即为满意解。

4.3 优化结果验证

优化后机翼的几何模型如图 18 所示。

(a) $Ma=0.40$




图 16 优化 1 与优化 2 的优化过程




图 17 优化 1 与优化 2 优化所得 Pareto 解集

Fig. 17 Pareto solution set obtained by optimization with/without PCA processing




图 18 优化机翼的几何模型

Fig. 18 Geometric model of the optimized wing

对优化机翼进行数值模拟，得出优化后机翼在工况 1 与工况 2 下的升力和阻力系数计算值。原机翼和优化机翼的气动参数在 DBN 模型下的预测值及计算值如表 5 所示。

表 5 原机翼与优化机翼气动参数的预测值与计算值				
Table 5 Prediction and calculation values of aerodynamic parameters of the original and optimized wings				
	C_{L1}	C_{D1}	C_{L2}	C_{D2}
优化1	原机翼计算值	0.4628	0.02027	0.4725
	优化机翼DBN预测值	0.5154	0.02018	0.5272
	优化机翼计算值	0.5082	0.02006	0.5204
	预测值与计算值误差/%	1.40	0.59	1.29
	相对原机翼增长量/%	9.81	-1.04	10.14
优化2	原机翼DBN预测值	0.5200	0.02026	0.5323
	优化机翼计算值	0.5065	0.02013	0.5184
	预测值与计算值误差/%	2.60	0.64	2.61
	相对原机翼增长量/%	9.44	-0.69	9.71
	相对原机翼增长量/%	9.44	-0.69	9.71

由表可以看出，优化 1 得到的优化机翼较原翼型的升力系数在工况 1 下提升 9.81%、工况 2 下提升 10.14%，阻力系数在工况 1 下减少 1.04%、工况 2 下减少 0.20%；优化 2 得到的优化机翼较原翼型的升力系数在工况 1 下提升 9.44%、工况 2 下提升 9.71%，具有较明显提升，阻力系数在工况 1 下减少 0.69%、工况 2 下不变，优化效果较为理想。

可以看到，优化 1 与优化 2 的优化结果基本相近，为了进一步比较两种优化的效率，表 6 给出了以无代理模型时过程需要 100 步迭代达到收敛计算，优化 1、优化 2 和无代理模型三种情况下的计算算例数

表 6 优化过程中 CFD 数值模拟算例数量和计算时间

Table 6 Computation time and number of CFD simulation cases during the optimization process

	训练时间/s	算例数量
无代理模型	—	50000
优化1	89	1082
优化2	52	591

量和计算时间。

由表可知:无代理模型情况下优化过程中所需要数值模拟的算例数量远远大于有代理模型;有代理模型的情况下,优化2的优化过程需要计算591个算例,远低于优化1所需的1082个算例,而两者所达到的优化效果是基本接近的。

5 结 论

本研究提出了一种基于DBN的多目标优化框架,并应用于某通用飞机机翼的气动优化设计,研究表明:

1)采用CST方法对机翼的控制剖面进行参数化描述,在此基础上,引入PCA技术,有效地降低了机翼的设计变量。

2)建立了机翼的气动数据库,针对是否采用PCA技术分别建立了DBN代理模型,训练结果表明所建立的DBN代理模型对气动参数具有很好的预测效果。

3)基于DBN代理模型,采用MOPSO算法对于是否采用PCA技术分别开展了机翼的多目标气动优化设计,结果表明两种优化结果基本一致,在阻力系数不增加的前提下,升力系数明显提升。然而,采用PCA技术可大幅减少优化过程中所需的计算量。

在后续的研究工作中,有必要开展更为高效的降维技术研究,进一步减少设计变量,从而减少气动优化设计过程中的计算量,提高优化效率。

参 考 文 献:

