

基于深度学习的翼型反设计方法

何磊, 钱炜祺, 刘滔, 张显才, 董康生
(中国空气动力研究与发展中心 计算空气动力研究所, 四川 绵阳 621000)

摘 要: 建立了一种基于深度学习的翼型反设计方法,将翼型曲线及其对应的压力分布图像作为训练学习对象,建立其内在联系的模型,实现通过卷积神经网络提取压力分布图像的特征,计算获得翼型曲线。该方法直接将压力分布图像作为模型输入,更加直观简洁,同时避免了传统方法中耗时的数值计算过程。模型测试中,6000 组压力分布图像和翼型曲线用于模型训练,另外 561 组用于模型验证,验证耗时仅 6.7 s,预测的翼型曲线与 CFD 计算结果的平均相对误差为 0.55%。对比实验中,通过对压力分布曲线添加噪声、改变输出层尺寸等方式,进一步验证和分析了预测模型性能。结果表明该翼型反设计方法具有较高预测精度和较强鲁棒性,能在保证精度的情况下降低计算时间,提高设计效率。

关 键 词: 反设计方法; 翼型曲线; 压力分布; 卷积神经网络; 深度学习; 预测模型

中图分类号: V211.3 **文献标志码:** A

Inverse design method of airfoil based on deep learning

HE Lei, QIAN Weiqi, LIU Tao, ZHANG Xiancai, DONG Kangsheng
(Computational Aerodynamics Institute,
China Aerodynamics Research and Development Center, Mianyang Sichuan 621000, China)

Abstract: An inverse design method of airfoil based on deep learning was proposed, and the pressure distribution image and airfoil curve were taken as the learning objects to build the prediction model. It can obtain the airfoil curve by using convolutional neural network to extract geometric features from pressure distribution image, while avoiding the time-consuming process of traditional numerical calculation method. In the test case, 6 000 samples of pressure distribution images and airfoil curves were used to train the prediction model, and the other 561 samples were used for validation with validation time only 6.7 s. The average relative error between the predicted and CFD results was 0.55%. In the comparison test, noise was added to the pressure distribution curve and the output layer size was changed to further validate the performance of the model. The results show that the proposed inverse design method of airfoil has strong robustness and prediction accuracy. The method can greatly reduce the computation time and improve the design efficiency of airfoil with satisfactory design accuracy.

Key words: inverse design method; airfoil curve; pressure distribution; convolutional neural network; deep learning; prediction model

收稿日期:2020-03-15

基金项目:国家自然科学基金(11802325);中国空气动力研究与发展中心基础和前沿技术研究基金(FFTRF20172015)

作者简介:何磊(1988—),男,助理研究员,博士生,主要从事气动数据建模与融合研究。

通信作者:钱炜祺(1973—),男,研究员,博士,主要从事实验数据分析与建模仿真。E-mail:qwqhy@ sina. com

引用格式:何磊,钱炜祺,刘滔,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 on deep learning[J]. Journal of Aerospace Power, 2020, 35(9):1909-1917.

