

基于深度学习光流法的荧光油膜 全局速度测量

王 超¹, 董秀成¹, 古世甫¹, 张征宇², 钱泓江¹

(1. 西华大学 电气与电子信息学院, 成都 610039;

2. 中国空气动力研究与发展中心 高速空气动力研究所, 四川 绵阳 621000)

摘 要: 针对基于先验的传统光流法存在前提条件苛刻的问题, 提出使用基于深度学习的光流法进行荧光油膜全局速度测量。采用数值仿真试验对基于先验的改进 HS 光流法和基于深度学习的 FlowNet2 光流法进行对比, 结果显示: 在不外加干扰时, 改进 HS 光流法和 FlowNet2 光流法的平均端点误差分别为 0.458 7 像素/s 和 0.381 7 像素/s; 在亮度变化、噪声干扰或不同的演化时间下, FlowNet2 光流法的平均端点误差均明显低于改进 HS 光流法, 平均端点误差差值最大可达 5.19 像素/s; 风洞试验进一步证明, FlowNet2 光流法能够获得正确、清晰、定量的荧光油膜全局速度场, 较改进 HS 光流法鲁棒性更高, 对风洞工程应用具有一定的参考价值。

关 键 词: 光流法; 深度学习; 荧光油膜; 全局速度; 鲁棒性

中图分类号: V19

文献标志码: A

Global velocity measurement of fluorescent oil film based on deep learning optical flow method

WANG Chao¹, DONG Xiucheng¹, GU Shifu¹,
ZHANG Zhengyu², QIAN Hongjiang¹

(1. School of Electrical Engineering and Electronic Information,
Xihua University, Chengdu 610039, China;

2. High Speed Aerodynamics Institute,
China Aerodynamics Research and Development Center, Mianyang Sichuan 621000, China)

Abstract: In order to solve the problems of the traditional optical flow method based on priori, such as harsh preconditions, an optical flow method based on deep learning was proposed to measure the global velocity of fluorescent oil film. The numerical simulation experiments were used to compare the improved HS optical flow method based on prior with FlowNet2 optical flow method based on deep learning. The results showed that the average endpoint errors of improved HS optical flow method and FlowNet2 optical flow method were 0.458 7 pixel/s and 0.381 7 pixel/s without external interference, respectively; the average endpoint error of FlowNet2 optical

收稿日期: 2022-01-27

基金项目: 国家自然科学基金(11872069); 四川省中央引导地方科技发展专项(2021ZYD0034)

作者简介: 王超(1998—), 男, 硕士生, 主要从事空气动力学、计算机视觉研究。

通信作者: 董秀成(1963—), 男, 教授, 硕士, 主要从事机器视觉研究。E-mail: dxc136@163.com

引用格式: 王超, 董秀成, 古世甫, 等. 基于深度学习光流法的荧光油膜全局速度测量[J]. 航空动力学报, 2022, 37(7): 1539-1549.
WANG Chao, DONG Xiucheng, GU Shifu, et al. Global velocity measurement of fluorescent oil film based on deep learning optical flow method[J]. Journal of Aerospace Power, 2022, 37(7): 1539-1549.

flow method was significantly lower than that of HS optical flow method under the conditions of brightness change, noise disturbance or different evolution times, and the maximum difference of average endpoint errors could reach 5.19 pixel/s. The experimental results in the wind tunnel further prove that the FlowNet2 optical flow method can obtain the correct, clear and quantitative global velocity fields of fluorescent oil film. With stronger robustness than the improved HS optical flow method, this method has certain reference value for wind tunnel engineering application.

Key words: optical flow method; deep learning; fluorescent oil film; global velocity; robustness

飞行器的表面摩阻,是指由于流体黏性在流体分子间及其与飞行器表面间的摩擦而产生的阻力,它与飞行器表面的光洁度、雷诺数以及表面流体的流态有关^[1]。在高速条件下,现代大型民航客机的表面摩阻可达总阻力的50%,表面摩阻每下降1%,油耗可下降0.625%,降低表面摩阻对降低油耗、增加航程、改善飞机性能都具有重要意义和价值^[2-3]。现有的摩阻测量技术种类繁多,主要有 Preston 管、Stanton 管、热线、热膜、摩擦天平、油膜法、底层隔板法、液晶膜法、激光多普勒法、蒸发膜法等^[4-7]。

