

采用知识迁移加速的智能气动设计优化方法

郭振东, 李存晰, 宋立明, 李军, 丰镇平

(西安交通大学能源与动力工程学院, 710049, 西安)

摘要: 为缩短精细气动形状设计优化所需的最少性能评估次数与任务周期内所能容许的最大性能评估次数之间的差距, 基于机器学习领域迁移学习理念, 开展了采用知识迁移加速的智能气动设计优化方法研究。首先, 搭建了翼型变分自编码器模型, 利用其解码器实现了气动形状的智能参数化, 同时借助其编码器将已完成任务样本统一至目标任务参数化空间; 其次结合单保真度和多保真度代理模型, 建立了贝叶斯迁移优化算法; 然后, 将翼型变分自编码器模型与贝叶斯迁移优化算法相结合, 搭建了智能气动形状迁移优化框架; 最后, 通过任务相关性分析对知识迁移加速优化过程的机理进行了讨论。研究表明: 通过开展翼型设计优化, 智能气动形状迁移优化框架所获得的最优解中位数相较于无知识迁移的变分自编码器优化方法, 性能提升了 4.8%, 比其他各参比方法提升了 19.9% 以上, 验证了该知识迁移策略的有效性。

关键词: 气动形状设计优化; 知识迁移; 变分自编码器; 贝叶斯优化; 多保真度代理模型

中图分类号: TK421.4 **文献标志码:** A

DOI: 10.7652/xjtuxb202310006 **文章编号:** 0253-987X(2023)10-0053-11

Knowledge Transfer-Accelerated Intelligent Aerodynamic Design Optimization

GUO Zhendong, LI Cunxi, SONG Liming, LI Jun, FENG Zhenping

(School of Energy and Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the gap between the minimum number of evaluations required for refined aerodynamic shape optimization tasks and the maximum number of evaluations constrained by the mission period, a study on intelligent aerodynamic design optimization accelerated by knowledge transfer was conducted based on the concept of transfer learning in the field of machine learning. Firstly, an airfoil variational autoencoder (VAE) model was built. The model's decoder enabled the intelligent parameterization of aerodynamic shapes, while its encoder unified samples from source tasks into the parameterization space of the target task. Secondly, the Bayesian transfer optimization algorithm was established, incorporating both single and multi-fidelity surrogate models. Then, an intelligent transfer optimization framework for aerodynamic shapes was established by integrating the airfoil VAE model and Bayesian transfer optimization algorithm. Last, task correlation analysis was made to discuss the mechanism of the optimization process accelerated by knowledge transfer. The results from airfoil optimization test demonstrate that such a framework improves the performance of median of the optimal solution by 4.8% compared to

using VAE optimization lack of knowledge transfer, and by more than 19.9% compared to other methods, confirming the effectiveness of knowledge transfer strategy.

Keywords: aerodynamic shape optimization; knowledge transfer; variational autoencoder; Bayesian optimization, multi-fidelity surrogate model

气动形状优化作为飞机翼型和航空发动机叶片设计的重要环节,一直是国内外学者研究和关注的重点^[1-4]。飞机翼型和航空发动机叶片的形状多采用自由曲线/曲面设计,由于设计时输入设计参数与输出目标性能之间的函数关系无法用显式表达^[5],且气动性能评估通常非常耗时,所以是典型的昂贵黑盒子问题^[6]。通常,气动形状优化包括 3 个关键环节,即气动形状设计空间参数化、优化算法和性能评估。常用的参数化方法包括非均匀有理 B 样条(non-uniformed rational B-spline, NURBS)法、自由网格形变(free-form deformation, FFD)法等^[7]。近年来,基于深度学习的智能参数化方法如 Bezier-GAN 法^[8]、AirfoilGAN 法^[9]等亦被提出用于翼型参数化建模。在确定气动形状设计空间后,代理模型优化算法等全局类优化算法被广泛用于气动设计空间寻优^[10-11],而计算流体力学(computational fluid dynamics, CFD)方法则被用于对优化个体进行性能评估。

随着气动形状设计要求的不断提高,精细气动形状设计优化面临如下困境:一方面,为满足日益苛刻的性能指标要求,设计人员往往会增加参数化设计空间的维度,以期实现更精细的气动型线调整,囊括性能更优的设计样本^[12],但随着设计空间变量维度的增加,采用全局类优化算法探寻设计空间最优解所需样本的评估次数将以指数形式急剧增加^[10-13];另一方面,日益精细的气动形状设计通常采用非定常计算等更高精度的 CFD 评估手段对飞机翼型、航空发动机叶片进行性能评估^[14-15],而非定常计算等高精度评估方法相对于传统常用的定常计算,所需的计算资源急剧增加,在规定的任务周期内所能容许的高精度性能评估次数非常有限。为此,如何平衡上述两个方面的矛盾,即如何缩短“精细化设计优化所需的最少性能评估次数”与“任务周期内所能容许的最大性能评估次数”之间的差距,是当前气动形状设计优化方法研究无法回避的难题。

另外需要特别指出的是,在当前绝大多数气动形状设计优化过程中,当优化目标和参数化设计空间确定后,优化算法往往“从零开始”对设计空间寻优。与此类传统优化方法不同的是,设计人员通常能不断地从已完成的任务中提取经验,用于指导新

任务的求解^[16-17]。受到上述启发,“知识迁移”理念在机器学习及计算智能领域得到了广泛关注,相关研究又被称为“迁移学习(transfer learning)”^[17]和“迁移优化(transfer optimization)”^[18-19],其核心思路是让机器学会像人一样累积经验,从已完成的类似任务中智能汲取有用信息,用于减少目标任务求解成本,并进一步提升目标任务优化解性能。

