

文章编号: 1000-8055(2023)09-2251-10

doi: 10.13224/j.cnki.jasp.20210741

基于深度学习的压气机叶型气动特性预测

杜 周^{1,2}, 徐全勇², 宋振寿³, 王晗丁³, 马玉林¹

(1. 辽宁工程技术大学 力学与工程学院, 辽宁 阜新 123000;

2. 清华大学 航空发动机研究院, 北京 100084;

3. 西安电子科技大学 人工智能学院, 西安 710071)

摘 要: 采用了数值模拟与机器学习相结合的方式对压气机双圆弧叶型流场气动参数预测开展了研究。对双圆弧叶型进行参数化批量建模, 通过计算流体力学进行数值模拟, 将数值模拟的模型数据与气动性能的映射提供给多层神经网络(MLP)和卷积神经网络(CNN)进行学习, 分别对预测模型的准确率进行了测试比较。研究发现: 通过深度学习的方式可以有效的对压气机内部流场气动参数进行准确预测, 该模型预测的压力系数误差率小于 0.2%, 总压损失系数误差率小于 1.2%, 并证明 CNN 在气动参数预测的精度上优于传统全连接神经网络。

关 键 词: 机器学习; 深度学习; 卷积神经网络; 计算流体力学(CFD); 压气机叶型

中图分类号: V231.3

文献标志码: A

Prediction of aerodynamic characteristics of compressor blade profile based on deep learning

DU Zhou^{1,2}, XU Quanyong², SONG Zhenshou³, WANG Handing³, MA Yulin¹

(1. School of Mechanics and Engineering,

Liaoning Technical University, Fuxin Liaoning 123000, China;

2. Institute for Aero Engine, Tsinghua University, Beijing 100084, China;

3. School of Artificial Intelligence, Xidian University, Xi'an 710071, China)

Abstract: A combination of numerical simulation and machine learning was used to investigate the prediction of aerodynamic coefficients in the flow field of a double-circular-arc leaf shape of a compressor. Parametric batch modeling of the double-arc impeller shape was carried out, and numerical simulation was performed by computational fluid dynamics. The mapping of model data from numerical simulation to aerodynamic performance was provided to multilayer neural network (MLP) and convolutional neural network (CNN) for learning, and the accuracy of the prediction models was tested and compared respectively. It was found that the accurate prediction of the impeller mechanical internal flow field aerodynamic coefficients can be effectively performed by deep learning, and the error rate of the model predicted pressure coefficient was less than 0.2% and the error rate of loss coefficient was less than 1.2%, proving that CNN was better than traditional fully connected neural network in the accuracy of aerodynamic coefficient prediction.

Keywords: machine learning; deep learning; convolutional neural network; computational fluid dynamics (CFD); compressor blade profile

收稿日期: 2021-12-31

基金项目: 国家科技重大专项 (J2019-V-0001-0092, J2019-V-0013-0108)

作者简介: 杜周(1996—), 男, 硕士生, 主要从事流体仿真与人工智能相结合方面的研究。E-mail: 321115728@qq.com

通信作者: 徐全勇(1980—), 男, 副教授, 博士, 主要从事航空发动机气动热力学方面的研究。E-mail: xuquanyong@tsinghua.edu.cn

引用格式: 杜周, 徐全勇, 宋振寿, 等. 基于深度学习的压气机叶型气动特性预测[J]. 航空动力学报, 2023, 38(9): 2251-2260. DU Zhou, XU Quanyong, SONG Zhenshou, et al. Prediction of aerodynamic characteristics of compressor blade profile based on deep learning[J]. Journal of Aerospace Power, 2023, 38(9): 2251-2260.