- [1] BENAOUALI A, KACHEL S. A surrogate-based integrated framework for the aerodynamic design optimization of a subsonic wing planform shape[J]. *Proceedings of the Institution of Mechanical Engineers, Part G:Journal of Aerospace Engineering*, 2018, 232(5): 872–883. doi: 10.1177/0954410017699007
- [2] 马晓永, 吴军强, 肖云雷, 等. 公务飞机翼气动外形优化研究[J]. *航空工程进展*, 2022, 13(2): 27–44. MA X Y, WU J Q, XIAO Y L, ETT AL. Study on Aerodynamic Shape Optimization for Wing of Business Jet[J]. *Advances in Aeronautical Science and Engineer*, 2022, 13(2): 27–44 (in Chinese). doi: 10.16615/j.cnki.1674-8190.2022.02.04
- [3] 周志强, 胡宗浩, 邢本东, 等. 基于遗传算法的飞机机翼结构拓扑优化设计方法[J]. *内燃机与配件*, 2021(24): 16–18. ZHOU Z Q, HU Z H, XING B D, et al. Topology optimization design method of aircraft wing structure based on genetic algorithm[J]. *Internal Combustion Engine & Parts*, 2021(24): 16–18 (in Chinese). doi: 10.3969/j.issn.1674-957X.2021.24.006
- [4] 郝璇, 张青青, 苏诚, 等. 民用客机可变弯度机翼优化设计研究[J]. *航空工程进展*, 2022, 13(4): 25–36. HAO X, ZHANG Q Q, SU C, et al. Research on variable camber wing optimization design of passenger aircraft[J]. *Advances in Aeronautical Science and Engineering*, 2022, 13(4): 25–36 (in Chinese). doi: 10.16615/j.cnki.1674-8190.2022.04.03
- [5] FENG C, GOWRISANKAR A C, SMITH A E. Practical guidelines for developing BP neural network models of measurement uncertainty data[J]. *Journal of Manufacturing Systems*, 2006, 25(4): 239–250. doi: 10.1016/S0278-6125(08)00006-X
- [6] 吕小龙, 黄丹, 姜冬菊. 基于POD-RBF代理模型的迭代更新反演方法[J]. *计算力学学报*, 2022, 39(4): 506–511. LYU X L, HUANG D, JIANG D J. Iterative updating inversion method based on POD-RBF surrogate model[J]. *Chinese Journal of Computational Mechanics*, 2022, 39(4): 506–511 (in Chinese). doi: 10.7511/jslx20201201001
- [7] 韩少强, 宋文萍, 韩忠华, 等. 基于梯度增强型Kriging模型的气动反设计方法[J]. *航空学报*, 2017, 38(7): 120817. HAN S Q, SONG W P, HAN Z H, et al. Aerodynamic inverse design method based on gradient-enhanced Kriging model[J]. *Acta Aeronautica et Astronautica Sinica*, 2017, 38(7): 120817 (in Chinese).
- [8] KWON H, YI S, CHOI S. Numerical investigation for erratic behavior of Kriging surrogate model[J]. *Journal of Mechanical Science and Technology*, 2014, 28(9): 3697–3707. doi: 10.1007/s12206-014-0831-x
- [9] 段焰辉, 吴文华, 范召林, 等. 基于本征正交分解的气动优化设计外形数据挖掘[J]. *物理学报*, 2017, 66(22): 138–147. DUAN Y H, WU W H, FAN Z L, et al. Proper orthogonal decomposition-based data mining of aerodynamic shape for design optimization[J]. *Acta Physica Sinica*, 2017, 66(22): 138–147 (in Chinese). doi: 10.7498/aps.66.220203
- [10] 郑传宇, 黄江涛, 周铸, 等. 飞翼翼型高维目标空间多学科综合优化设计[J]. *空气动力学学报*, 2017, 35(4): 587–597. ZHENG C Y, HUANG J T, ZHOU Z, et al. Multidisciplinary optimization design of high dimensional target space for flying wing airfoil[J]. *Acta Aerodynamica Sinica*, 2017, 35(4): 587–597 (in Chinese). doi: 10.7638/kqdlxxb-2017.0079
- [11] 李阁强, 袁畅, 王帅, 等. 基于协同进化多目标遗传算法的复式液压摆动缸结构设计[J]. *船舶力学*, 2022, 26(11): 1694–1704. LI G Q, YUAN C, WANG S, et al. Structural design of compound hydraulic swing cylinder based on co-evolution multi-objective genetic algorithm[J]. *Journal of Ship Mechanics*, 2022, 26(11): 1694–1704 (in Chinese). doi: 10.3969/j.issn.1007-7294.2022.11.012
- [12] 吴宽展, 刘学军, 吕宏强. 基于多输出高斯过程的超临界翼型优化[J]. *空气动力学学报*, 2015, 33(6): 728–732, 746. WU K Z, LIU X J, LYU H Q. A supercritical airfoil design based on multi-output surrogate model[J]. *Acta Aerodynamica Sinica*, 2015, 33(6): 728–732, 746 (in Chinese). doi: 10.7638/kqdlxxb-2014.0059
- [13] GAO M H, WU C B, LI B C, et al. Design and implementation of a