近年来,知识迁移理念在航空发动机设计领域亦受到重视^[20-21],Rolls-Royce 研究团队已着手于将知识迁移理念用于航空发动机总体设计建模,测试结果表明相对于传统方法,采用知识迁移策略可将设计效率提升 80%^[22]。然而,将知识迁移理念推广到飞机翼型、航空发动机叶片形状的设计优化时,仍需解决如下两个方面的问题:①如何将已完成的类似任务优化解集编码至目标任务参数化设计空间,即如何将已采用 NURBS、FFD 及 Bezier-GAN 等不同方法进行参数化建模的已完成任务优化解编码至目标任务参数化设计空间;②如何提取已完成任务样本中所包含的有用设计信息,用于促进目标优化任务的求解。

针对以上两方面问题,本文采用深度学习模型变分自编码器(variational autoencoder, VAE)^[23],将已完成的相关任务优化解集编码至目标任务参数化设计空间;接着,采用多保真度高斯过程^[24-25]从已完成任务的样本中提取有用信息,促进目标任务的求解;最后基于上述思路,建立了气动形状迁移优化方法,并通过基准数值算例开展测试与翼型气动型线优化分析,验证了知识迁移策略的有效性。

1 迁移优化简介

如图 1 所示,迁移优化的基本思路即让优化算法像人一样累积经验,从已完成的相关任务 $S_1, \dots, S_m$ 中汲取有用信息,并形成知识库 $K(t)$,用于指导目标任务 T 的求解^[18]。相应的目标优化任务表达式可表示如下

$$T = \min_{x \in \chi} f(x) \quad (1)$$

$$\begin{cases} \min\{T \mid S_1, \dots, S_m, K(t)\} \\ S_m = \min_{x_m \in \chi_m} f_m(x_m) \end{cases} \quad (2)$$

式中： f_m 和 χ_m 分别为相关任务 S_m 所对应的目标函数及参数化设计空间。




图 1 迁移优化原理示意图

Fig. 1 Schematic of transfer optimization

除经典的迁移优化方式外,在同一问题的不同形式间相互汲取有用信息的多平台迁移优化亦被提出,其原理如图 2 所示。多平台迁移优化原理的基本思路为寻找可对目标任务 T 进行简化的问题 $T_1, \dots, T_k$, 和目标任务 T 一起求解,并在优化过程中不断从 $T_1, \dots, T_k$ 以及 T 中提取有用设计信息,形成知识库 $K(t)$,以促进各任务的求解,最终实现提高目标任务 T 的优化效率。其相关表达式如下

$$\begin{cases} \min\{T \mid T_1, \dots, T_k, K(t)\} \\ T_k = \min_{x_k \in \chi_k} g_k(x_k) \end{cases} \quad (3)$$

式中： g_k 为近似问题 T_k 对应的目标函数； χ_k 为相应的设计空间,可与目标任务的设计空间 χ 相同,也可为 χ 的子空间。




图 2 多平台迁移优化原理示意图

Fig. 2 Schematic of multi-form transfer optimization

2 知识迁移加速的气动设计优化方法

采用知识迁移加速的智能气动设计优化方法包括两个环节:气动形状设计空间参数化和迁移优化算法。下面将在 2.1 节和 2.2 节对所提出的采用 VAE 模型的气动形状参数化方法与贝叶斯迁移优化算法进行介绍,进而在 2.3 节对所发展的气动型线迁移优化设计框架进行说明。

2.1 采用 VAE 模型的形状参数化方法

图 3 展示了 VAE 形状参数化方法的原理图。

VAE 模型包含 χ 和 ζ 两个变量空间,由编码器和解码器两个神经网络组成^[23]。其中, χ 为以散点坐标表示的高维设计空间, ζ 为由数个或数十个变量构建的低维参数化设计空间。VAE 编码器的功能是将 χ 中以散点坐标表示的样本 x 降维编码至低维空间 ζ ,生成样本 z ,即实现 $x \rightarrow z$ 的映射;而与之相反,解码器的功能是在已知参数空间 ζ 中样本 z 的情况下,重构对应的以散点坐标表示的型线样本 $\hat{x}$,实现 $z \rightarrow \hat{x}$ 的映射。




图 3 VAE 模型气动形状参数化方法原理图

Fig. 3 Schematic of VAE-based aerodynamic shape parameterization method

采用 VAE 形状参数化方法的训练过程如下:首先,收集气动型线样本,构建采用统一散点坐标格式表征的样本数据集 X ;然后,确定参数化设计空间 ζ 的维度,结合数据集 X ,进行 VAE 模型训练。在训练过程中,从数据集 X 中批量采集样本,利用编码器和解码器完成 $x \rightarrow z \rightarrow \hat{x}$ 的映射,并根据 x 与 $\hat{x}$ 之间的均方根误差对编码器和解码器神经网络权重系数进行调整,最终实现 $x \rightarrow z$ 和 $z \rightarrow \hat{x}$ 的精确映射。

结合 UIUC 翼型数据集^[8],开展基于 VAE 的形状参数化模型训练,并进行 $x \rightarrow z$ 和 $z \rightarrow \hat{x}$ 的映射测试,过程如图 4 所示。其中,实线为以散点坐标表示的原始型线样本 x ,虚线为利用 VAE 编码器和解码器依次进行 $x \rightarrow z$ 和 $z \rightarrow \hat{x}$ 映射所得到的重构样本 $\hat{x}$ 。可以看出, $\hat{x}$ 与 x 吻合良好,表明 VAE 模型能精确实现型线样本在 χ 和 ζ 两个空间的相互转换。




图 4 VAE 编码器和解码器的映射过程精度校验

Fig. 4 Precision verification of the mapping process using Encoder and Decoder of VAE

在传统的设计优化过程中,设计人员往往采用 NURBS、FFD 等方法获得低维参数化设计空间 ζ , 进而在 ζ 空间开展型线优化设计。在完成型线优化设计后,设计人员往往会保留以散点坐标表征的真实型线样本 $\mathbf{x}$ 及其性能分析结果文件,却很少保留对应的低维参数化空间样本 $\mathbf{z}$ 。然而,NURBS、FFD 等传统参数化方法无法实现从 $\mathbf{x} \rightarrow \mathbf{z}$ 的转换,即很难将已完成任务所获得的优秀型线样本编码至目标任务参数化设计空间。当且仅当已完成任务与目标任务样本可用相同的 FFD、NURBS 参数化空间表示时,已完成任务样本才能被用于目标任务设计过程,这严重限制了迁移优化策略在气动型线设计优化中的应用。