压气机是航空发动机的核心部件,压气机性能不但对发动机的推质比、耗油率等性能参数起决定性作用,而且对整机的稳定性、可靠性也有重大影响。压气机的研制周期长、投入大。国内外航空发动机的研制经验表明,压气机性能的优劣直接影响到发动机研制的全局。目前,压气机的气动设计还是主要依靠准三维流面设计方法,如图 1 所示,即采用中线一维设计,通流二维设计,叶型选型,叶片三维造型,三维气动验证的设计流程。其中通流二维设计确定每个叶高的气流角之后,叶型选型是其中的重要环节。二维叶型的气动性能决定了压气机性能的优劣。最早的叶型气动性能都是通过叶栅实验吹风测得,实验能够

获得的叶型成本高,数量有限,结构简单,不能代表所有所需要的叶型。

20 世纪 80 年代以来,随着计算机性能的不断提升,进行数值模拟来获取压气机叶型上的流场发展成为常规手段,可以使用高性能的计算机来求解 Navier-Stokes 方程来获取到流场的信息。其中求解雷诺平均方程成为解决工程问题比较切实可行的手段^[1-2]。伴随深度学习研究的兴起,人工智能领域与 CFD 领域相结合的研究飞速发展,在几何参数建模、网格划分模型、湍流数值计算和计算结果可视化方面均有新进展^[3],机器学习而且在气动优化方面也有所应用^[4]。




图 1 典型压气机气动设计流程

Fig. 1 Typical compressor aerodynamic design process

计算量过大是 CFD 计算存在的问题之一,需要大量的计算资源才能达到准确性需求。Font 等^[5]通过有监督学习的深度神经网络闭合 SANS (spanwise-averaged Navier-Stokes) 方程来降低计算量。基于数据驱动的有监督学习神经网络方法也在逐步发展。机器学习与仿真计算结合在很多方面已经开展了大量的研究,例如翼形优化,湍流系数修正,流场预测等^[6-15]。可以使用机器学习的方式对 CFD 计算部分工作替换以节约计算成本,神经网络属于黑箱模型,相对于传统算法来说时间成本较低,另外还可以通过网络去优化模型,使模型具有更精确的计算结果。神经网络训练需要大量的数据,由于计算机硬件的发展,神经网络训练是相对容易实现,对于其他计算方法算法是具有优势。

复杂流场计算的问题在于模型复杂,仿真计算周期过长,计算机性能相形见绌。而单纯依靠实验取得数据,不仅耗资巨大,而且对于某些实际工程问题,完全相似的实验不容易实现。机器学习模型结构简单,需求的驱动数据较少,易于实现与训练,但模型对于多变量问题的处理能力略有不足。深度学习的模型复杂化,需要数据量

较大,但是对于非线性问题处理的能力较强。目前基于深度学习所进行的工作多为翼型的外部流场研究,压气机内流场与深度学习相结合的研究工作较少。

本文基于卷积神经网络(convolutional neural network, CNN)对压气机内部的双圆弧叶型进行气动参数预测,通过 ANSYS Workbench 平台进行自动化编程完成叶型数据模型建立,通过改变多个参数进行排列组合建立样本信息库,通过 CFX 流体仿真软件求解计算,最后将得到的气动特性以及流场信息交由 CNN 进行学习,得到可以预测内流场气动参数的模型,旨在为深度学习与气动参数相结合的内部流场计算研究方面提供一定的思路。

1 研究方法

1.1 数据生成

CNN 学习需要大量可信的数据样本,样本获取工作相当关键,需要建立出与气动特性与叶型数据的映射数据库,将数据交付给 CNN 进行学习,进而通过不断学习而优化。

叶片的建模存在大量复杂的尺寸和约束问题,

而参数化建模能够快速准确地解决叶片建模的问题,常用的建模参数化方法有多项式拟合法、正交奇函数法和特征参数描述法等,通过这些方式很好的控制系数,能够准确地生成大量的叶型^[16]。本文所选取的叶型为双圆弧叶型,在进口马赫数小于1.2的情况下,双圆弧叶型能够获得较好的性能。双圆弧叶型与NACA(National Advisory Committee for Aeronautics)系列的叶型相比结构较为简单,并且约束的系数较少。双圆弧叶型的中线为单圆弧中线,叶型前缘方向角与叶型后缘的方向角角度大小一致,假设 (x, y) 为双圆弧叶型的中心线上的控制点,双圆弧叶型的中线方程为

$$(x - C/2)^2 + [y + (C/2) \cot(\theta/2)]^2 = [(C/2) / \sin(\theta/2)]^2 \quad (1)$$

