

DOI: 10.19650/j.cnki.cjsi.J2514358

GPR 初值引导自监督 DIC 的旋转 结构位移场测量方法 *

金 旭^{1,2}, 张一鸣^{1,2}, 李 广^{1,2}, 徐自力^{1,2}

(1. 西安交通大学航天航空学院 西安 710049; 2. 西安交通大学复杂服役环境重大装备结构强度与寿命全国重点实验室 西安 710049)

摘要:针对传统数字图像相关(DIC)方法因依赖子集相关性计算,在旋转测试中存在去相关现象和参数敏感性高的问题,提出了一种融合高斯过程回归(GPR)引导自监督DIC的旋转位移场测量方法(GPR-SSL-DIC)。该方法构建基于Kolmogorov-Arnold网络的自监督学习框架,利用重建图像与参考图像的灰度差异及位移场平滑约束设计自监督损失函数,驱动位移场自适应优化,从而避免了传统DIC方法基于子集匹配范式的局限。为增强网络对大角度旋转的收敛能力,在结构目标区域检测具有旋转不变性的SURF特征点,并利用其位移信息构建稀疏观测样本;进一步结合GPR预测全局位移场作为初始解,以引导网络收敛至真实解空间。数值模拟试验表明,在全周刚体旋转及耦合大变形工况下,所提方法的平均端点误差不超过0.0017 pixels;在叠加正弦位移的复杂场景中,其平均端点误差不超过0.0074 pixels,较传统DIC方法减少93.5%,验证了该方法对不同旋转工况的自适应能力与高精度表现。旋转叶片位移测量试验显示,在帧间旋转角度为9°时,所提方法对叶片表面固定点距离测量的标准差较传统DIC方法减少54.3%,稳定性更优;在帧间旋转角度达30°时,传统DIC方法因去相关失效,而所提方法仍能稳定获取叶片位移分布。研究表明,所提方法具备处理大角度旋转场景的能力,为旋转结构位移场测量提供了有效手段。

关键词: 旋转结构; 数字图像相关; 自监督学习; 高斯过程回归; 位移场

中图分类号: TH741 文献标识码: A 国家标准学科分类代码: 460.40

GPR-initialized self-supervised learning DIC for displacement field measurement of rotating structures

Jin Xu^{1,2}, Zhang Yiming^{1,2}, Li Guang^{1,2}, Xu Zili^{1,2}

(1. School of Aerospace Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. State Key Laboratory for Strength and Vibration of Mechanical Structures, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Traditional digital image correlation (DIC) methods that rely subset-based correlation calculations are prone to decorrelation and strong parameter sensitivity under rotational motions. To overcome these limitations, this study proposes a Gaussian process regression-guided self-supervised learning DIC method (GPR-SSL-DIC) for accurate rotational displacement field measurement. The method develops a self-supervised learning framework based on the Kolmogorov-Arnold Network (KAN) network, in which a loss function is formulated using the grayscale differences between the reconstructed and reference images together with a displacement-field smoothness constraint, driving adaptive optimization of the displacement field and thereby overcoming the limitations of the conventional subset-matching paradigm in traditional DIC. To improve convergence under large-angle rotations, rotation-invariant SURF feature points are detected in the structural target region, and their displacement information is used to construct sparse observation samples. Furthermore, Gaussian process regression is employed to predict a global displacement field as an initial solution, thereby guiding the network to converge toward the true solution space. Numerical simulations show that the proposed method achieves average end-point errors below 0.0017 pixels under rigid-body rotation and coupled large-deformation conditions, and below 0.0074 pixels with sinusoidal displacements are superimposed, corresponding to a 93.5% improvement over traditional DIC. Rotating-blade displacement experiments further demonstrate that at a 9° inter-frame rotation, the standard deviation of fixed-point distance measurements decreases by 54.3% compared with traditional DIC. At 30°, where traditional DIC fails due to severe decorrelation, the proposed method is still able to obtain the displacement distribution of the blade. These results confirm that the proposed framework is robust under large-angle rotational

conditions and offers an effective solution for displacement field measurement in rotating structures.

Keywords: rotating structures; digital image correlation; self-supervised learning; Gaussian process regression; displacement field

0 引言

螺旋桨叶、风电叶片等旋转结构作为叶轮机械的核心部件,在服役过程中需承受气动力、离心力、惯性力等多种复杂力学载荷的共同作用,易导致结构偏离最佳运行状态,甚至出现超出安全阈值的变形,影响其工作性能与疲劳寿命^[1]。因此,开展旋转结构全场、高精度的动态位移测量对其结构优化设计、力学性能评估至关重要,且能够为健康状态监测提供重要支撑。