然而,图 3 所示的基于 VAE 模型的型线参数化方法,可轻松实现样本在高维散点坐标空间 χ 和低维参数化空间 ζ 之间的相互转换。也就是说,在已完成的类似任务采用 FFD、NURBS 等不同参数化方法的情况下,仍可采用 VAE 编码器,将对应已完成任务的优秀样本 $\mathbf{x}$ 编码至目标任务参数化设计空间 ζ 。因此,VAE 参数化方法为扩展迁移优化策略在气动设计优化中的应用提供了契机。

2.2 贝叶斯迁移优化 TGO 算法

在建立 VAE 参数化设计空间实现了将已完成任务样本统一编码至目标任务参数化空间后,仍需解决如何提取已完成任务样本中的有用信息用于加速目标任务的优化进程这一问题。为此,在贝叶斯优化框架下,将基于多保真度高斯过程的序列迁移优化策略与多平台迁移优化策略相结合,研发了贝叶斯迁移优化算法 (transfer learning accelerated efficient global optimization, TGO)。以下将对 TGO 算法所采用的迁移优化策略及其优化流程进行介绍,并应用算例进行测试。

2.2.1 基于多保真度模型的序列迁移优化

在目标任务参数化设计空间中,假定已完成任务样本集为 $\{\mathbf{z}_S, \mathbf{y}_S\}_m$,目标任务样本为 $\{\mathbf{z}_T, \mathbf{y}_T\}_n$ 。基于多保真度模型的序列迁移优化策略的基本思路为,将 $\{\mathbf{z}_S, \mathbf{y}_S\}_m$ 作为目标任务的低保真度样本,利用多保真度高斯过程将 $\{\mathbf{z}_S, \mathbf{y}_S\}_m$ 与 $\{\mathbf{z}_T, \mathbf{y}_T\}_n$ 进行数据融合。上述过程能有效地提高贝叶斯寻优代理模型的预测精度,特别是代理模型在最优值邻域内的预测精度,由此加速目标任务优化进程。

参照原始模型推导过程^[26],用于融合 $\{\mathbf{z}_S, \mathbf{y}_S\}_m$ 与 $\{\mathbf{z}_T, \mathbf{y}_T\}_n$ 的多保真度高斯过程预测模型可表示

如下

$$\begin{cases} \hat{\mathbf{y}}_M(\mathbf{z}) = \mathbf{k}_M(\mathbf{z}, \mathbf{Z}^*) \mathbf{K}_M^{-1} \begin{bmatrix} \mathbf{y}_T \\ \mathbf{y}_S \end{bmatrix} \\ \sigma_M^2(\mathbf{z}) = \mathbf{k}_M(\mathbf{z}) - \mathbf{k}_M(\mathbf{z}, \mathbf{Z}^*) \mathbf{K}_M^{-1} \mathbf{k}_M(\mathbf{Z}^*, \mathbf{z}) + \sigma_n^2 \end{cases} \quad (4)$$

式中: $\mathbf{z}$ 为目标任务参数化设计空间样本; $\hat{\mathbf{y}}_M$ 和 σ_M^2 分别为多保真度高斯过程在 $\mathbf{z}$ 处目标函数的预测值与预测值的均方根误差; $\mathbf{Z}^*$ 为已完成任务样本 $\{\mathbf{z}_S\}_m$ 和目标任务样本 $\{\mathbf{z}_T\}_n$ 组成的样本矩阵; $\mathbf{k}_M$ 和 $\mathbf{K}_M$ 分别为多保真度高斯过程协方差向量和协方差矩阵; σ_n 为高斯白噪声项。

在构建多保真度代理模型的基础上,通过最大化期望提升 (expected improvement, EI) 函数对目标函数设计空间进行贝叶斯寻优,其具体表达式如下

$$\begin{cases} f_{EI}^M(\mathbf{z}) = (\mathbf{y}_{PBS} - \hat{\mathbf{y}}_M(\mathbf{z})) \Phi(u) + \sigma_M(\mathbf{z}) \varphi(u_M) \\ u_M = (\mathbf{y}_{PBS} - \hat{\mathbf{y}}_M(\mathbf{z})) / \sigma_M(\mathbf{z}) \end{cases} \quad (5)$$

式中: $\mathbf{y}_{PBS}$ 为当前所获得的最优目标函数值; $\Phi(\cdot)$ 和 $\varphi(\cdot)$ 分别为高斯累积分布函数和密度分布函数; $\sigma_M(\mathbf{z})$ 为多保真度高斯过程在 $\mathbf{z}$ 处目标函数预测值的标准差。

2.2.2 多平台迁移优化与 TGO 算法流程

在优化后期,随着目标任务样本增加,直接采用目标任务样本构建的单保真度代理模型精度可能会比融合已完成任务、目标任务样本所构建的多保真度代理模型精度更高^[24]。为尽可能提高用于贝叶斯寻优的代理模型精度,进而加速目标任务求解,在图 2 所示多平台迁移优化思想的启发下,提出同时开展基于单保真度模型和多保真度模型的设计空间寻优。直接采用目标任务样本 $\{\mathbf{z}_T, \mathbf{y}_T\}_n$ 所构建的单保真度预测模型表达式如下^[26-27]

$$\begin{cases} \hat{\mathbf{y}}_S(\mathbf{z}) = \mathbf{k}(\mathbf{z}, \mathbf{Z}_T) (\mathbf{K}_T + \sigma_{n,T}^2 \mathbf{I})^{-1} \mathbf{y}_T \\ \sigma_S^2(\mathbf{z}) = \mathbf{k}(\mathbf{z}) - \mathbf{k}(\mathbf{z}, \mathbf{Z}_T) (\mathbf{K}_T + \sigma_{n,T}^2 \mathbf{I})^{-1} \mathbf{k}(\mathbf{Z}_T, \mathbf{z}) + \sigma_n^2 \end{cases} \quad (6)$$