Liu 等^[8]提出的荧光油膜全局摩阻测量技术具有设备简单、空间分辨率高、全局测量等优点,已成为目前最广泛使用的飞行器表面摩阻测量技术。在油膜厚度极薄时,简化后的荧光油膜表面摩阻测量模型与油膜全局速度、油膜动力黏度和油膜全局厚度有关,其中油膜动力黏度和全局厚度可通过试验设备直接测得^[9-11],而油膜全局速度通常使用光流法求解。

光流本质上是三维场景的物体运动投影到二维图像平面所表现出的像素点的亮度变化。通常,光流值大小表示运动前后像素点在水平和垂直方向上的位移或平均运动速度。光流法最初由计算机视觉领域提出,现已发展出数十种光流法,主要可以分为两大类:基于先验的传统光流法和基于深度学习的光流法^[12-13]。传统光流法主要依据亮度恒定假设建立变分光流模型进行求解^[14-15],但这种假设过于理想化,在现实场景中无法完全满足,导致其对环境干扰比较敏感。为了提高鲁棒性,研究者提出了大量的优化算法,主要可以分为四大类^[16]。第一类是使用高阶恒定性假设扩展依赖亮度恒定假设的数据项,这类方法仅在两帧图像光照变化较小时有效。第二类是提取图像中的光照不变特征用于数据项中,这类方法通常需

要更长的计算时间。第三类是采用结构-纹理分解方法进行预处理,这类方法对图像的质量要求较高,期望光照变化几乎不会影响图像纹理。第四类是直接建立光照变化的数学模型,这种模型相对于亮度恒定模型更为松弛,允许不太精确的匹配,但对图像的运动连续性要求较高。近年来,基于深度学习的光流法成为一种趋势,FlowNet 作为第一个基于深度学习的光流法,采用简单的卷积神经网络模型学习两帧图像的特征进行光流解算,率先证明了光流估计是一个可学习的过程^[17],但精度尚无法达到最先进的传统光流法。随后,FlowNet2 将多个 FlowNet 网络进行堆叠,并使用了不同的训练策略,增加了模型大小,但有效提高了光流解算的精度^[18]。

针对目前测量荧光油膜全局速度所使用的传统光流法存在前提条件较为苛刻等问题,本文先介绍了两种光流法的理论原理^[19],并以此为角度进行了亮度变化、噪声干扰和大位移的对比试验,结果表明基于深度学习的光流法具有更高的鲁棒性。最后,使用风洞试验采集的荧光油膜图像进行了光流解算,结果进一步验证了该方法的有效性,其能够得到正确、清晰、定量的全局速度场,为后续深入研究做了铺垫,具有一定的工程应用参考价值。

1 光流法原理

1.1 HS 光流法

Horn 和 Schunck 基于三大假设开创性地提出了基于变分法的传统光流法估计模型,即 HS 光流法。首先,基于亮度恒定假设,在相邻两帧图像内同一像素点的亮度保持不变,即

$$I(x, y, t) = I(x + dx, y + dy, t + dt) \quad (1)$$

式中 $I(x, y, t)$ 表示像素点 (x, y) 在时间 t 的亮度,

$I(x+dx, y+dy, t+dt)$ 表示此像素点经过时间 dt 移动到 $(x+dx, y+dy)$ 处时的亮度。

基于小运动假设,对式(1)进行泰勒展开并化简可得

$$I_x u + I_y v + I_t = 0 \quad (2)$$

其中 $I_x = \partial I / \partial x$, $I_y = \partial I / \partial y$, $I_t = \partial I / \partial t$, $u = dx/dt$, $v = dy/dt$ 。引入全局光滑假设,平滑项能量函数 E_{rg} 通常表示为

$$E_{rg}(u, v) = \iint_{\Omega} (|\nabla u|^2 + |\nabla v|^2) dx dy \quad (3)$$

式中 Ω 代表整个图像区域。综上可得 HS 光流法的能量函数为

$$E(u, v) = \iint_{\Omega} [(I_x u + I_y v + I_t)^2 + \lambda (|\nabla u|^2 + |\nabla v|^2)] dx dy \quad (4)$$