气动设计是飞行器设计的关键环节,对飞行性能和飞行安全具有重要影响^[1-2]。气动设计方法一般分为优化方法和反设计方法两大类^[2-3]。翼型反设计是其中一类重要方法,通常需要给定设计翼型表面的压力分布,然后通过求解空气动力学反问题,获得对应的几何外形^[3-4]。Light-hill^[5]较早开始翼型反设计方法的研究,提出了基于保角变换的反设计方法。之后 Takanashi、詹浩、华俊、李焦赞等^[6-9]发展的余量修正法是工程中常用的反设计方法之一,该方法基于初始翼型的目标压力差量计算几何外形修正量,叠加于初始翼型之上,如此反复迭代,求得翼型。赵小虎等^[10]将 CFD 与反设计技术结合,借助于几何和流动控制方程,通过数值计算反复迭代求解反问题,获得给定流场的翼型。Bui-Thanh 等^[11]发展的 Gappy POD (proper orthogonal decomposition) 的翼型反设计方法,为该问题求解提供了新的思路,白俊强等^[3]针对 Gappy POD 方法进行了改进,根据迭代压力分布和实际压力分布误差,引入迭代校正法,提高了反设计精度。刘俊、韩少强等^[12-13]将 Kriging 代理模型应用到气动反设计中,将翼型反设计问题转换为优化问题,取得了较好效果。有学者将遗传算法^[14-15]、模拟退火^[16]等应用于翼型反设计的优化中,有效提高了设计效率。随着机器学习技术的不断发展,有研究者尝试将其应用到翼型反设计领域,利用数据驱动的思想,构建翼型反设计模型。单志辉^[17]将高斯过程回归用于翼型反设计,使用压力分布和外形数据训练模型,以预测新的压力分布对应的翼型。刘凌君等^[18]、Sun 等^[19]基于人工神经网络开展了翼型反设计研究,刘凌君利用 BP(back propagation)神经网络,通过输入压力系数分布预测翼型 PARSEC(parametric section)参数^[20-21],进而获得翼型外形,但该方法需要将 PARSEC 参数分为 3 组,并通过 3 个 BP 神经网络预测。以上方法均为传统设计方法,主要是构建压力分布与翼型外形关系的方程,部分方法涉及的浅层学习方法的算法复杂度将随样本数量和模型精度提高呈指数级增长,部分方法使用了参数化技术,而参数化技术会带来曲线描述精度的问题^[22]。

近年来,深度学习方法^[23]作为机器学习的重要分支,已经在图像识别^[24]、文本生成^[25]、语音识别^[26]等领域被成功应用,有不少学者尝试将深度学习方法引入气动领域,并在翼型气动系数预测^[27]、压力分布预测^[28]、不稳定流动预测^[29]等方

面进行了探索,取得了不少研究成果。卷积神经网络(convolutional neural network, CNN)^[30]作为深度学习的重要模型之一,能够直接将图像作为输入,并且能够通过卷积核有效提取复杂外形曲线的特征。本文采用深度学习方法,针对翼型外形与其压力分布图像的内在联系进行训练学习,基于此对已知的压力分布预测其对应翼型,形成了基于深度卷积神经网络的翼型反设计方法。该方法在前期通过大量数据训练建立模型后,在预测阶段可以直接多次使用,耗时仅为秒级,避免了传统方法中繁琐耗时的数值计算过程,也能够有效解决由于输入变量过多和样本数的增大而带来的算法复杂度急剧增加的问题。使用该方法,可以在保证设计精度的情况下,大大降低预测时间,提高翼型设计效率。

1 基于 CNN 的翼型反设计方法

CNN 的主要模型层有卷积层、池化层和全连接层等^[31-32],一般需要根据拟解决问题的特点和复杂程度灵活选择卷积层、池化层和全连接层的个数。卷积层是 CNN 的核心组成部分,卷积操作的目的是通过卷积核(过滤器)从输入图像中提取特征,卷积核在图像上移动计算点积得到“特征映射”矩阵,不同的卷积核可以产生的不同特征映射,因此在 CNN 模型设计时每个卷积层会设置多个卷积核^[27]。每次卷积操作后都会进行非线性映射操作,通过引入非线性激励函数解决训练数据的非线性问题,常用的非线性激励函数包括 Sigmoid、tanh、ReLU 等^[33-35],大多数情况下,由于 ReLU 具有更快的收敛速度,因此表现更好。CNN 的卷积层后面可以连接一个池化层(又名下采样层或子采样层),在保留重要特征的同时,降低特征映射的维度,从而减少运算量并防止过拟合,常用的池化方式有平均池化、求和池化、最大池化。全连接层与传统的多层感知机(multilayer perceptron, MLP)相同,即前一层的每个神经元都链接到后一层的每个神经元,实现回归或分类的作用。

1.1 模型结构设计

本文设计的卷积神经网络结构与 LeNet-5^[31]类似,如图 1 所示。

1) 输入层 负责读取压力分布图像,图像分辨率越高,包含的信息越丰富,但建模时间和预测时间都会相应的增加。对于本模型要处理的压力分布而言,分辨率只要能够描述出其几何特征即