式中: $\mathbf{k}$ 和 $\mathbf{K}$ 分别为单保真度高斯过程协方差向量和协方差矩阵; $\mathbf{Z}_T$ 为目标任务设计空间变量; $\sigma_{n,T}^2$ 为 $\{\mathbf{z}_T, \mathbf{y}_T\}_n$ 中的白噪声项; $\mathbf{I}$ 为单位对角矩阵; $\mathbf{K}_T$ 为仅使用目标问题样本构建的协方差矩阵。

在完成单保真度代理模型构建后,通过最大化 EI 函数进行设计空间寻优,表达式可写为

$$\begin{cases} f_{EI}^S(\mathbf{z}) = (\mathbf{y}_{PBS} - \hat{\mathbf{y}}_S(\mathbf{z})) \Phi(u) + \sigma_S(\mathbf{z}) \varphi(u_S) \\ u_S = (\mathbf{y}_{PBS} - \hat{\mathbf{y}}_S(\mathbf{z})) / \sigma_S(\mathbf{z}) \end{cases} \quad (7)$$

由于同时进行单保真度与多保真度代理模型寻优,在多保真度框架下每次优化迭代将更新 2 个样本,相关表达式如下

$$\mathbf{Z}^{\text{new}} = \{\text{argmax}_{f_{\text{El}}^{\text{S}}(\mathbf{z})}, \text{argmax}_{f_{\text{El}}^{\text{M}}(\mathbf{z})}\} \quad (8)$$

式中 $\mathbf{Z}^{\text{new}}$ 为每步迭代将采样的个体。

图 5 给出了本文所提出 TGO 算法的流程图。其中,实线方框对应传统无知识迁移的经典代理模型优化(efficient global optimization, EGO) 算法的执行流程,即仅利用目标任务样本 $\{\mathbf{z}_{\text{T}}, \mathbf{y}_{\text{T}}\}_n$ 构建单保真度代理模型,进而基于式(7)进行设计空间寻优。在 EGO 算法的基础上, TGO 算法融入了基于多保真度代理模型的寻优过程,开展针对同一优化问题的“多任务”寻优过程,并在每次优化结束时,通过交换最优解,用于单、多保真度模型更新,来实现“多任务”信息交换,达到提升优化效率的目的。

2.2.3 数值算例测试

鉴于迁移优化与多保真度优化的相似性,选取经典的多保真度优化基准测试算例,对 TGO 算法的有效性进行测试,相关函数表达式如表 1 和表 2 所示。可以看到,多保真度优化测试中采用的低保真度函数被当作了迁移优化测试的已完成任务函数。




图 5 本文所提出 TGO 算法流程
Fig. 5 Flowchart of TGO algorithm

表 1 用于 TGO 算法测试的目标任务与已完成任务表达式

Table 1 Expression of target and source tasks for testing the TGO algorithm

函数名称	目标任务函数	已完成任务目标函数
基准函数 1	Ackley5	Ackley5 + 0.74MA5
基准函数 2	Hartman6	Hartman6 + 0.21MA6

表 2 测试函数表达式

Table 2 Mathematical expressions of testing functions

函数名称	函数表达式
Ackley5	$f_{\text{Ackley}}(\mathbf{x}) = -a \exp\left(-b \sqrt{\frac{1}{d} \sum_{i=1}^d x_i^2}\right) - \exp\left(\frac{1}{d} \sum_{i=1}^d \cos(cx_i)\right) + a + \exp(1)$ $a=20, b=0.2, c=2\pi, x_i \in [-2, 2], i=1, \dots, 5$
Hartman6	$f_{\text{Hartman6}}(\mathbf{x}) = -\sum_{i=1}^4 w_i \exp\left(-\sum_{j=1}^6 M_{ij} (x_j - P_{ij})^2\right), \mathbf{w} = [1.0, 1.2, 3.0, 3.2]^T$ $\mathbf{M} = \begin{bmatrix} 10 & 3 & 17 & 3.50 & 1.70 & 8 \\ 0.05 & 10 & 17 & 0.10 & 8 & 14 \\ 3 & 3.50 & 1.70 & 10 & 17 & 8 \\ 17 & 8 & 0.05 & 10 & 0.10 & 14 \end{bmatrix}; \mathbf{P} = 10^{-4} \begin{bmatrix} 1 & 312 & 1 & 696 & 5 & 569 & 124 & 8 & 283 & 5 & 886 \\ 2 & 329 & 4 & 135 & 8 & 307 & 3 & 736 & 1 & 004 & 9 & 991 \\ 2 & 348 & 1 & 451 & 3 & 522 & 2 & 883 & 3 & 047 & 6 & 650 \\ 4 & 047 & 8 & 828 & 8 & 732 & 5 & 743 & 1 & 091 & 381 \end{bmatrix}$
MA5	$f_{\text{MA5}}(\mathbf{x}) = 0.585 - 0.001\,27x_1 + 0.001\,13x_2 + 0.006\,63x_3 + 0.012\,9x_4 + 0.006\,11x_5 + 0.005\,26x_1x_4 + 0.010\,6x_1x_5 - 0.000\,626x_2x_4 - 0.003\,10x_2x_5 - 0.007\,24x_4x_5 + 0.000\,96x_3^2 + 0.012\,4x_1^2 + 0.010\,1x_5^2$
MA6	$f_{\text{MA6}}(\mathbf{x}) = 0.544 + 0.159\,84x_1 + 0.188\,57x_2 + 0.023\,71x_3 - 0.041\,44x_4 + 0.331\,3x_5 - 0.118\,13x_6 - 0.037\,19x_1x_2 + 0.030\,99x_2x_3 - 0.050\,4x_3x_6 - 0.031\,03x_4x_5 + 0.193\,45x_1x_6 - 0.263\,5x_1^2 - 0.176\,94x_2^2 - 0.235\,28x_5^2$