式中 λ 是权重因子,用于调节平滑项能量函数的比重。最后,采用欧拉-拉格朗日方程可求解得到光流速度的迭代方程,设定初值和迭代终止条件即可解算出相应光流值。

$$\begin{cases} u^{k+1} = \bar{u}^k - \frac{I_x (I_x \bar{u}^k + I_y \bar{v}^k + I_t)}{\lambda + I_x^2 + I_y^2} \\ v^{k+1} = \bar{v}^k - \frac{I_y (I_x \bar{u}^k + I_y \bar{v}^k + I_t)}{\lambda + I_x^2 + I_y^2} \end{cases} \quad (5)$$

式中 $\bar{u}$ 和 $\bar{v}$ 分别为 u 和 v 在邻域内的平均值, k 为迭代次数。

1.2 改进 HS 光流法

HS 光流法对图像质量要求高,对光照变化或光流位移比较敏感。改进 HS 光流法在一定程度上克服了这些问题,与 HS 光流法相比,主要增加了金字塔优化模块^[20]。

金字塔优化的本质是一种由上到下、由粗略到精细的“迭代优化”。其主要思想是通过下采样降低图像分辨率,得到多层图像金字塔,然后从上到下逐层使用演化得到的修正值对 HS 光流法解算的光流粗值进行修正,最终得到光流精细值。通过金字塔优化可以使 HS 光流法尽可能处理较小的位移,避免其弊端,在一定程度上提升了算法性能。图1给出了常用的三层金字塔优化示意图。




图1 三层金字塔优化示意图

Fig.1 Schematic diagram of three-layer pyramid optimization

1.3 FlowNet2 光流法

FlowNet使用简单的卷积神经网络模型,率先证明了光流解算是一个可学习的过程。图2给出了FlowNet原理示意图,它采用编解码网络即U型网络,可分为FlowNetS和FlowNetC两种结构,两者的编码器不同,而解码器相同。在编码部分,前者将两帧图像堆叠输入网络,直接通过6次卷积得到图像的特征图;后者先分别对两帧图像进行3次卷积,然后对卷积结果进行相关性匹配,

最后再对匹配结果进行3次卷积。在解码部分,两者均是通过反卷积深入学习特征,但与通常的反卷积层不同的是,它将反卷积层特征图以及对应的卷积层特征图和光流粗值三者的通道串联起来,这样既保留了粗糙特征映射传递的主要信息,又保留了低层特征映射提供的细节信息。通过6次卷积和4次反卷积解算得到的光流尺度仅为原图像的四分之一,但继续使用反卷积操作对光流的精度提升很小,故后续直接采用了双线性插值




图2 FlowNet原理示意图

Fig.2 Schematic diagram of FlowNet princible

算法将光流恢复到原图像尺寸。

作为初代版本,FlowNet结构简单、数据集单一、泛化能力较差,其综合性能尚无法达到最先进的传统光流法。其团队随后又提出FlowNet2,作为FlowNet的改进版本,主要贡献如下:

1) 开发了多种堆叠网络,即将多个FlowNet网络堆叠成新的网络,分别进行训练和对比测试,

最终将性能最佳的网络结构定义为FlowNet2。

2) 更加关注训练过程,并通过改变训练策略开发了一种微调的、专门处理较小位移的网络FlowNetSD,以及融合该网络的网络Fusion。

3) 引入了HS光流法的演化操作,并将演化的误差作为一个监督信号辅助训练,逐步提炼出更精细的光流。

4) 在相同的数据集上,FlowNet2与FlowNet相比,误差降低了50%以上,且更能突出图像清晰的边界、精细的结构和对噪声的鲁棒性,其综合性能与当时最先进的光流法相当。

FlowNet2网络结构图如图3所示。

参照文献[18]的试验对比结果,本文首先在Chairs数据集上训练模型,然后在Things3D数据集上进行微调,学习率设置为0.001。该数据集具有以下特征:数据集较大、质量较高、包含不同尺度位移、包含2D和3D运动和灯光效果。两种数据集特征见表1。




图3 FlowNet2网络结构图

Fig.3 Network architecture diagram of FlowNet2

表1 两种数据集特征

Table 1 Features of two datasets

特征	数据集名称	
	Chairs	Things3D
训练集帧数	22 232	21 818
测试集帧数	640	4 248
场景数	964	2 247

综上,对比两种光流法的算法原理,可见FlowNet2光流法更具优势:HS光流法以三大假设为基础建立模型,但在高速风洞试验中,设备的振动或油膜的剧烈流动,一方面会导致图像亮度发生变化,另一方面也会导致光流位移偏大,都与