图 1 基于卷积神经网络的翼型反设计模型结构示意图

Fig. 1 Structure diagram of airfoil inverse design model based on CNN

可,本文中输入图像的分辨率设置为 100×100 ,即输入层为 100×100 的二维矩阵,取值范围在 $0\sim255$ 之间,0 表示黑色,255 表示白色。

2) 卷积层 1 选取卷积核数量为 40,大小设置为 6×6 ,步长为 1,激励函数为 ReLu。经过卷积响应和非线性激励函数运算后,该层输出 40 个尺寸为 100×100 的特征图。

3) 池化层 1 选取池化区域大小为 2×2 ,步长为 2,即相邻池化区域不重叠。池化方法选择最大池化法。经过池化操作后,该层输出得到 40 个尺寸为 47×47 的特征图。

4) 卷积层 2 选取卷积核数量为 80,大小设置为 5×5 ,步长为 1,激励函数为 ReLu。经过卷积响应和非线性激励函数运算后,该层输出 80 个尺寸为 43×43 的特征图。

5) 池化层 2 选取池化区域大小为 2×2 ,步长为 2。经过池化处理后,该层输出 80 个尺寸为 21×21 的特征图。

6) 卷积层 3 选取卷积核数量为 80,大小设置为 5×5 ,步长为 1,激励函数为 ReLu。经过卷积响应和非线性激励函数运算后,该层输出 80 个尺寸为 17×17 的特征图。

7) 扁平化层 将卷积层 3 输出的 80 个尺寸为 17×17 的特征图展平,即输出表示 23120 个神经元的一维向量。

8) 输出层 该层为全链接层,负责输出翼型曲线 y 坐标值,其对应的 x 坐标值固定,并进行了归一化,前缘加密, x 坐标值间距较小。该层尺寸决定了翼型曲线描述的细腻度。文中尺寸为 61,即上翼面 31 个(含后缘点),下翼面 30 个(不含后缘点),图中 y_1 到 y_N 为 61 个 y 坐标值。

1.2 模型训练过程

CNN 的训练过程包括前向计算和误差反向传播两大步骤。前向计算通过卷积和池化操作来提取图像特征,再链接全链接层实现分类或回归目的。误差反向传播通过梯度下降等算法反向传

递预测误差,更新网络权值和偏置,一般将预测值与期望值之差作为误差。训练过程中,为解决计算资源有限而样本数据量又通常较大的问题,CNN 一般将训练样本按照固定批次大小(batch size)送入模型进行训练,每个批次训练进行误差反向传播和权值更新。训练集中的所有样本都训练完一次,称为一个迭代(epoch),每次训练完若未达结束条件,则再次按批次输入样本继续对 CNN 的训练。训练的结束条件可以设置为误差阈值或迭代(epoch)次数,本文设置为迭代次数。图 2 是本文建立的预测模型的训练过程示意图,图中省略号表示多个卷积和池化操作。




图 2 模型训练过程

Fig. 2 Training process of model

2 数 据

本文的翼型反设计方法将压力分布图像输入 CNN 预测模型,直接计算得到翼型外形,因此样本数据集包括翼型和与之对应的压力分布。本文使用的数据集包含 6 561 组样本,所有翼型的上下表面边界范围如图 3 所示, x 为沿翼型弦长方

向无量纲化坐标, y 为垂直于翼型弦长方向的无量纲化坐标,均采用翼型函数生成,函数如式(1)所示。

$$\begin{cases} y_{up} = y_{0up}(x) + \sum_{k=1}^n c_k f_k(x) \\ y_{low} = y_{0low}(x) + \sum_{k=1}^n c_{k+n} f_k(x) \end{cases} \quad (1)$$

其中 y_{up} 和 y_{low} 分别为翼型上下表面函数, y_0 表示基准翼型, x 取值范围在 $0 \sim 1$ 之间, $f_k(x)$ 为改进的 Hicks-Henne 型函数^[36], n 为型函数数目, c_k 为型函数系数,通过改变 n 和 c_k 控制翼型厚度与弯度。本文选取 NACA0012 为基准翼型,上下表面型函数数量 n 均设置为 4,因此共 8 个 c_k ,每个 c_k 取值有 0、0.005、0.01 三种情况,因此得到 $3^8 = 6561$ 个翼型。