由于在实际场景中,已完成任务样本 $\{z_s, y_s\}_m$ 的设计空间分布特征无法事先确定,为模拟上述情形,对表 1 所示已完成任务样本开展贝叶斯优化,将优化完成时所生成的样本集作为 $\{z_s, y_s\}_m$ 的候选数据库。此外,注意到用于迁移优化的多保真度建模的核心任务,是利用已完成任务与目标任务的相似性,提高用于贝叶斯寻优的代理模型在设计空间最优值邻域内的预测精度。为此,借鉴 Wang 等迁移优化研究经验^[21],采用最优解准则筛选出已完成任务样本用于 TGO 优化,即根据目标函数对已完成任务样本进行排序,选取性能最优的数十个样本,用于 TGO 算法中的多保真度建模过程。

在对 TGO 算法和传统无知识迁移的 EGO 算法进行测试时,通常采用指数型高斯核函数^[28]构建单保真度和多保真度代理模型,采用拉丁超立方抽样技术对目标任务进行初始采样,初始样本数量设置为测试函数维度 d 的 4 倍。在构建多保真度代理模型时,已完成任务样本数量 m 保持与目标任务初始采样样本量相同,即 $m = 4d$,则优化迭代所允许的总样本评估次数为 $15d$ 。此外,由于测试函数最优值已知,采用 $R_t = f_{\min}^{(t)} - \min f(\mathbf{x})$ 来衡量算法的收敛速度,其中 $f_{\min}^{(t)}$ 为第 t 次迭代算法所得到的最优值, $\min f(\mathbf{x})$ 为测试函数 $f(\mathbf{x})$ 的理论最优值。

对基准测试函数分别开展 10 次测试计算,图 6 分别展示了 TGO 和 EGO 算法的均值收敛图,表 3 展示了 10 次优化所获得的最优解均值及标准差。易见,相较于传统无知识迁移的 EGO 算法, TGO 算法收敛速度更快,获得的优化解更优,且 10 次优化的最优解均值和标准差均显著小于 EGO 算法,由此验证了所提出的采用知识迁移加速的 TGO 算法的有效性。




图 6 2 种算法的基准函数优化测试收敛过程

Fig. 6 Convergence history of benchmark testing functions for two algorithms

表 3 2 种算法的基准函数算例测试结果

Table 3 Testing results of benchmark functions for two algorithms

测试函数	算法	最优解均值	最优解标准差
基准函数 1	EGO	0.614 7	0.904 9
	TGO	0.030 1	0.012 3
基准函数 2	EGO	0.055 2	0.032 3
	TGO	7.224×10^{-6}	4.082×10^{-6}

2.3 采用知识迁移加速的设计优化框架 VAE-TGO 方法

将基于 VAE 的形状参数化方法与 TGO 算法相结合,研发了气动型线迁移优化框架,并将其命名为 VAE-TGO 方法,如图 7 所示。VAE-TGO 方法的基本流程如下:首先收集型线样本,构建基于 VAE 的型线参数化模型;然后基于 VAE 解码器,在 VAE 低维参数化设计空间 ζ 进行样本采集,生成目标任务样本集 $\{z_T, y_T\}_n$ 。另一方面,基于 VAE 编码器,将以散点坐标表示的已完成任务样本 $\{x_s, y_s\}_m$ 编码至目标任务参数化设计空间,生成 $\{z_s, y_s\}_m$ 。上述过程又称为已完成任务样本重参数化,如图 7 中虚线框所示。最后进一步耦合 $\{z_T, y_T\}_n$ 和 $\{z_s, y_s\}_m$, 基于 TGO 算法流场开展型线设计空间寻优。




图 7 VAE-TGO 方法设计优化框架

Fig. 7 VAE-TGO design optimization framework

采用 NURBS 和 FFD 等传统参数化方法替代图 7 中的 VAE 参数化方法,可构建基于传统参数化方法的知识迁移优化框架,分别命名为 NURBS-TGO 和 FFD-TGO 方法。但与 VAE-TGO 方法不同,NURBS-TGO 和 FFD-TGO 方法难以将散点坐标表示的样本重参数化至目标任务参数化设计空间,因而 NURBS-TGO 和 FFD-TGO 方法仅在目标任务与已完成任务样本具有相同参数化设计空间的情形进行。

3 气动型线迁移优化典型案例测试

本节以跨声速翼型设计优化为例,对搭建的 VAE-TGO 方法的有效性进行验证。

3.1 目标优化问题及迁移源任务描述

参照相关研究工作^[8,27],选取最大化翼型升阻比 C_L/C_D (C_L 为升力系数, C_D 为阻力系数) 为目标任务的优化目标函数,选取优化工况为 $Ma = 0.75$, $Re = 6.5 \times 10^5$, 迎角 $\alpha = 0^\circ$ 。为满足结构强度要求,以 RAE2822 翼型作为参考设计,要求优化翼型截面积不小于参考面积的 90%。对应的优化模型可表示为

$$\begin{cases} \min f(\mathbf{z}) = \min -C_L/C_D(\mathbf{z}) \\ \text{s. t. } A(\mathbf{z}) \geq 0.9A_{\text{RAE2822}} \\ Ma = 0.75, Re = 6.5 \times 10^5, \alpha = 0^\circ \end{cases} \quad (9)$$

式中: $A(\mathbf{z})$ 和 A_{RAE2822} 分别为优化设计和参考设计的翼型截面积。

与此同时,用于知识迁移的已完成任务工况假定为 $Ma = 0.45$, $Re = 3.5 \times 10^5$, 迎角 $\alpha = 0^\circ$ 。

3.2 优化过程相关设置

3.2.1 XFOIL 性能评估求解器

选取广泛使用的 XFOIL 求解器,对优化过程中生成的翼型进行气动性能评估^[28]。该软件理论基础为基于小扰动势流理论的面源法,以位于边界层位移厚度内流和外流的边界条件为迭代收敛的标志。由于 XFOIL 求解器对小攻角条件下的翼型扰流问题计算精度较高,被广泛应用于翼型设计优化性能的评估过程^[8-9,29-30]。图 8 展示了 RAE2822 翼型在工况条件为 $Ma = 0.676$, $Re = 5.7 \times 10^5$, 迎角 $\alpha = 2.4^\circ$ 下, XFOIL 求解器的数值计算结果与文献^[28]中实验结果的对比。由图可见, XFOIL 求解器得到的数值解与实验结果吻合良好,可满足优化设计过程中性能评估的精度要求。