基于计算机视觉的数字图像相关(digital image correlation, DIC)方法凭借其高精度、非接触性与高空间分辨率等优势为旋转结构的动态响应测试提供了一种有效手段^[2]。例如,潘济宇等^[3]采用3D-DIC结合旋转信号触发锁相拍摄,成功获取了螺旋桨叶片工作状态下的三维形貌。Huñady等^[4]利用DIC捕获薄壁圆盘在不平衡惯性力作用下的振动响应,并通过迭代最近点算法剔除刚体运动以获取工作挠度形状。Guan等^[5]和Feng等^[6]将大视场标定与DIC技术相结合,实现了风电叶片上多点三维运动轨迹的跟踪。

传统DIC方法通过形函数描述子集变形,并以反向组合高斯-牛顿等迭代算法最小化参考与变形子集间的灰度残差来求解位移参数^[7]。然而,该类算法的收敛范围有限^[8],当结构发生大角度旋转时,参考子集的空间取向显著改变,致使在变形图像中难以匹配到对应区域,易引发去相关现象而导致计算失效。为提升DIC算法对旋转运动的适应性,研究者在形函数中显式引入旋转参数,同时结合具备旋转鲁棒性的初值估计方法,以辅助位移与旋转参数的初始化。例如,Yang等^[9]通过逆向旋转参考子集抑制旋转诱发的去相关效应,并结合粒子群优化算法实现整数像素级初始位移估计,但要求相邻帧间旋转角不超过16°;Turner等^[10]利用图像配准方法估计全局刚体运动初值,但其在帧间旋转角度达到29.4°时已基本失效^[11];另一类方法利用圆形或环形模板的旋转不变幅值特征估计初值^[12-14],但其基本假设建立在小变形条件之上,面对大变形匹配时存在困难^[15]。此外,子集尺寸、形函数阶次等模型参数对测量精度影响显著,通常依赖经验设定或针对具体场景调优,制约了传统DIC在旋转场景下的通用性与自动化程度。

近年来,基于深度学习的数字图像相关方法受到越来越多的关注。与依赖显式参数模型的传统DIC方法不同,基于深度学习的DIC方法通过参数丰富的隐式神经网络模型表征图像间的变形关系,具备更强非线性建模能力,能够在无需手动调整参数的情况下实现高精度、密集位移

场估计^[16]。然而,此类方法通常依赖大量高质量标注数据进行监督预训练,其泛化能力和精度受限于训练数据集规模与多样性^[17]。特别在实际工程应用中,精确标注的真实变形场数据难以获取,预训练过程亦需耗费大量计算资源。针对上述问题,Cheng等^[18]借助U-Net网络开发自监督DIC方法(self-supervised learning DIC, SSL-DIC),该方法基于光度一致性假设与位移连续性约束,通过最小化参考图像生成的预测变形图像与实际变形图像之间的差异,摆脱了对真实位移标签的依赖。Li等^[19]进一步引入物理信息神经网络(physics-informed neural networks, PINN),基于多层次感知机构建PINN-DIC模型,将散斑图像坐标作为输入,位移场作为输出,有效降低了模型复杂度并提高了拟合精度。然而,在大角度旋转工况下,帧间大幅刚体位移会导致网络初始预测严重偏离真值,使其难以确定有效优化方向,最终导致优化过程陷入局部极小甚至完全收敛失败,限制了SSL-DIC在旋转结构测量中的实用性。

为此,本研究提出了一种融合高斯过程回归(Gaussian process regression, GPR)与自监督学习的旋转位移场测量方法——GPR-SSL-DIC,实现在大角度旋转工况下的高精度位移测量。主要研究工作包括:1)构建基于Kolmogorov-Arnold网络(Kolmogorov-Arnold networks, KAN)的自监督学习框架,设计光度一致性与位移场平滑约束复合驱动的损失函数,实现位移场的自适应优化;2)提出加速稳健特征(speed up robust features, SURF)匹配结合GPR全局回归的初值生成策略,利用稀疏特征点位移构建高斯过程先验,生成连续平滑的全局初始位移场,作为KAN的收敛先验有效引导网络优化,显著提升在大角度旋转工况下的收敛稳定性;3)通过系列数值模拟与真实旋转叶片试验,验证了所提方法在旋转位移场测量中的高精度表现与鲁棒性。

1 GPR-SSL-DIC 位移场测量方法

本研究提出的GPR-SSL-DIC方法主要流程如图1所示。

1.1 全局位移初值估计策略

1) 基于SURF的稀疏特征点提取

为在旋转场景下获得高置信度的稀疏位移观测值,本文采用SURF算法^[20]对参考图像与目标图像进行特征点提取与匹配。该算法首先利用积分图像与盒式滤波器快速构建尺度空间,计算各像素点的Hessian矩阵响应;随后在离散尺度空间内非极大值抑制策略,即将候选点与其同尺度层8个相邻像素及上下尺度层各9个像素