压力分布采用自主研发的 MBNS2D 数值计算软件^[37-38]得到,计算网格如图 4 所示,网格量为 300×100 ,前缘后缘网格加密,第一层到墙壁的法向距离小于 $10^{-5}C$ (C 为翼型弦长),模拟计算采用 N-S (Navier-Stokes) 方程、Roe 格式、双方程 $k-\omega$ SST (shear stress transport) 湍流模型,流动条件取迎角为 2° 、马赫数为 0.4,雷诺数为 6.5×10^6 的固定值。将计算所得压力分布曲线数据转换为如图 5 所示的灰度图像,图像尺寸为 100 像素 $\times$ 100 像素,为避免由于图像中压力分布的坐标轴取值范围不一致对模型带来的计算误差,所有压力分布灰度图像均将 x 坐标轴取值范围固定为 $[-0.1, 1.1]$, y 坐标轴取值范围固定为 $[-1.5, 1.1]$,坐标轴取值范围可根据实际情况调整。




图 3 6561 组翼型几何外形变化范围
Fig. 3 Geometry shape variation scope of 6561 airfoils




图 4 某翼型计算网格图
Fig. 4 Computational grid of a airfoil




图 5 压力分布灰度图像
Fig. 5 Gray images of pressure distribution

3 模型训练与结果分析

本文将样本数据集的 6 561 组样本顺序打乱,随机选择 6 000 组作为训练集,用于 CNN 预测模型训练,调整优化模型权值参数;剩下的 561 组作为验证集合,对模型的预测能力进行测试。

3.1 模型训练

本文基于开源深度学习架构 tensorflow 的 keras 高级接口实现 CNN 网络的构建、训练和预测。选择均方误差(mean square error, MSE, 量符号记为 E_{ms})作为损失函数,使用反向传播算法对 CNN 网络模型参数进行优化, MSE 通过式(2)计算得到,其中 y_t 是真值, y_p 是模型预测值。

$$E_{ms} = \sum_{i=1}^{N_{batch}} \frac{(y_t^i - y_p^i)^2}{N_{batch}} \quad (2)$$

预测模型训练参数设置如下:训练优化方法选择 Adam^[39],学习率(learning rate)的初始值为

0.001, β_1 为 0.9, β_2 为 0.999, 学习率衰减值为 0; 分批大小为 10, 即每批输入 10 个压力分布图像进行训练; 迭代次数为 50 次; 本文用于建模和训练的计算机配置为: Intel Core i5-5250、1.6GHz、4 核 CPU (central processing unit)、8GB 内存, 通过以上训练参数, 采用 CPU 运算, 模型训练时间大约为 3 h (10 489 s)。训练过程中, 样本的 MSE 随迭代次数的变化曲线如图 6 所示。从图中可以看出, 经过约 20 次迭代后, MSE 就迅速趋于收敛, 并随着迭代次数的增加, 有继续小幅下降的趋势。




图 6 训练过程
Fig. 6 Training process

3.2 结果分析与对比

3.2.1 模型验证

将验证数据集的 561 组压力分布图像输入训练好的 CNN 模型, 计算其对应的翼型曲线, 在本文中定义为测试实验 1。图 7 为其中任意 3 组模型预测翼型曲线与实际翼型曲线的对比图, 从图中可以看出, 预测值与实际期望值几乎重合, 结果令人满意。

为进一步定性说明模型的性能, 本文计算了预测翼型曲线的方均根误差 (RMSE, 量符号记为 E_{rms}) 和平均相对偏差 (ϵ), 其定义如下:

$$E_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i^i - y_p^i)^2} \tag{3}$$

$$\epsilon = \frac{\sum_{i=1}^N |y_p^i - y_t^i|}{\sum_{i=1}^N |y_t^i|} \tag{4}$$

其中 N 为描述翼型曲线的坐标点数。这里 N 可以是单个翼型的坐标点数, 也可以是多个翼型的坐标点总数, 分布描述单个翼型和多个翼型的平均预测误差。

表 1 是图 7 中 3 个翼型预测结果的误差指标




图 7 实验 1 翼型预测结果
Fig. 7 Airfoil prediction of test case 1

表 1 实验 1 翼型曲线预测结果误差
Table 1 Airfoil prediction error of test case 1

翼型	E_{rms}	$\epsilon/\%$
a	0.000 314 9	0.691
b	0.000 219	0.579
c	0.000 297 3	0.769