3.2.2 优化方法相关设置

为验证知识迁移策略的有效性,分别采用知识迁移策略的优化方法与无知识迁移的传统优化方法求解式(9)所示的目标任务。除 VAE 参数化方法




图 8 XFOIL 求解器计算结果与实验结果^[28]对比

Fig. 8 Comparison of results of XFOIL and experimental data

外, NURBS 和 FFD 等传统方法亦被用于跨声速翼型参数化建模。其中,采用已完成任务样本进行知识迁移加速的优化过程被分别命名为 VAE-TGO、NURBS-TGO 和 FFD-TGO 方法,而不采用已完成任务样本进行知识迁移的传统优化过程则被命名为 VAE-EGO、NURBS-EGO 和 FFD-EGO 方法。

在进行翼型设计空间参数化建模时, VAE 将以 UIUC 数据集作为训练样本集, VAE 参数空间 ζ 的变量维度为 10。NURBS 和 FFD 参数化建模将以 RAE2822 翼型作为参考型线, 参考陈伟等^[8]相关工作完成 NURBS 与 FFD 方法的参数化空间设置。

注意到在已完成任务场景中, 样本 $\{\mathbf{x}_s, \mathbf{y}_s\}_m$ 的分布特征依根据算法寻优过程而定, 无法事先设置且不能人为更改。为模拟上述已完成任务场景, 在参数化建模的基础上开展工况条件为 $Ma = 0.45$, $Re = 3.5 \times 10^5$, 迎角 $\alpha = 0^\circ$ 的气动型线优化设计, 所生成对应的优化样本将作为 $\{\mathbf{x}_s, \mathbf{y}_s\}_m$ 的候选样本集。为模拟已完成任务样本可能来自不同参数化空间的情形, 从已完成任务优化解集中选取 40 个性能最优的个体 $\{\mathbf{x}_s, \mathbf{y}_s\}_{40}$, 按照图 7 所示流程, 采用 VAE 编码器对已完成任务样本重参数化, 在获得目标参数空间样本 $\{\mathbf{z}_s, \mathbf{y}_s\}_{40}$ 后开展迁移优化。


与 VAE-TGO 方法不同, 由于 NURBS 和 FFD 方法难以将散点坐标表示的型线样本编码至目标任务参数化设计空间, 因而在采用 NURBS 和 FFD 方法完迁移源任务优化后, 直接从已完成任务优化解集中选取性能最优的 40 个样本 $\{\mathbf{z}_s, \mathbf{y}_s\}_{40}$, 用于 NURBS-TGO 和 FFD-TGO 方法的优化过程。

在 EGO 和 TGO 算法设置方面, 相关参数设置与 2.2.3 节标准算例保持一致, 即采用指数型高斯核函数分别构建单保真度和多保真度代理模型。同时, 采用拉丁超立方抽样技术生成 40 个目标任务的


初始样本,优化过程所允许的总样本评估次数设为140。

3.3 结果分析

基于3.2节相关设置,采用VAE-TGO等不同优化方法,对独立抽取的初采样和迁移源样本开展10次优化,得到的优化结果如图9所示。由于采用拉丁超立方抽样技术所生成的目标任务初始样本的分布不同,因而10次优化所得到的最优解存在差异。图9(a)和(b)分别展示了10次优化平均结果收敛过程和所得到的最优解分布。



(a) 平均优化结果收敛曲线



(b) 最优解统计箱线图

图9 不同优化设计方法10次优化后的结果对比

Fig. 9 Comparison of optimization results of different approaches over 10 runs

相较而言,采用VAE方法的翼型优化结果在优化收敛速度和最优解性能方面均显著优于基于NURBS和FFD方法所得到的优化结果,这和李继超等^[1]、陈伟等^[8]获得的结果相类似。由于NURBS和FFD等传统参数化方法需先选定参考型线,所构建的参数空间型线样本形状往往需要对参考翼型进行小幅度调整,因而参数空间内性能优异的型线样本相对匮乏。相反地,基于VAE模型的参数化方法将囊括了从低速翼型到跨声速翼型等各类类型线的UIUC数据库作为训练数据,且VAE深度学习模型的非线性特征捕捉能力强,可较

好地捕捉数据库中各类翼型的几何特征,因而使得VAE参数空间样本多样性强,且所囊括的性能优异的型线样本更为丰富。因此,基于VAE方法的优化收敛曲线从初始阶段开始,所得到的最优解即显著优于FFD和NURBS方法的优化结果。

基于相同的参数化模型,将TGO方法的优化结果与无知识迁移的EGO方法的优化结果进行比较后可知,对于所采用的VAE、FFD、NURBS这3种参数化方法,TGO方法的优化过程在优化进程和取得最优解两个方面均明显优于无知识迁移的EGO方法的优化过程。由此表明,本文提出的多保真度迁移优化策略与多平台迁移优化策略能有效提取已完成任务优化解集中有用的设计信息,从而显著提高目标任务的求解速度与最优解性能。

在进一步探究采用知识迁移策略的有效性之前,以最优解集中的中位数作为代表,对采用不同优化方法所得到的最优型线进行气动分析。图10展示了RAE翼型和中位数解所对应的气动型线。由图可见,相较于RAE2822翼型,优化后的翼型弯曲程度明显增加,靠近尾缘的区域曲线上凹趋势最为明显,此区域型线的变化有利于在吸力面增大气流速度、降低当地静压,在压力面降低气流速度且提高当地静压,从而达到显著提升翼型升力的目的。表4给出了不同设计方法得到的最优设计性能对比,可见相较于RAE2822翼型,优化后翼型的升力系数和升阻比均显著增加,但优化翼型阻力系数却略有增加,这与式(9)所选取的目标函数有关。在未来的优化研究中,加入关于阻力系数的约束条件有望解决上述不足。