前提假设不相符;而FlowNet2光流法不基于任何假设,它通过学习数据集特征来对光流进行预测,其算法性能主要与网络结构和数据集相关,它既包含专门处理不同尺度位移的网络,又采用了大量包含不同尺度位移和不同灯光效果的数据集,因此它理应具有较好的泛化能力和鲁棒性。

2 数值仿真试验

为更直观地对比综合性能,本文从光流原理的角度对改进HS光流法和FlowNet2光流法进行了3组数值仿真试验:亮度变化试验、噪声干扰试验以及光流大位移试验。采用端点误差(endpoint error)和平均端点误差(average endpoint error)作为评价指标,分别记为 E_{ep} 和 E_{aep} ,前者表示

图像上单个像素点的解算光流值与光流真值的欧式距离,后者表示图像上所有像素点端点误差的均值。

$$E_{\text{ep}(i,j)}=\sqrt{(u_{(i,j)}^{\text{t}}-u_{(i,j)})^2+(v_{(i,j)}^{\text{t}}-v_{(i,j)})^2} \quad (6)$$
$$E_{\text{aep}}=\frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n E_{\text{ep}(i,j)} \quad (7)$$

式中 m 、 n 为图像像素尺寸, i 、 j 为单个像素点的序号, u^{t} 、 v^{t} 表示光流真值, u 、 v 表示光流法解算的光流值。

现实场景中的光流真值作为理想值,无法通过试验设备精确测量。为此,采用荧光油膜模拟演化方法进行算法性能对比和分析^[21-22]。根据 Oseen 涡对速度场公式

$$U_r=\frac{\Gamma}{2 \pi r}\left[1-\mathrm{e}^{\left(-r^2 / r_0^2\right)}\right] \quad (8)$$

式中 U_r 为速度, Γ 为强度, r_0 为涡核半径, r 为像素点到涡核的距离。

设定 Γ 为 3 000 平方像素/s, r_0 为 20 像素的涡对速度场,并将其与一个水平向右、大小为 10 像素/s 的均匀速度场叠加,得到如图 4(a) 所示的模拟速度场,以此作为光流真值。为尽可能地贴近真实场景下的荧光油膜图像,采用如图 4(b) 所示的木星表面图像^[23]作为第 1 帧荧光油膜模拟图像(记为图像 1),大小为 320 像素×320 像素;将演化 0.02 s 后得到的图像作为第 2 帧荧光油膜模拟图像(记为图像 2),如图 4(c) 所示。




图 4 荧光油膜模拟图像
Fig.4 Simulation images of fluorescent oil film

2.1 亮度变化试验

试验光源的功率变化、外部光源的干扰以及试验设备的抖动等因素都可能导致油膜的亮度发生变化,进而影响光流法的性能。为对比两种光流法在亮度变化下的鲁棒性,分别改变±2%到±10%的图像全局亮度以模拟亮度变化,其中正号代表变亮,负号代表变暗。

两种光流法的平均端点误差如表 2 所示,图 5 为对应的曲线。在不改变图像亮度的情况下,改进 HS 光流法和 FlowNet2 光流法的平均端点误差分别为 0.458 7 像素/s 和 0.381 7 像素/s;当图像变暗或变亮后,改进 HS 光流法和 FlowNet2 光流法的平均端点误差都有所上升,最大值分别为 0.840 0 像素/s 和 0.495 6 像素/s;改进 HS 光流法在图像亮度变暗时的平均端点误差较为稳定,而在图像亮度变亮时的平均端点误差呈明显的上升趋势。因此,FlowNet2 光流法对光照变化更不敏感,鲁棒性更强。图 6 分别给出了亮度变化

表 2 不同亮度变化下的平均端点误差

Table 2 Average endpoint error with different brightness changes		
亮度变化/%	平均端点误差/(像素/s)	
	改进 HS 光流法	FlowNet2 光流法
−10	0.557 0	0.495 6
−8	0.555 9	0.477 5
−6	0.557 4	0.459 5
−4	0.556 3	0.452 7
−2	0.559 4	0.447 9
0	0.458 7	0.381 7
+2	0.579 3	0.450 3
+4	0.620 9	0.452 3
+6	0.670 9	0.458 4
+8	0.752 8	0.461 9
+10	0.840 0	0.464 0