值,平均相对偏差均小于 0.8%。整个验证集的 561 组翼型预测共耗时 6.7 s,平均一组预测时间为约为 0.01 s,整体方均根为 0.000 245 3,平均相对偏差为 0.550%。

3.2.2 噪声对模型预测能力的影响

为了验证本文所建立模型在有噪声干扰情况下的鲁棒性,将带噪声的压力分布曲线图像输入模型,测试输入噪声对模型计算结果的影响,本文称为实验 2。将信噪比(SNR,量符号记为 R_{sn})为 30 dB(噪声约占 3.2%)^[40] 的高斯白噪声加入验证数据集的压力分布,SNR 计算见式(5),其中 P_s 表示信号功率, P_n 表示噪声功率, s_i 表示无噪声压力幅值, n_i 表示噪声幅值。

$$R_{sn} = 10\lg \frac{P_s}{P_n} = 10\lg \frac{\frac{\sum (s_1^2 + s_2^2 + \cdots + s_N^2)}{N}}{\frac{\sum (n_1^2 + n_2^2 + \cdots + n_N^2)}{N}} \quad (5)$$

将验证集加入噪声的压力分布数据转换为灰度图像,图 8 是生成的部分压力分布灰度图像。

将验证集 561 组添加了噪声的压力分布图像输入训练好的 CNN 预测模型,计算其对应的翼型曲线。图 9 为与实验 1 中相同的 3 组预测翼型曲线与实际翼型曲线的对比图,从图中可以看出,预测值与实际期望值几乎重合,结果依然令人满意。




图 8 带噪声压力分布灰度图像
Fig. 8 Gray images of pressure distribution with noise




图 9 实验 2 翼型曲线预测结果
Fig. 9 Airfoil prediction of test case 2

表 2 是图 9 中 3 个翼型预测结果的误差指标值,平均相对偏差均在 1% 左右。整个验证集的 561 组翼型预测共耗时 7.9 s,平均一组预测时间为约为 0.01 s,方均根值为 0.000 457 7,平均相对偏差 0.953%。

表 2 实验 2 翼型曲线预测结果误差

Table 2 Airfoil prediction error of test case 2

翼型	E_{rms}	$\epsilon/\%$
a	0.0004427	1.107
b	0.000478	1.123
c	0.0004525	1.177

实验表明本文建立模型对压力分布特性的提取能力具有较强的抗噪声干扰能力,对模型输入带 3.2% 噪声的压力分布图像,其翼型曲线预测结果的平均相对误差依然能控制再 1% 以内。

3.2.3 输出层尺寸对模型预测能力的影响

输出层描述了翼型曲线固定点上的 y 坐标值,为了测试输出层坐标点个数对模型预测能力的影响,在原 61 个点的每两个点之间再增加 1 个点,总点数变为 121,即将模型输出层神经元个数设置为 121,本文称为实验 3。由于改变了输出层尺寸,CNN 模型结构发生了变化,模型需要重新训练。重新准备数据后,仍然随机选择 6 000 组作为训练集,用于 CNN 预测模型训练,561 组作为验证集合,对模型的预测能力进行测试。

训练参数设置不变,训练耗时同样大约 3 h (11084s),变化不大。图 10 展示了其中任意 3 个翼型曲线预测结果,与期望曲线相比几乎重合,直观结果依然令人满意。表 3 是图 9 中 3 个预测翼型曲线的误差指标,其中平均相对偏差均在 0.5% 左右。如表 4 所示,整个验证集 561 组预测共耗时 6.6 s,方均根值为 0.0002812,平均相对偏差 0.586%。