图10 不同优化设计方法的中位数结果型线对比


Fig. 10 Comparison of median result airfoils from different design approaches

图11进一步展示了不同翼型表面的压力系数分布。由图可见,相较于RAE2822翼型,优化后翼型的载荷明显提升,这与表4中各优化解所对应的升力系数显著提升的结果吻合较好。与此同时,从


各优化翼型表面压力系数分布易见,翼型表面流动组织良好,没有出现大迎角和大分离的情况,表明优化后的翼型气动性能良好。

表 4 不同设计方法得到的最优设计性能对比
Table 4 Performance comparison of optimized solutions obtained by different design methods

方法	C_L	C_D	$C_L \cdot C_D^{-1}$
RAE2822	0.308 1	0.008 70	35.410
NURBS-EGO	0.655 7	0.008 69	75.455
NURBS-TGO	0.734 2	0.008 86	82.867
FFD-EGO	0.988 0	0.011 13	88.769
FFD-TGO	1.087 6	0.011 13	97.718
VAE-EGO	1.206 4	0.010 72	112.540
VAE-TGO	1.262 9	0.010 71	117.920



(a)未使用知识迁移策略



(b)使用知识迁移策略

图 11 不同优化型线表面静压系数分布

Fig. 11 Distribution of static pressure coefficient of airfoils

3.4 迁移优化机理讨论

在验证优化解性能有效性的基础上,本节对知识迁移可加速目标任务优化进程的原因进行了探究。采用 VAE 参数化模型生成 1 024 个型线样本,分别计算已完成任务工况和目标任务工况下同一翼型的升阻比,并对其进行相关性分析,得到的结果如图 12 所示。由图可见,皮尔逊相关系数为 0.911 0,表明对于 $Ma=0.75$ 的目标任务工况与 $Ma=0.4$

的已完成任务工况,翼型表面流动存在一定的相似性,这与描述亚声速翼型流动相似性的普朗特-葛劳渥法则吻合较好^[31],即在迎角不变的情况下,不同工况下翼型的表面静压系数分布可近似地按来流马赫数的单值函数缩放。这一流动相似性法从理论上佐证了已完成任务与目标任务间的相关性。




图 12 同一翼型不同工况下的性能指标相关性
Fig. 12 Correlation between performances of identical airfoil under different working conditions

在验证目标优化任务与已完成任务流动相似性的基础上,对采用知识迁移可加速目标任务优化进程的机理可作如下解释:一方面,在目标任务与已完成任务相似性较高的前提下,将已完成任务样本与目标任务样本耦合后构建多保真度代理模型,可有效提高用于捕捉设计空间全局趋势的代理模型精度,进而加速目标任务的求解;另一方面,已完成任务与目标任务流动的相似性表明,已完成任务与目标任务的最优解分布在设计空间相同的邻域。因此,将已完成任务样本加入到目标任务建模与求解过程中,可帮助优化求解器更快地到达目标任务最优解邻域,从而加速目标任务优化进程。

4 结 论

受机器学习领域迁移学习理念的启发,将深度学习模型 VAE 和贝叶斯优化算法相结合,采用知识迁移加速研发了智能气动形状设计优化方法,主要获得以下结论。

(1) 相对于 NURBS、FFD 等传统参数化方法,采用 VAE 方法所构建的翼型参数化设计空间样本的多样性更强,表明基于 VAE 方法的优化设计结果显著优于基于传统参数化方法所获得的优化解。此外,VAE 编码器结构可将采用不同参数化方法建模的已完成任务样本编码至相同的参数化设计空

间,为拓展迁移优化方法在气动形状设计领域的应用提供契机。

(2) 数值算例与翼型气动型线优化的分析结果表明,将多保真度建模的序列迁移策略与多平台迁移优化策略相结合,可充分挖掘已完成任务样本中所包含的有用设计信息,从而显著加速目标任务优化进程,得到的最优解性能明显优于无知识迁移的传统优化方法优化解。

为验证知识迁移策略的有效性,本文主要针对翼型的气动性能展开优化设计,但该方法可通用于考虑结构强度约束的翼型多学科设计优化问题,并可推广至航空发动机叶片二维及三维多学科设计优化。

参考文献:

- [1] LI Jichao, ZHANG Mengqi, MARTINS J R R A, et al. Efficient aerodynamic shape optimization with deep-learning-based geometric filtering [J]. *AIAA Journal*, 2020, 58(10): 4243-4259.
- [2] 席光, 王志恒, 王尚锦. 叶轮机械气动优化设计中的近似模型方法及其应用 [J]. *西安交通大学学报*, 2007, 41(2): 125-135, 184.
XI Guang, WANG Zhiheng, WANG Shangjin. Aero-dynamic optimization design of turbomachinery with approximation model method [J]. *Journal of Xi'an Jiaotong University*, 2007, 41(2): 125-135, 184.
- [3] 黄松, 阳诚武, 韩戈, 等. 采用鲸鱼算法的可控扩散叶型优化设计 [J]. *西安交通大学学报*, 2020, 54(3): 49-57.
HUANG Song, YANG Chengwu, HAN Ge, et al. Optimal design of a controlled diffusion airfoil with the whale algorithm [J]. *Journal of Xi'an Jiaotong University*, 2020, 54(3): 49-57.
- [4] 汪祺能, 宋立明, 郭振东, 等. 采用动态交互作用分析的叶轮机械优化算法研究 [J/OL]. *西安交通大学学报*, 2023(7): 1-10 [2022-08-15]. <http://kns.cnki.net/kcms/detail/61.1069.t.20230110.1409.001.html>.
WANG Qineng, SONG Liming, GUO Zhendong, et al. Study on turbomachinery optimization based on dynamic interaction analysis [J/OL]. *Journal of Xi'an Jiaotong University*, 2023(7): 1-10 [2022-08-15]. <http://kns.cnki.net/kcms/detail/61.1069.t.20230110.1409.001.html>.
- [5] 郭振东, 宋立明, 李军, 等. 基于子元模型的全局优化与设计空间知识挖掘方法 [J]. *推进技术*, 2015, 36(2): 207-216.