式中 C 表示叶型弦长, θ 表示叶型外倾角。

双圆弧叶型是由圆弧形成的两个表面与前后缘小圆所构成,如图2所示,图2中上表面圆弧下标为 u ,下表面圆弧下标为 l 。上半圆弧的圆弧半径 R_u 可由式(2)、式(3)确定,角度为 $-\theta/2$ 至 $\theta/2$,与前后缘小圆相连接,下表面圆弧半径的推导方程与上半圆弧类似^[17]。

$$d = t_b/2 - r_0 \sin(\theta/2) \quad (2)$$

$$R_u = \frac{d^2 - r_0^2 + [C/2 - r_0 \cos(\theta/2)]^2}{2(d - r_0)} \quad (3)$$

式中 t_b 表示最大厚度直径, R_u 表示上表面圆弧半径, r_0 表示前尾缘小圆半径。

参数化建模通过ANSYS Workbench实现,可以将参数进行排列组合导入到ANSYS Workbench中,通过软件Design Modeler批量建立几何,




图2 双圆弧叶型

Fig. 2 Double-circular-arc profile

建立的叶型模型计算域截面如图3所示。双圆弧叶型的上下轮廓线都为圆弧线。为验证CNN有效性,对长度尺度进行了扩大,模型的弦长 C 的值设置为1 m,前后端小圆半径 r_0 设置为0.001 m,叶型空气进口角设置为 49.5° ,攻角设为 0° 。不同叶型的外部轮廓分布是不同的,调节4个参数的变化,目的是在合理范围内尽可能涵盖更多的叶型。对叶型外部轮廓的大厚度的值在0.02~0.04 m的区间内设置了4个值,最大厚度所处的位置在0.3~0.7 m的区间范围内设置了9个值,叶片与叶片之间的距离称之为栅距,在仿真中即为空气进口端的长度,在0.9~1.5 m的范围内设置了7个值,以及叶型后缘方向与 X 轴的角度数目的个数设置为21个,基于控制变量法对决定流场域的4个不同参数进行排列组合,固定约束后在合理范围内共建立出 $4 \times 9 \times 7 \times 21 = 5292$ 个叶型。

流体域网格使用网格划分软件ANSYS Mesh批量化生成,网格整体采用非结构网格,网格如图4所示。由于雷诺数较高,对叶型边界层进行了局部加密,边界层采用六面体网格划分,流体域网格总数目一般为60万前后,叶型边界层网格细节如图5所示。

由于网格数量较多,5292个模型全部计算需要大量的时间,因此叶型性能计算是在无锡超算上通过远程完成计算的。流场特性计算采用CFX完成,所有的模型均采用相同的边界条件。由于




图3 计算域截面图

Fig. 3 Computational domain cross section diagram




图4 截面网格

Fig. 4 Cross section grid




图 5 叶型边界层网格

Fig. 5 Boundary layer grid of blade profile

模型的数量多, 计算周期长, 采用并行计算的方式。

计算边界条件为: 稳态计算, 入口边界条件总压为 101 325 Pa, 总温为 288 K, 出口边界静压为 90 000 Pa, 计算域上下边界为周期性边界条件, 最大迭代步长为 1 000 步, 计算均收敛。

仿真采用的气体为理想空气, 气体在流场中的运动需要满足连续性方程, 动量守恒方程, 以及能量守恒方程。模拟过程中需要对叶型工况的其中的两个关键气动参数进行重点关注, 分别为压力系数(C_p)和总压损失系数(ω)。