实验表明输出层尺寸由 61 变为 121 后,训练时间、预测时间变化均不大,预测结果误差也相当





图 10 实验 3 翼型曲线预测结果
Fig. 10 Airfoil prediction of test case 3


表 3 实验 3 翼型曲线预测结果误差
Table 3 Airfoil prediction error of test case 3

翼型	E_{rms}	$\epsilon/\%$
a	0.0002581	0.508
b	0.0001855	0.415
c	0.0002581	0.576

表 4 实验 1~实验 3 性能对比
Table 4 Performance comparison of test case 1—3

参数	实验 1	实验 2	实验 3
预测时间/s	6.7	7.9	6.6
$E_{rms}/10^{-3}$	0.2453	0.4577	0.2812
$\epsilon/\%$	0.55	0.953	0.586

接近,因此本文所建模型具有一定灵活性,实践中可以根据需求合理设置输出层尺寸。



4 结 论

针对翼型反设计问题,本文建立了一种基于深度卷积神经网络的设计方法,该方法直接将压力分布图像作为输入,通过预测模型获得翼型曲线。实验表明,模型预测出的翼型曲线与 CFD 计算结果重合度非常高,平均相对误差在 1% 以内。当输入带有噪声的压力分布曲线时,模型具有较强的鲁棒性,从而更具工程实用性。同时,可根据实际应用,适当修改输出层尺寸,满足不同的翼型描述需求。另外,需要说明的是,在模型建立过程中可通过使用图形处理器(GPU)计算减少训练时间,通过增加训练迭代次数提高模型预测精度。下一步将着重研究翼型迎角、来流马赫数等参数为非固定值的情况,增强该方法在工程实践中的通用性。

总之,深度学习方法在翼型气动外形设计领域具有很强的应用前景,能将长期积累的计算或实验气动数据资源有效利用起来,值得继续深入研究。

参考文献:

- [1] 王清,招启军. 基于遗传算法的旋翼翼型综合气动优化设计[J]. 航空动力学报, 2016, 31(6): 1486-1495.
WANG Qing, ZHAO Qijun. Synthetical optimization design of rotor airfoil by genetic algorithm[J]. Journal of Aerospace Power, 2016, 31(6): 1486-1495. (in Chinese)
- [2] 高正红,王超. 飞行器气动外形设计方法研究与进展[J]. 空气动力学学报, 2017, 35(4): 516-528.
GAO Zhenghong, WANG Chao. Aerodynamic shape design methods for aircraft: status and trends[J]. Acta Aerodynamica Sinica, 2017, 35(4): 516-528. (in Chinese)
- [3] 白俊强,邱亚松,华俊. 改进型 Gappy POD 翼型反设计方法[J]. 航空学报, 2013, 34(4): 762-771.
BAI J Qunqiang, QIU Yasong, HUA Jun. Improved airfoil inverse design method based on Gappy POD[J]. Acta Aeronautica et Astronautica Sinica, 2013, 34(4): 762-771. (in Chinese)
- [4] 赵国庆,招启军. 基于目标压力分布的旋翼先进气动外形反设计分析方法[J]. 航空学报, 2014, 35(3): 744-755
ZHAO Guoqing, ZHAO Qijun. Inverse design analysis method on rotor with advanced aerodynamic configuration based upon target pressurse distribution[J]. Acta Aeronautica et Astronautica Sinica, 2014, 35(3): 744-755. (in Chinese)
- [5] Lighthill M J. A new method of two-dimensional aerodynamics design [R]. Aeronautical Research Council, ARC Technical Report No. 2112, 1945.
- [6] Takanashi S. Iterative three-dimensional transonic wing design using integral equations[J]. Journal of Aircraft, 1985, 22(8): 655-660.
- [7] 詹浩,华俊,张仲寅. 基于余量修正原理的多翼面气动反设计方法[J]. 航空学报, 2003, 24(5): 411-413.
ZHAN Hao, HUA Jun, ZHANG Zhongyin. Design of multi-lifting surfaces based on iterative residual correction [J]. Acta Aeronautica et Astronautica Sinica, 2003, 24(5): 411-413. (in Chinese)
- [8] 华俊,张仲寅. 一种跨声速翼型设计方法及设计诸例[J]. 空气动力学学报, 1990, 8(2): 117-123.
HUA Jun, ZHANG Zhongyin. A Transonic airfoil design method and example[J]. Acta Aerodynamica Sinica, 1990, 8(2): 117-123. (in Chinese)
- [9] 李焦赞. 基于目标压力分布优化翼型反设计方法研究[D]. 西安:西北工业大学, 2007.
LI Jiaoan. Study on inverse design method of airfoil based on optimization of target pressure distribution[D]. Xi'an: Northwestern Polytechnical University, 2007. (in Chinese)
- [10] 赵小虎,阎超. 基于气动数值模拟的翼型反设计方法[J]. 航空学报, 1997, 18(6): 9-12.
ZHAO Xiaohu, YAN Chao. Aerodynamic inverse design method of airfoil via CFD[J]. Acta Aeronautica et Astronautica Sinica, 1997, 18(6): 9-12. (in Chinese)
- [11] BUI-THANH T, DAMODARAN M, WILLCOX K. Aerodynamic data reconstruction and inverse design using proper orthogonal decomposition[J]. AIAA Journal, 2004, 42(8): 1501-1516.
- [12] 刘俊,宋文萍,韩忠华. Kriging 模型在翼型反设计中的应用研究[J]. 空气动力学学报, 2014, 32(4): 518-526.
LIU Jun, SONG Wenping, HAN Zhonghua, et al. Kriging-based airfoil inverse design[J]. Acta Aerodynamica Sinica, 2014, 32(4): 518-526. (in Chinese)
- [13] 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): 138-152
HAN Shaoqiang, SONG Wenping, HAN Zhonghua, et al. Aerodynamic inverse design method based on gradient-enhanced Kriging model[J]. Acta Aeronautica et Astronautica Sinica, 2017, 38(7): 138-152. (in Chinese)
- [14] 詹浩,朱军,白俊强,等. 遗传算法结合反设计的翼型优化设计研究[J]. 西北工业大学学报, 2006, 24(5): 541-543.
ZHAN Hao, ZHU Jun, BAI Junqiang, et al. Improving design of airfoil with genetic algorithm (GA) combined with inverse design method[J]. Journal of Northwestern Polytechnical University, 2006, 24(5): 541-543. (in Chinese)
- [15] 李秀娟,廖文和,刘浩. 基于翼型反设计的遗传算法[J]. 南京航空航天大学学报, 2007, 39(2): 263-266.
LI Xiujian, LIAO Wenhe, LIU Hao. Genetic algorithms based on airfoil inverse design[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2007, 39(2): 263-266. (in Chinese)
- [16] WANG X, DAMODARAN M, LEE S L. Inverse transonic airfoil design using parallel simulated annealing and computational fluid dynamics[J]. AIAA Journal, 2002, 40(4): 791-794.

[17] 单志辉. 基于高斯过程回归的翼型快速设计研究[D]. 南京:南京航空航天大学,2011.
SHAN Zhihui. Fast airfoil design based on gaussian process regression [D]. Nanjing: Nanjing University of Aeronautics and Astronautics,2011. (in Chinese)

[18] 刘凌君,周越,高振勋. 基于神经网络的翼型气动力计算和反设计方法[J]. 气体物理,2018,3(5):43-49.
LIU Lingjun, ZHOU Yue, GAO Zhenxun. Aerodynamic force calculation and inverse design for airfoil based on neural network[J]. Physics of Gases, 2018, 3(5): 41-47. (in Chinese)

[19] SUN G, SUN Y, WANG S. Artificial neural network based inverse design: airfoils and wings[J]. Aerospace Science and Technology, 2015, 42: 415-428.

[20] SOBIECZKY H. Parametric airfoils and wings[C]// Proceedings of Recent Development of Aerodynamic Design Methodologies. Berlin: Vieweg Teubner Verlag, 1999: 71-87.

[21] 张德虎,席胜,田鼎. 典型翼型参数化方法的翼型外形控制能力评估[J]. 航空工程进展, 2014, 5(3): 281-288.
ZHANG Dehu, XI Sheng, TIAN Ding. Geometry control ability evaluation of classical airfoil parametric methods [J]. Advance in Aeronautical Science And Engineering, 2014, 5(3): 281-288. (in Chinese)

[22] SAMAREH J A, SAMAREH J A, POLYNOMIAL B B. A survey of shape parameterization techniques[R]. NASA/CP-1999-209136, 1999.