- GUO Zhendong, SONG Liming, LI Jun, et al. Meta model-based global design optimization and exploration method [J]. *Journal of Propulsion Technology*, 2015, 36(2): 207-216.
- [6] SHAN Songqing, WANG G G. Survey of modeling and optimization strategies to solve high-dimensional design problems with computationally-expensive black-box functions [J]. *Structural and Multidisciplinary Optimization*, 2010, 41(2): 219-241.
- [7] MASTERS D A, TAYLOR N J, RENDALL T C S, et al. Geometric comparison of aerofoil shape parameterization methods [J]. *AIAA Journal*, 2017, 55(5): 1575-1589.
- [8] CHEN Wei, CHIU K, FUGE M D. Airfoil design parameterization and optimization using Bézier generative adversarial networks [J]. *AIAA Journal*, 2020, 58(11): 4723-4735.
- [9] WANG Yuyang, SHIMADA K, FARIMANI A B. Airfoil GAN: encoding and synthesizing airfoils for aerodynamic shape optimization [J/OL]. *Journal of Computational Design and Engineering*, 2023: qwad046 [2022-10-26]. <https://doi.org/10.1093/jcde/qwad046>.
- [10] VIANA F A C, SIMPSON T W, BALABANOV V, et al. Special section on multidisciplinary design optimization: metamodeling in multidisciplinary design optimization: how far have we really come [J]. *AIAA Journal*, 2014, 52(4): 670-690.
- [11] 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.
- [12] BAERT L, DUMONT C, BEAUTHIER C, et al. Multidisciplinary design of a low-noise propeller: part II efficient aero-acoustic-mechanical design methodology exploiting surrogate models in an adaptive design space [C]//ASME Turbo Expo 2020: Turbomachinery Technical Conference and Exposition. New York, USA: ASME, 2020: 16321.
- [13] BHOSEKAR A, IERAPETRITOU M. Advances in surrogate based modeling, feasibility analysis, and optimization: a review [J]. *Computers & Chemical Engineering*, 2018, 108: 250-267.
- [14] LI Kai, KOU Jiaqing, ZHANG Weiwei. Unsteady aerodynamic reduced-order modeling based on machine learning across multiple airfoils [J]. *Aerospace Sci-*

- ence and Technology, 2021, 119: 107173.
- [15] TUCKER P G. Trends in turbomachinery turbulence treatments [J]. Progress in Aerospace Sciences, 2013, 63: 1-32.
- [16] MIN A T W, SAGARNA R, GUPTA A, et al. Knowledge transfer through machine learning in aircraft design [J]. IEEE Computational Intelligence Magazine, 2017, 12(4): 48-60.
- [17] PAN S J, YANG Qiang. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [18] GUPTA A, ONG Y S, FENG Liang. Insights on transfer optimization: because experience is the best teacher [J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2018, 2(1): 51-64.
- [19] TAN K C, FENG Liang, JIANG Min. Evolutionary transfer optimization: a new frontier in evolutionary computation research [J]. IEEE Computational Intelligence Magazine, 2021, 16(1): 22-33.
- [20] VALENZUELA DEL RÍO J E, MAVRIS D. Gaussian process surrogate model for leveraging similar trends across concepts [J]. AIAA Journal, 2015, 53(4): 1002-1015.
- [21] WANG Qineng, SONG Liming, GUO Zhendong, et al. Transfer optimization in accelerating the design of turbomachinery cascades [C]//ASME Turbo Expo 2020: Turbomachinery Technical Conference and Exposition. New York, USA: ASME, 2020: 16321.
- [22] MIN A T W, ALMANDOZ R, GUPTA A, et al. Coping with data scarcity in aircraft engine design [C]//18th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference. Reston, VA, USA: AIAA, 2017: 4434.
- [23] KINGMA D P, WELLING M. Auto-encoding variational Bayes [C]//2nd International Conference on Learning Representations. New York, USA: ICLR, 2014.
- [24] GUO Zhendong, SONG Liming, PARK C, et al. Analysis of dataset selection for multi-fidelity surrogates for a turbine problem [J]. Structural and Multidisciplinary Optimization, 2018, 57(6): 2127-2142.
- [25] GUO Zhendong, WANG Qineng, SONG Liming, et al. Parallel multi-fidelity expected improvement method for efficient global optimization [J]. Structural and Multidisciplinary Optimization, 2021, 64(3): 1457-1468.
- [26] GUO Zhendong, SUN Wei, SONG Liming, et al. Generative transfer optimization for aerodynamic design [C]//Proceedings of Global Power and Propulsion Society. Zug, Switzerland: GPPS, 2021: 225.
- [27] GUO Zhendong, ONG Y S, LIU Haitao. Calibrated and recalibrated expected improvements for Bayesian optimization [J]. Structural and Multidisciplinary Optimization, 2021, 64(6): 3549-3567.
- [28] DRELA M. XFOIL: an analysis and design system for low Reynolds number airfoils [C]//Low Reynolds Number Aerodynamics. Berlin, Heidelberg: Springer Berlin Heidelberg, 1989: 1-12.
- [29] CHEN Wei, AHMED F. PaDGAN: learning to generate high-quality novel designs [J]. Journal of Mechanical Design, 2021, 143(3): 031703.
- [30] YONEKURA K, MIYAMOTO N, SUZUKI K. Inverse airfoil design method for generating varieties of smooth airfoils using conditional WGAN-gp [J]. Structural and Multidisciplinary Optimization, 2022, 65(6): 173.
- [31] SPREITER J R. On the application of transonic similarity rules [EB/OL]. [2022-05-05]. <https://digital.library.unt.edu/ark:/67531/metadc56143/>.

(编辑 李慧敏 刘杨)