压力系数是描述流体动力学中遍布整个流场的相对压力的无量纲数。

$$C_p = \frac{p_2 - p_1}{p_1^* - p_1} \quad (4)$$

总压损失系数是总压力损失与进口气流动压的比值, 为无量纲数。

$$\omega = \frac{p_2^* - p_1^*}{p_1^* - p_1} \quad (5)$$

式中 p_1 为进口静压, p_2 为出口静压, p_1^* 为进口总压, p_2^* 为出口总压。

图 6~图 8 分别为某一案例的叶型区域叶栅流场速度矢量图、压力分布云图以及马赫数云图。由速度矢量图可以看出, 叶盆处的速度明显要低于叶背的速度。从压力分布云图可以看出, 叶盆处的动压要高于上叶背的动压, 可以看出双圆弧的增压效果较好。在叶片尾缘处出现了涡旋, 气流混乱, 不同的叶型的涡旋的个数和程度也不一致。由于每个叶型所固有的叶型特性不同, 因此每个叶型的流场也具有区别, 总压损失系数与压力系数的值是判断叶型性能是否优秀的重要指标。

图 9 和图 10 分别为 5 292 个案例的压力系数以及总压损失系数分布。由于建模时对变量进行




图 6 叶栅流场速度矢量图

Fig. 6 Velocity vector diagram of cascade flow field




图 7 叶栅流场压力云图

Fig. 7 Pressure cloud diagram of cascade flow field






图 8 叶栅流场马赫数云图

Fig. 8 Mach number cloud diagram of cascade flow field

排列组合, 因此两个系数呈现了规律性的变化, 通过对比可以看出, 当总压损失系数比较大, 压力系数就会相对比较小。在第 4 000 个算例以后, 出现了一些叶型的总压损失系数特别大, 压力系数变得极低的算例, 将几个压力系数值特别大的算例对比后发现, 在最大厚度半径与弦长的比为 0.05、栅距与弦长的比为 0.9、最大厚度位置与弦长的比大于 0.6 时, 叶型后缘流动角与 X 轴正方向夹角越大, 总压损失系数会越大, 压力系数会越小。

为了验证本文所采用的 CFD 数值模拟方法

图9 样本的 C_p 分布Fig. 9 C_p distribution of the sample图10 样本的 ω 分布Fig. 10 ω distribution of the sample

的准确性,采用本文模拟所使用的 CFD 仿真方法与论文中实验进行对比验证^[18-19],图 11 采用本文 CFD 仿真方法对论文中实验工况下的叶型进行仿真所得到的叶栅马赫数云图。

图 12 为论文中的实验数据与 CFD 仿真所得出的叶型附近 C_p 对比结果,从对比结果可以看出本文 CFD 仿真的准确性比较高,验证了所采用的数值模拟方法的准确性。

1.2 机器学习方法

自从 LeCun 成功地将 LeNet-5 应用到手写数字识别以来^[20],CNN 已经被广泛地用于各种机





图11 实验工况下叶栅马赫数云图

Fig. 11 Cascade Mach number cloud diagram under experimental conditions

图12 实验与 CFD 仿真 C_p 对比Fig. 12 Comparison of C_p between experiment and CFD simulation

器学习的任务当中,尤其是图像领域。LeNet-5 的网络结构如图 13 所示,图片数据从输入层输入,经过两次卷积,两次池化层,到全连接层,最后使用 Softmax 分类作为其输出层。LeNet-5 的网络虽小,但是它包含了卷积神经网络的基本模块:输入层,卷积层,池化层,全连接层,输出层,其中卷积层和池化层的数量可以根据实际情况任意增减。

1) 输入层:在图像处理领域,训练数据一般以图片形式作为 CNN 的输入。

2) 卷积层:卷积层是 CNN 的核心,图片像素的空间联系是局部的,在 CNN 中是通过卷积核来实现上述过程,以提取图像的局部特征。传统的




图13 LeNet-5 结构

Fig. 13 LeNet-5 structure

CNN 中主流的非线性激活函数主要有 Sigmoid、Tanh、Maxout 和 ReLU^[21-24], 假定输入特征图为 V , 卷积核为 W , 卷积操作为 $\text{conv}(V, W)$, 偏置为 b , $f(x)$ 为激活函数, 则经过卷积和激活函数后得到的特征图 Z 是

$$Z = f[\text{conv}(V, W) + b] \quad (6)$$

3) 池化层: 主要目的是降低特征图的特征空间。常用的池化方法有平均池化, L2 池化, 最大池化等。其中最大池化可以刻画图片的纹理特征, 平均池化则倾向于保留背景特征^[25]。