- Placido disk-based corneal topographer optical system based on aberration theory and simulated annealing algorithm[J]. *Optics Communications*, 2020, 475: 126097.
doi: [10.1016/j.optcom.2020.126097](https://doi.org/10.1016/j.optcom.2020.126097)
- [14] 程禹, 魏承, 游斌弟, 等. 基于蚁群的天基预警多目标优化算法[J]. *哈尔滨工程大学学报*, 2021, 42(10): 1428–1438.
CHENG Y, WEI C, YOU B D, et al. Multi-objective optimization algorithm of space-based early warning based on ant colony[J]. *Journal of Harbin Engineering University*, 2021, 42(10): 1428–1438 (in Chinese).
doi: [10.11990/jheu.202006027](https://doi.org/10.11990/jheu.202006027)
- [15] WANG Z, HU Z Y, YANG X F. Multi-agent and ant colony optimization for ship integrated power system network reconfiguration[J]. *Journal of Systems Engineering and Electronics*, 2022, 33(2): 489–496.
doi: [10.23919/JSEE.2022.000048](https://doi.org/10.23919/JSEE.2022.000048)
- [16] TAO J, SUN G. An artificial neural network approach for aerodynamic performance retention in airframe noise reduction design of a 3D swept wing model[J]. *Chinese Journal of Aeronautics*, 2016, 29(5): 1213–1225.
doi: [10.1016/j.cja.2016.08.008](https://doi.org/10.1016/j.cja.2016.08.008)
- [17] KIM T, KIM S, LIM J, et al. Numerical investigation of compressibility effect on dynamic stall[J]. *Aerospace Science and Technology*, 2020, 105: 105918.
doi: [10.1016/j.ast.2020.105918](https://doi.org/10.1016/j.ast.2020.105918)
- [18] 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 J, GAO Z H, HUANG J T, et al. Aerodynamic optimization system based on CST technique[J]. *Acta Aerodynamica Sinica*, 2012, 30(4): 443–449 (in Chinese).
doi: [10.3969/j.issn.0258-1825.2012.04.004](https://doi.org/10.3969/j.issn.0258-1825.2012.04.004)
- [19] ZHAO Z Z, SHKOLNISKY Y, SINGER A. Fast steerable principal component analysis[J]. *IEEE Transactions on Computational Imaging*, 2016, 2(1): 1–12.
doi: [10.1109/TCI.2016.2514700](https://doi.org/10.1109/TCI.2016.2514700)
- [20] PINAYA W H L, GADELHA A, DOYLE O M, et al. Using deep belief network modelling to characterize differences in brain morphometry in schizophrenia[J]. *Scientific Reports*, 2016, 6: 38897.
doi: [10.1038/srep38897](https://doi.org/10.1038/srep38897)
- [21] GHAAHABI O, HERNANDO J. Restricted Boltzmann machines for vector representation of speech in speaker recognition[J]. *Computer Speech & Language*, 2018, 47: 16–29.
doi: [10.1016/j.csl.2017.06.007](https://doi.org/10.1016/j.csl.2017.06.007)
- [22] BAGHAEI H R, MIRSALEM M, GHAREHPETIAN G B. Multi-objective optimal power management and sizing of a reliable wind/PV microgrid with hydrogen energy storage using MOPSO[J]. *Journal of Intelligent & Fuzzy Systems*, 2017, 32(3): 1753–1773.
doi: [10.3233/jifs-152372](https://doi.org/10.3233/jifs-152372)
- [23] LI G S, CHOU W S. Path planning for mobile robot using self-adaptive learning particle swarm optimization[J]. *Science China Information Sciences*, 2018, 61(5): 052204.
doi: [10.1007/s11432-016-9115-2](https://doi.org/10.1007/s11432-016-9115-2)
- [24] Raquel C R, Jr P C N. An effective use of crowding distance in multiobjective particle swarm optimization[C]// Genetic and Evolutionary Computation Conference, Washington DC, USA, 2005.
doi: [10.1145/1068009.1068047](https://doi.org/10.1145/1068009.1068047)
- [25] JESÚS, MOLINA-MUÑOZ. Market-crash forecasting based on the dynamics of the alpha-stable distribution[J]. *Physica A: Statistical Mechanics and Its Applications*, 2020, 557: 124876.
doi: [10.1016/j.physa.2020.124876](https://doi.org/10.1016/j.physa.2020.124876)
- [26] 李静威, 全厚德, 崔佩璋. 基于粒子群优化的偏斜 α 稳定分布参数估计[J]. *电波科学学报*, 2013, 28(1): 163–168.
LI J W, QUAN H D, CUI P Z. Parameter estimation for skewed α -stable distribution based on PSO[J]. *Chinese Journal of Radio Science*, 2013, 28(1): 163–168 (in Chinese).
- [27] CHEN L, XIN B, CHEN J. Interactive multiobjective evolutionary algorithm based on decomposition and compression[J]. *Science China (Information Sciences)*, 2021, 64(10): 166–181.
- [28] ZHAN D W, CHENG Y S, LIU J. Expected improvement matrix-based infill criteria for expensive multiobjective optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2017, 21(6): 956–975.
doi: [10.1109/TEVC.2017.2697503](https://doi.org/10.1109/TEVC.2017.2697503)
- [29] CHEN Y, WEN J Y, CHENG S J. Probabilistic load flow method based on nataf transformation and Latin hypercube sampling[J]. *IEEE Transactions on Sustainable Energy*, 2013, 4(2): 294–301.
doi: [10.1109/TSTE.2012.2222680](https://doi.org/10.1109/TSTE.2012.2222680)

(本文责编: 徐燕)