图5 不同亮度变化下的平均端点误差曲线


Fig.5 Average endpoint error curve with different brightness changes



(a) 亮度变化为-10%



(b) 亮度变化为0%



(c) 亮度变化为10%

图6 不同亮度变化下的图像

Fig.6 Images with different brightness changes

为-10%、0和+10%的图像。

2.2 噪声干扰试验


高斯噪声和椒盐噪声作为电子设备的主要噪声源,具有非黑即白的特点,容易造成较多的离群值^[24]。本文为荧光油膜模拟图像分别添加了均值为0、方差为0.002的高斯噪声,以及密度为1%的椒盐噪声,以模拟不同的噪声干扰。

表3给出了不同噪声下两种光流法的平均端点误差。可见,无论添加哪种噪声,改进HS光流法和FlowNet2光流法的平均端点误差都有所增大,但改进HS光流法的平均端点误差始终相对更高,两种光流法的平均端点误差在椒盐噪声下达到最大值,分别为0.859 8像素/s和0.460 4像素/s。因此,FlowNet2光流法对噪声的鲁棒性更优。添加高斯噪声、椒盐噪声和混合噪声的图像如图7所示。


表3 不同噪声下的平均端点误差

Table 3 Average endpoint error with different noises


噪声类型	平均端点误差(像素/s)	
	改进HS光流法	FlowNet2光流法
无噪声	0.458 7	0.381 7
高斯噪声	0.775 4	0.457 9
椒盐噪声	0.859 8	0.460 4
混合噪声	0.855 5	0.456 6



(a) 高斯噪声



(b) 椒盐噪声




(c) 混合噪声

图 7 不同噪声下的图像


Fig.7 Images with different noises

2.3 光流大位移试验


光流位移的尺度问题一直是光流研究的一大难点^[25-26]。当光流位移太小时,容易因图像的缩放导致细节信息丢失;当光流位移较大时,一方面大量超出图像边界的像素信息会丢失,另一方面与光流法原理的小位移前提相悖,将直接导致算法精度显著下降。为便于分析和讨论,同样采用荧光油膜模拟演化方法,取时间间隔为 0.02 s,得到演化 0.02~0.2 s 的共 10 帧光流位移递增的图像,与原始图像组成 10 组图像对,其中最大位移可达 28 像素。图 8 给出了演化时间为 0.02、0.1、0.2 s 时的图像。



(a) 演化时间为0.02 s



(b) 演化时间为0.1 s



(c) 演化时间为0.2 s

图 8 不同演化时间的图像

Fig.8 Images with different evolution times

表 4 给出了不同演化时间下两种光流法的平均端点误差,图 9 为对应的曲线。当演化时间较短即光流位移较小时,两种光流法的平均端点误

表 4 不同演化时间下的平均端点误差
Table 4 Average endpoint error with different evolution times

演化时间/s	平均端点误差/(像素/s)	
	改进 HS 光流法	FlowNet2 光流法
0.02	0.458 6	0.381 7
0.04	0.564 4	0.436 0
0.06	0.718 6	0.527 7
0.08	1.426 1	0.650 5
0.10	2.495 6	0.858 4
0.12	3.709 5	1.203 3
0.14	4.882 7	1.674 1
0.16	6.091 1	2.197 9
0.18	7.419 0	2.760 3
0.20	8.632 7	3.442 7




图 9 不同演化时间下的平均端点误差曲线

Fig.9 Average endpoint error curve with different evolution times

差相差较小;当演化时间较长即光流位移较大时,两种光流法的误差都逐渐增大,但 FlowNet2 光流法误差曲线的上升趋势明显低于改进 HS 光流法,两者的平均端点误差最大值分别为 3.442 7 像素/s 和 8.632 7 像素/s,差值可达 5 像素/s,FlowNet2 光流法处理光流大位移的性能优于改进 HS 光流法。