[23] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.

[24] 吴正文. 卷积神经网络在图像分类中的应用研究[D]. 成都:电子科技大学,2015.
WU Zhengwen. Application research of convolution neural network in image classification[D]. Chengdu: University of Electronic Science and Technology, 2015. (in Chinese)

[25] 袁江林,郭志刚,陈刚,等. 基于深度学习的文本自动生成技术研究综述[J]. 信息工程大学学报, 2018, 19(5): 616-620.
YUAN Jianglin, GUO Zhigang, CHEN Gang, et al. Summary of text auto-generation technology research based on deep learning[J]. Journal of Information Engineering University, 2018, 19(5): 616-620. (in Chinese)

[26] FRANK S, GANG L, Dong Y. Conversational speech transcription using context-dependent deep neural networks [R]. Florence, Italy: the 12th Annual Conference of the International Speech Communication Association, 2011.

[27] 陈海,钱炜祺,何磊. 基于深度学习的翼型气动系数预测[J]. 空气动力学学报, 2018, 36(2): 294-299.
CHEN Hai, QIAN Weiqi, HE Lei. Aerodynamic coefficient prediction of airfoils based on deep learning[J]. Acta Aerodynamica Sinica, 2018, 36(2): 294-299. (in Chinese)

[28] 廖鹏,姚磊江,白国栋,等. 基于深度学习的混合翼型前缘压力分布预测[J]. 航空动力学报, 2019, 34(8): 1751-1758.
LIAO Peng, YAO Leijiang, BAI Guodong, et al. Prediction of hybrid airfoil leading edge pressure distribution based on deep learning[J]. Journal of Aerospace Power, 2019, 34(8): 1751-1758. (in Chinese)

[29] LEE S, YOU D. Data-driven prediction of unsteady flow over a circular cylinder using deep learning[J]. Journal of Fluid Mechanics, 2019, 879: 217-254.

[30] 李彦冬,郝宗波,雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508-2515.
LI Yandong, HAO Zongbo, LEI Hang. Survey of convolutional neural network[J]. Journal of Computer Applications, 2016, 36(9): 2508-2515. (in Chinese)

[31] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.

[32] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-446.

[33] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[R]. Brookline, MA, USA: International Conference on Artificial Intelligence and Statistics, 2010.

[34] NAIR V, HINTON G E. Rectified linear units improve restricted Boltzmann machines[C]//Proceedings of the 27th International Conference on Machine Learning. Haifa, Israel: Omni Press, 2010: 807-814.

[35] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//Advances in Neural Information Processing Systems. New York: Curran Associates, 2012: 1097-1105.

[36] 王建军,高正红. HicksHenne翼型参数化方法分析及改进[J]. 航空计算技术, 2010, 40(4): 46-49.
WANG Jianjun, GAO Zhenghong. Analysis and improvement of hickshenne airfoil parameterization method[J]. Aeronautical Computing Technique, 2010, 40(4): 46-49. (in Chinese)

[37] 陈作斌,江雄,周铸,等. 计算流体技术及应用[J]. 中国科学: E 辑, 2008, 38(5): 657-670.
CHEN Zuobin, JIANG Xiong, ZHOU Zhu, et al. Computational fluid technology and application[J]. Science in China: E, 2008, 38(5): 657-670. (in Chinese)

[38] 王建涛,易贤,肖中云,等. ARJ21-700 飞机冰脱落数值模拟[J]. 空气动力学学报, 2013, 31(4): 430-436.
WANG Jiantao, YI Xian, XIAO Zhongyun, et al. Numerical simulation of ice shedding from ARJ21-700[J]. Acta Aerodynamica Sinica, 2013, 31(4): 430-436. (in Chinese)

[39] KINGMA D P, BA J. Adam: a method for stochastic optimization[R]. San Diego, USA: the 3rd International Conference for Learning Representations, 2015.

[40] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[R]. Prague, Czech Republic: the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), 2011.