4) 全连接层: 不同于卷积层, 全连接层是许多神经元组成的平铺结构, 作用是对这些特征进行分类。

5) 输出层: 输出层即是整个 CNN 网络的输出。现有的大多数 CNN 都是针对分类任务设计的, 其输出是离散分类。

CNN 执行的是监督训练, 可大致分为以下 4 个阶段, 参数初始化、前向传播、反向传播、停止条件判断。一般而言, 网络的深度越深, 网络的性能表现越好。然而, 在使用更深层的网络时, CNN 将会面对反向传播时梯度消失或梯度爆炸、网络的性能退化的问题。为了解决这一问题, He 等^[26]在 2016 年提出了深度残差网络(deep residual network, ResNet), 引入残差学习来避免简单堆叠的卷积神经网络退化问题, 使模型更容易优化。

假设 $F(x) = x$ 为任务的最优映射, 传统的 CNN 直接拟合这个最优映射, 而在 ResNet 中, 模型期望网络拟合的是一个残差映射 $H(x)$

$$H(x) = F(x) - x \quad (7)$$

此时原最优映射 $F(x)$ 可以表示为

$$F(x) = H(x) + x \quad (8)$$

因此, 在 ResNet 的训练过程中, 网络只需要拟合确定函数 $H(x) = 0$, 即完成了一个恒等映射 $F(x) = x$, 这样比直接学习 $F(x) = x$ 这个映射要更容易。ResNet 中的基本残差单元如图 14 所示。

在 ResNet 中采用的激活函数是非线性激活函数 ReLU。ReLU 相较于其他的激活函数没有饱和区, 不存在梯度消失的问题; 计算简单, 没有复杂的指数计算, 实际收敛速度快, 其函数曲线如图 15 所示。




图 14 ResNet 基本的残差单元

Fig. 14 ResNet basic residual element




图 15 ReLU 激励函数

Fig. 15 ReLU excitation function

2 叶型气动参数预测模型

本文利用 ResNet 对叶型气动参数进行预测的流程如图 16 所示。

2.1 数据预处理

数值仿真实验中收集到的叶型数据和对应栅距为一组坐标点, 对这些坐标点进行图形化处理, 得到如图 17 所示的输入图像, 其中黑色部分是流体域的可视化处理, 在黑色区域内的白色部分是对应的叶型, 涂黑的目的是增强叶型和栅距的特征信息。

此外, 网络在反向传播的过程中, 由于气动参数的数量级较小, 容易出现浮点数太小引起的不同程度误差问题, 为了增强模型学习的能力, 因此对最后的输出放大了一定的倍数进行了训练。对 C_p 放大了 10 倍, 对 ω 放大了 100 倍, 使得这些气动参数的值都在 1 附近。

2.2 训练 CNN 模型

为了更好地预测叶型气动参数, 本文选择 ResNet 为两种系数分别建立预测模型。ResNet 根据其网络深度的不同而具有不同的版本, 常用的有 ResNet-18、ResNet-34、ResNet-50 等。在本文中选择 ResNet-34 作为训练的 CNN 模型。相




图 16 叶型气动参数预测流程

Fig. 16 Blade aerodynamic parameters prediction process




图 17 9个叶型流场轮廓

Fig. 17 9 blade profile flow field contours

比较于 ResNet-18、ResNet-34 具有更强的高级表征能力; 相比较于 ResNet-50、ResNet-34 不容易过拟合。ResNet-34 结构如表 1 所示, ResNet-34 结构共包含 5 个卷积组, 在参数结构中, 矩阵中的 3×3 表示卷积核的大小, 64、128、256、512 分别代表每层的卷积核的数量。