3 风洞试验

3.1 低速风洞试验

为对比光流法在亮度变化、噪声干扰和大位移下实际解算效果,进行了低速风洞试验。试验平台如图 10 所示,主要设备有高速相机(Baumer HXC13)、紫外光源(波长为 365 nm,功率为 18 W)、涡轮风机(风速为 5 m/s)、高精度陀螺仪(HWT605)、相机滤光片、荧光油和计算机。首先,使用有机配合物和硅油制备获得荧光油,该油在 365 nm 波长的紫外光源照射下受激辐射出 650 nm 波长的红光。然后均匀涂抹少量荧光油

于平板模型上,再将紫外光源固定于模型上方,使其均匀照射荧光油膜。同时,为降低杂光的干扰、提高图像的信噪比,相机镜头加装了滤光片。最后,固定涡轮风机和平板模型,启动涡轮风机,待风速稳定后,通过高速相机和计算机采集荧光油膜灰度图像。

通过 3 组不同的对照试验,分别采集了不同变量下的荧光油膜图像。通过调节紫外光源的功率,并测量平板模型平面的亮度,获取了 500lx 下的油膜图像,如图 11(a)所示,图 11(b)和图 11(c)分别为改进 HS 光流法和 FlowNet2 光流法的解算结果。通过调节相机焦距,获取了模糊的油膜图像,如图 12(a)所示,图 12(b)和图 12(c)分别为改进 HS 光流法和 FlowNet2 光流法的解算结果。通过调节采样时间,获取了间隔为 6s 的油膜图像,如图 13(a)所示,图 13(b)和图 13(c)分别为改进 HS 光流法和 FlowNet2 光流法的解算结果。

由于本试验所用的平板模型未放置于封闭管道内,模型表面的气流实际呈扩张状态,导致流线方向与水平方向存在一定的偏移,同时该模型表面水平且光滑,因此油流主要做直线运动,不会形成涡或鞍点。由此对比两种光流法解算的流线图,总体来看,改进 HS 光流法和 FlowNet2 光流法解算的流线的趋势走向基本相同,但明显可见改进 HS 光流法解算的流线图存在较多不连续的流线,表明其突变值较多,同时流线纹理也相对混乱,尤其是在噪声下的流线图。而 FlowNet2 光流法在 3 组试验下都能获取正确、清晰的流线图,与该试验场景和现有研究^[27]相符,进一步验证了基于深度学习的光流法在荧光油膜全局速度测量中的鲁棒性。

3.2 跨声速风洞试验

为进一步验证使用基于深度学习的光流法测量荧光油膜全局速度的有效性,对 2.4 m 跨声速风洞($Ma=0.82$)中的荧光油膜展翼图像进行了光流解算。图像如图 14 所示,解算结果如图 15 所示。

通过对比荧光油膜展翼图像,观察到展翼表面的油流趋势主要为向下运动,这与两种光流法解算得到的速度流线基本相符。但受试验环境影响,如光源、噪声、背景等,改进 HS 光流法解算的流线图在边界处较为混乱,而 FlowNet2 光流法解算的流线图纹理更为清晰和均匀。对比





图 10 试验平台

Fig.10 Experimental platform




图 11 亮度变化下的流线图
Fig.11 Streamlines with brightness variation




图 12 噪声下的流线图
Fig.12 Streamlines with noise




图 13 大位移下的流线图
Fig.13 Streamlines with large displacement






图 14 荧光油膜展翼图像
Fig.14 Fluorescent oil film images of airfoil

观察全局速度场,两种光流法解算的速度分布情况基本相同,在模型端部速度较大,尾部速度较小,与图像的油流运动情况相符。通过以上分析,进一步验证了基于深度学习的光流法的鲁棒性和有效性,对拓展其工程应用具有一定的参考价值。



(a) 改进HS光流法



(b) FlowNet2光流法

图 15 展翼速度场和流线图

Fig.15 Velocity magnitude and streamlines of airfoil

4 结 论

本文介绍了基于深度学习的 FlowNet2 光流法和基于先验的 HS 光流法的理论原理,并以此为角度进行了鲁棒性对比试验,最后通过风洞试验进行了分析和验证,主要结论如下:

1) 在不外加干扰的情况下,改进 HS 光流法和 FlowNet2 光流法的平均端点误差分别为 0.458 7 像素/s 和 0.381 7 像素/s。在分别添加 $\pm 2\%$ 到 $\pm 10\%$ 的亮度干扰后,改进 HS 光流法在亮度变亮时的平均端点误差上升明显,而 FlowNet2 光流法的平均端点误差相对稳定,其对亮度变化更不敏感,适用性更强。