在 ResNet 的原论文中, 最后是一层 1 000 维的全连接层和一层 softmax 作为输出。对于本文的回归任务将全连接 (fully connected, FC) 层的维度变为一维, 采用取平均的方式得到系数值。采用均方差损失函数作为衡量网络实际输出与期

表 1 ResNet-34 结构

Table 1 ResNet-34 architecture

层名	输出大小	参数结构
Conv1	143×218	$7 \times 7, 64$, 步长 2
Conv2	72×109	3×3 最大池化, 步长 2 $\begin{bmatrix} 3 \times 3, & 64 \\ 3 \times 3, & 64 \end{bmatrix} \times 3$
Conv3	36×55	$\begin{bmatrix} 3 \times 3, & 128 \\ 3 \times 3, & 128 \end{bmatrix} \times 4$
Conv4	18×28	$\begin{bmatrix} 3 \times 3, & 256 \\ 3 \times 3, & 256 \end{bmatrix} \times 6$
Conv5	9×14	$\begin{bmatrix} 3 \times 3, & 512 \\ 3 \times 3, & 512 \end{bmatrix} \times 3$
Output	1×1	平均池化, 1-D 全连接

望输出的误差。其数学描述如下:

$$E_{ms} = \sum_{i=1}^{j_{batch}} \frac{(\hat{y}_i - y_i)^2}{j_{batch}} \quad (9)$$

式中量符号 E_{ms} 表示均方误差 (mean square error, MSE), j_{batch} 是每批输入样本的数量, $\hat{y}_i$ 是网络预测输出, y_i 是期望输出。

2.3 ResNet 模型参数设置

叶型图片及其对应的气动参数样本数共计 5 292 个。随机地将这些样本顺序打乱, 选择 4 234 (样本总数的 80%) 样本用作训练, 剩余 1 058 (样本总数的 20%) 样本用于对模型预测性能的验证。为了实验的公平性, 在本文中打乱一次样本顺序之后, 固定训练数据和验证数据, 保证每个实验所用的数据是相同的。网络的优化器选择 Adam 算法; 图片输入的批量大小设置为 64 张; 训练总迭代次数设置为 50 代; 初始学习率的值设置为 0.01, 此后每隔 10 代降低为原学习率的 1/10。网络采用 Kaiming 高斯初始化。

用于模型训练以及测试的计算机配置为: Intel@Xeon(R) Gold 6226R 2.9 GHz CPU、251 GB 内存、3 张 NVIDIA 2080Ti 显卡。

待模型的训练停止条件达到之后, 将待预测的数据样本输入已经训练好的模型当中, 即可得到模型预测的气动参数。

3 结果分析

C_p 和 ω 在训练过程中每次迭代训练样本的 E_{ms} 分别如图 18 和图 19 所示, 从图 18 中可以看出, 模型虽然存在着一些波动, 但是整体的趋势是下降的。在迭代 20 次之后, E_{ms} 就已经下降到

0.002 以下。从图 19 能够看出模型在训练前期 E_{ms} 下降较快, 在迭代 30 次之后就已 E_{ms} 已经趋近于 0。从两个图的迭代曲线后半段可以看出, 设定的 50 次总迭代次数可以使网络最后收敛。




图 18 C_p 训练误差

Fig. 18 C_p training error




图 19 ω 训练误差

Fig. 19 ω training error

3.1 压力系数预测

在压力系数模型训练完成之后, 将 1058 个测试样本输入到模型当中, 得到预测 C_p 。图 20 为测试样本 C_p 的预测值与期望值的示意图, 其中横坐标为样本序号, 纵坐标为压力系数扩大 10 倍的数值。可以看到预测值与期望值几乎是重叠的, 该模型预测精度非常高。

3.2 总压损失系数预测

同样在得到 ω 的预测模型之后, 将 1058 个测试样本输入到模型中, 得到其预测的 ω 。图 21 展示了测试样本的 ω 的预测值与期望值, 其中纵坐标为总压损失系数扩大 100 倍的数值。可以看出, 模型在 ω 的预测效果同样很好。