2) 不同噪声的对比试验结果显示,无论添加高斯噪声、椒盐噪声还是混合噪声,FlowNet2 光流法的平均端点误差和端点误差的峰值都明显低于改进 HS 光流法,其对噪声的鲁棒性更优。

3) 不同光流位移的对比试验结果显示,两种光流法的平均端点误差都随着位移的增大而增

大,但 FlowNet2 光流法的平均端点误差上升趋势明显低于改进 HS 光流法,其处理大位移的性能更优。

4) 低速风洞和跨声速风洞的试验结果表明,基于深度学习的光流法更能获取正确、清晰、定量的荧光油膜全局速度场,进一步验证了该方法的鲁棒性和有效性,对飞行器表面摩擦阻测量研究具有一定的工程应用参考价值。

参考文献:

- [1] 邢宇,罗东明,余雄庆.超临界层流翼型优化设计策略[J].北京航空航天大学学报,2017,43(8):1616-1624.
XING Yu, LUO Dongming, YU Xiongqing. Optimization strategy of supercritical laminar flow airfoil design[J]. Journal of Beijing University of Aeronautics and Astronautics, 2017, 43(8):1616-1624. (in Chinese)
- [2] 朱自强,吴宗成,丁举春.层流流动控制技术及应用[J].航空学报,2011,32(5):765-784.
ZHU Ziqiang, WU Zongcheng, DING Juchun. Laminar flow control technology and application[J]. Acta Aeronautica et Astronautica Sinica, 2011, 32(5):765-784. (in Chinese)
- [3] 王帅,何国强,秦飞,等.超声速内流道摩擦阻力分析及减阻技术研究[J].航空动力学报,2019,34(4):908-919.
WANG Shuai, HE Guoqiang, QIN Fei, et al. Research on skin-friction drag and drag reduction technics in a supersonic inner flow path[J]. Journal of Aerospace Power, 2019, 34(4): 908-919. (in Chinese)
- [4] 黄湛,王宏伟,魏连风,等.基于荧光油膜的全局表面摩擦阻测量技术研究[J].空气动力学学报,2016,34(3):373-378.
HUANG Zhan, WANG Hongwei, WEI Lianfeng, et al. Research of global skin friction measurement based on fluorescent oil film[J]. Acta Aerodynamica Sinica, 2016, 34(3):373-378. (in Chinese)
- [5] NAUGHTON J W, SHEPLAK M. Modern developments in shear-stress measurement[J]. Progress in Aerospace Sciences, 2002, 38(6/7):515-570.
- [6] 林其勋,郭捷,李亚平,等.用热线风速仪研究轴流压气机的非定常流场及端壁附面层[J].航空动力学报,1989,4(2):141-144.
LIN Qixun, GUO Jie, LI Yaping, et al. Investigation on unsteady flow field and endwall boundary layer in axial flow compressor with hot wire anemometer[J]. Journal of Aerospace Power, 1989, 4(2):141-144. (in Chinese)
- [7] 徐大川,龙彦志,李玉栋.基于激光多普勒原理的极低风速测量实验[J].航空动力学报,2020,35(6):1228-1237.
XU Dachuan, LONG Yanzhi, LI Yudong. Experiment of extremely low wind velocity measurement based on laser Doppler[J]. Journal of Aerospace Power, 2020, 35(6):1228-1237. (in Chinese)
- [8] LIU T, SULLIVAN J P. Luminescent oil-film skin-friction meter[J]. AIAA Journal, 2015, 36(8):1460-1465.