3.3 与其他模型方法比较

为了进一步验证图形化方法性能, 将该方法




图 20 C_p 预测结果

Fig. 20 C_p prediction results




图 21 ω 预测结果

Fig. 21 ω Forecast results

与其他参数化方法和非卷积网络方法进行了对比。结果如表 2 所示, 其中对比方法 1 采用了在叶型上采集的 310 个二维坐标作为输入参数, 使用多层感知机作预测模型; 方法 2 不采用卷积层的深度神经网络, 其隐含层个数 5, 每层的神经元节点为 1000。另外, 为了验证模型深度的影响, 将 ResNet-34 与 ResNet-18、ResNet-50 进行了对比。在表 2 中, 比较各个方法所获得的方均根误差 (root mean square error, RMSE, 量符号记为 E_{rms}), RMSE 表示一组数据的离散程度, 引入的第 2 个指标: 误差率 (error ratio, ER, 量符号记为 E_r), 目的是量化模型的预测误差, 其计算公式分别如下:

$$E_{rms} = \sqrt{E_{ms}} \quad (10)$$

$$E_r = E_{ms}/E(y) \quad (11)$$

式中 $E(y)$ 是期望的均值, 从表 2 中可以看出, 相比于方法 1 使用的参数化方法, 使用图形化方法的效果具有明显的优势。与方法 2 对比可以看出, 卷积层对图像特征的提取有着显著的优势。另外

表2 对比测试结果
Table 2 Comparison of test results

比较方法	C_p		ω	
	E_{rms}	$E_t/\%$	E_{rms}	$E_t/\%$
方法1	0.150 4	2.872	0.247 5	10.45
方法2	0.279 2	5.332	0.326 3	13.78
ResNet-18	0.009 7	0.184	0.029 3	1.256
ResNet-50	0.012 6	0.240	0.031 3	1.343
ResNet-34	0.009 1	0.173	0.278	1.192

从3种不同的ResNet的性能比较可以看到ResNet-34表现最好,如文中第2.2节分析的那样,较浅的网络ResNet-18相比较于ResNet-34表征能力不足,较深的网络ResNet-50相比较于ResNet-34训练最后过拟合,造成性能减退。

4 结 论

1) 本文提出了一种压气机叶栅流场气动参数预测方法,将CFD数值模拟与深度学习相结合可以有效实现系数准确预测。

2) 该模型与传统的CFD计算相比,可以对气动参数做出准确预测,性能计算响应速度更快,可以看出具有明显的优势,只需要将生成的叶型输入到预测模型,即可直接输出预测的气动参数,这是一个可实现的数值模拟与机器学习结合的新思路。

3) 该模型预测的压力系数误差率小于0.2%,总压损失系数误差率小于1.2%,已经达到叶型设计可用的预测精度。

4) 本文为建立任意参数的叶型库提供了一种方法。如何将工况加入到CNN,以及提高预测模型的泛化能力和深度学习所接受输入数据精度是本文工作接下来的研究方向。

参考文献:

- [1] 张伟伟,寇家庆,刘溢浪.智能赋能流体力学展望[J].航空学报,2021,42(4):26-71.
ZHANG Weiwei, KOU Jiaqing, LIU Yilang. Prospect of artificial intelligence empowering fluid mechanics[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 26-71. (in Chinese)
- [2] 张伟伟,朱林阳,刘溢浪,等.机器学习在湍流模型构建中的应用进展[J].空气动力学学报,2019,37(3):444-454.
ZHANG Weiwei, ZHU Linyang, LIU Yilang, et al. Progresses in the application of machine learning in turbulence modeling[J]. Acta Aerodynamica Sinica, 2019, 37(3): 444-454. (in Chinese)
- [3] 李義進,宋紅超,周帥,等.人工智能在计算流体力学中的应用[J].航空动力,2018(1):57-59.
LI Yijin, SONG Hongchao, ZHOU Shuai, et al. The application of artificial intelligence on computational fluid dynamics[J]. Aerospace Power, 2018(1): 57-59. (in Chinese)
- [4] 陈海昕,邓凯文,李润泽.机器学习技术在气动优化中的应用[J].航空学报,2019,40(1):52-68.
CHEN Haixin, DENG Kaiwen, LI Runze. Utilization of machine learning technology in aerodynamic optimization[J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(1): 52-68. (in Chinese)
- [5] FONT B, WEYMOUTH G D, NGUYEN V T, et al. Deep learning of the spanwise-averaged Navier-Stokes equations[J]. Journal of Computational Physics, 2021, 434(10): 110199.1-110199.25.
- [6] 王述之,战林浩,曹博超,等.基于直接数值模拟数据和神经网络的湍流封闭模型构建[J].水动力学研究与进展:A辑,2020,35(2):141-154.
WANG Shuzhi, ZHAN Linhao, CAO Bochao, et al. Turbulence closure model based on neural network and direct numerical simulation data[J]. Chinese Journal of Hydrodynamics: Series A, 2020, 35(2): 141-154. (in Chinese)
- [7] 尹宇辉,杨普,张宇飞.基于机器学习的湍流建模研究[R].杭州:中国力学大会,2019.
- [8] 陈海,钱伟祺,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)
- [9] ZHANG Y, SUNG W J, MAVRIS D. Application of convolutional neural network to predict airfoil lift coefficient[R]. Kissimmee, US: AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference, 2018.
- [10] 何磊,钱伟祺,汪清,等.机器学习方法在气动特性建模中的应用[J].空气动力学学报,2019,37(3):470-479.
HE Lei, QIAN Weiqi, WANG Qing, et al. Applications of machine learning for aerodynamic characteristics modeling[J]. Acta Aerodynamica Sinica, 2019, 37(3): 470-479. (in Chinese)
- [11] 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):41-47.
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)
- [12] 姚琳.机器学习在翼型优化问题中的应用[J].航天标准化,2020(1):43-47.
YAO Lin. Application of machine learning in airfoil optimization[J]. Aerospace Standardization, 2020(1): 43-47. (in Chinese)
- [13] SEKAR V, ZHANG M, SHU C, et al. Inverse design of airfoil using a deep convolutional neural network[J]. AIAA Journal, 2019, 57(3): 993-1003.
- [14] 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)
- [15] SEKAR V, KHOO B C. Fast flow field prediction over airfoils using deep learning approach[J]. Physics of Fluids, 2019, 31(5): 057103.1-057103.14.
- [16] 艾子健,秦国良,陈雪飞,等.翼型叶片精确参数化建模的研究及应用[J].流体机械,2015,43(8):36-40.
AI Zijian, QIN Guoliang, CHEN Xuefei, et al. Research and application on accurate parametric modeling for aerofoil blade[J]. Fluid

- Machinery, 2015, 43(8): 36-40. (in Chinese)
- [17] AUNGIER R H. Axial-flow compressors-a strategy for aerodynamic design and analysis[M]. New York: ASME Press, 2003.
- [18] FOTTNER L. Test cases for computation of internal flows in aero engine components[R]. AGARD Advisory Report No. 275, 1990.
- [19] STARK U, HOHEISEL H. The combined effect of axial velocity density ratio and aspect ratio on compressor cascade performance[J]. Journal of Engineering for Power, 1981, 103(1): 247-255.
- [20] 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.
- [21] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[R]. Sardinia, Italy: the 13th International Conference on Artificial Intelligence and Statistics, 2010.
- [22] ELMAN J L. Learning and development in neural networks: the importance of starting small[J]. [Cognition](#), 1993, 48(1): 71-99.
- [23] GOODFELLOW I, WARDE-FARLEY D, MIRZA M, et al. Max-out networks[R]. Atlanta, US: International Conference on Machine Learning, 2013.
- [24] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
- [25] BOUREAU Y L, BACH F, LECUN Y, et al. Learning mid-level features for recognition[R]. San Francisco, US: IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2010.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[R]. Las Vegas, US: IEEE Conference on Computer Vision and Pattern Recognition, 2016.

(编辑: 王碧琚)