- [9] 钱泓江,董秀成,张征宇.基于Hankel阵的荧光油膜灰度与厚度预测模型改进[J].航空动力学报,2021,36(10):2061-2071.
QIAN Hongjiang, DONG Xiucheng, ZHANG Zhengyu. Improved prediction model of gray and thickness of fluorescent oil film based on Hankel matrix[J]. Journal of Aerospace Power, 2021, 36(10):1228-1237. (in Chinese)
- [10] QIAN H, DONG X C, ZHANG Z Y. Research on stability of gray value of excited-state fluorescent oil film based on variable light vector angle[J]. Mathematical Problems in Engineering, 2021:8632992.1-8632992.12.
- [11] 钱泓江,董秀成,徐椰桢,等.基于神经网络的荧光油膜厚度与灰度研究[J].南京航空航天大学学报,2021,53(3):470-476.
QIAN Hongjiang, DONG Xiucheng, XU Yeting, et al. Fluorescence oil film thickness and gray level identification based on neural network[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2021, 53(3):470-476. (in Chinese)
- [12] ZHAI M, XIANG X, LV N, et al. Optical flow and scene flow estimation: a survey[J]. Pattern Recognition, 2021, 114(3):107861.1-107861.15.
- [13] TU Z, XIE W, ZHANG D, et al. A survey of variational and CNN-based optical flow techniques[J]. Signal Processing Image Communication, 2019, 72:9-24.
- [14] HORN B, SCHUNCK B G. Determining optical flow[J]. Artificial Intelligence, 1981, 17(1):185-203.
- [15] SUN D, ROTH S, Black M J. Secrets of optical flow estimation and their principles[C]//Proceeding of IEEE Conference on Computer Vision and Pattern Recognition. San Francisco, US:IEEE, 2010:2432-2439.
- [16] 邵绪强,杨艳,刘艺林.流体运动估计光流算法研究综述[J].中国图象图形学报,2021,26(2):355-367.
SHAO Xuqiang, YANG Yan, LIU Yilin. Review of optical flow algorithm in fluid motion estimation[J]. Journal of Image and Graphic, 2021, 26(2):355-367. (in Chinese)
- [17] FISCHER P, DOSOVITSKIY A, ILG E, et al. FlowNet: learning optical flow with convolutional networks[C]//Proceeding of IEEE International Conference on Computer Vision. Santiago, Chile:IEEE, 2015:2758-2766.
- [18] ILG E, MAYER N, SAIKIA T, et al. FlowNet 2.0: evolution of optical flow estimation with deep networks[C]//Proceeding of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, US:IEEE, 2017:1647-1655.
- [19] HEITZ D, MÉMIN E, SCHNÖRR C. Variational fluid flow measurements from image sequences: synopsis and perspectives[J]. Experiments in Fluids, 2010, 48(3):369-393.
- [20] BROX T, BRUHN A, PAPENBERG N, et al. High accuracy optical flow estimation based on a theory for warping[C]//Proceeding of European Conference on Computer Vision. Berlin, German:Springer, 2004:25-36.
- [21] 李鹏.全局表面摩擦应力直接测量技术研究[D].南京:南京航空航天大学,2012.
LI Peng. Studies of direct measurement techniques about global skin friction[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2012. (in Chinese)
- [22] 邹易峰,张征宇,王学渊,等.风洞试验模型表面的荧光油膜路径运动速度测量[J].航空学报,2019,40(6):92-105.
ZOU Yifeng, ZHANG Zhengyu, WANG Xueyuan, et al. Velocity measurement of fluorescent oil film path movement on wind tunnel testing model surface[J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(6):92-105. (in Chinese)
- [23] WANG Bo, CAI Zemin, SHEN Lixin, et al. An analysis of physics-based optical flow[J]. Journal of Computational and Applied Mathematics, 2015, 276:62-80.
- [24] 陈吉明,吕金磊,廖达雄,等.连续跨声速风洞试验段降噪技术[J].航空动力学报,2021,36(8):1712-1719.
CHEN Jiming, LÜ Jinlei, LIAO Daxiong, et al. Noise reduction technology in test section of continuous transonic wind tunnel[J]. Journal of Aerospace Power, 2021, 36(8):1712-1719. (in Chinese)
- [25] HU Y, RUI S, LI Y. Efficient coarse-to-fine patch match for large displacement optical flow[C]//Proceeding of IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, US:IEEE, 2016:5704-5712.
- [26] WEINZAEPFEL P, REVAUD J, HARCHAOU Z, et al. DeepFlow: large displacement optical flow with deep matching[C]//Proceeding of IEEE International Conference on Computer Vision. Sydney, Australia:IEEE, 2013:2523-2541.
- [27] COSTANTINI M, LEE T, NONOMURA T, et al. Feasibility of skin-friction field measurements in a transonic wind tunnel using a global luminescent oil film[J]. Experiments in Fluids, 2021, 62(1):1-34.

(编辑:秦理曼)