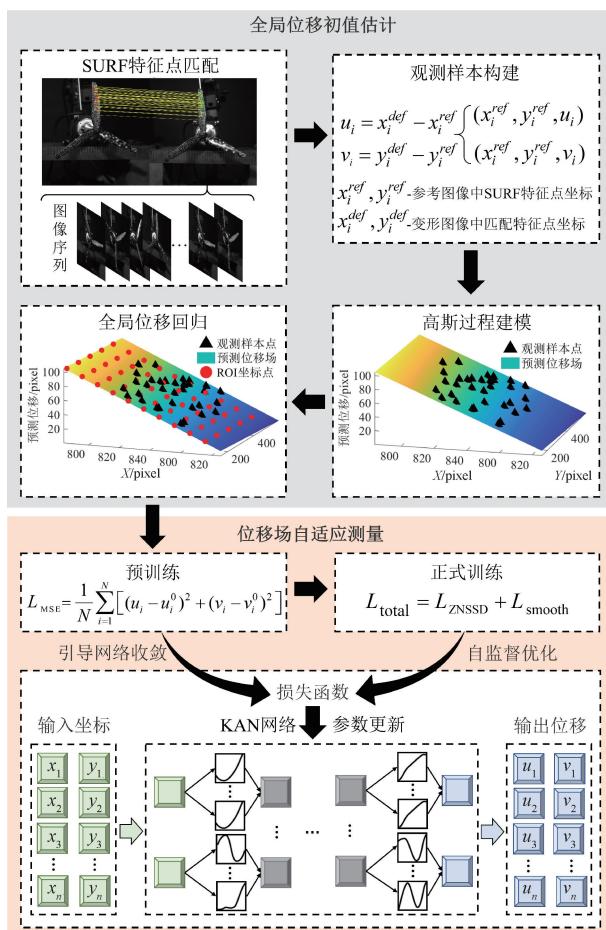


图 1 GPR-SSL-DIC 方法流程

Fig. 1 Flowchart of the proposed method

(共 26 个邻点, 如图 2 所示) 进行比较, 仅保留局部极值点作为尺度不变特征点。

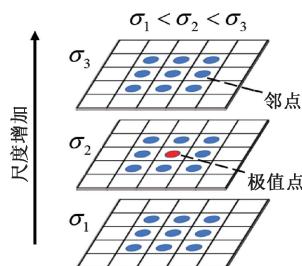


图 2 尺度空间中的 26 个邻点

Fig. 2 The 26 neighbors points in scale-space

在描述子生成阶段, 以特征点为中心, 在半径为 6σ (σ 为特征点所在尺度) 的圆形邻域内通过扇形 Haar 小波响应统计确定主方向; 随后沿主方向对局部图像进行旋转校正, 取 $20\sigma \times 20\sigma$ 正方形区域并划分为 4×4 个子区域, 对每个子区域计算水平与垂直方向 Haar 小波响应的和及其绝对值之和, 形成 4 维统计向量, 最终串联构成 64 维旋转不变的 SURF 描述子, 如图 3 所示。

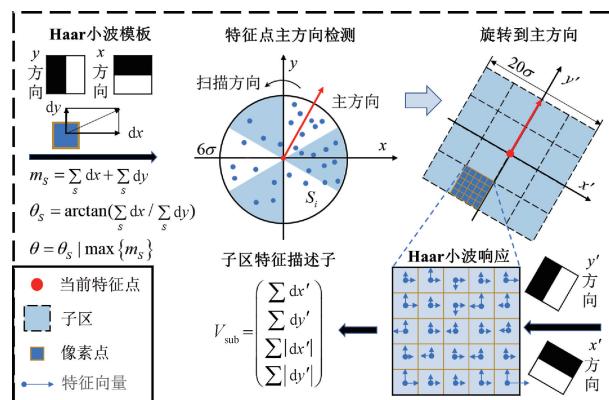


图 3 SURF 描述子构建流程

Fig. 3 Construction process of SURF descriptors

匹配阶段采用 Lowe 提出的最近邻与次近邻距离比值准则(阈值取 0.4)^[21]进行初步筛选。为进一步去除误匹配并确保几何一致性, 本文引入随机抽样一致算法估计两视图间的基础矩阵, 并依据对极几何约束保留内点集合。最终获得的稀疏匹配点对具有较高的准确性和鲁棒性, 为后续生成密集位移场初始值提供了可靠的观测先验。

2) 基于 GPR 的位移场初值预测

GPR 作为一种经典的非参数贝叶斯模型, 凭借协方差核函数的灵活选择, 具备强大的非线性建模能力, 在小样本监督学习任务中表现出色^[22]。本文从目标区域(region of interest, ROI)中提取稀疏的 SURF 特征点作为观测样本, 基于 GPR 进行贝叶斯推断, 生成符合物理约束的位移场初始估计, 流程如图 4 所示。该初始值作为可靠先验, 为后续自监督学习网络提供了解空间的有效引导, 显著提升了网络在大角度旋转场景下的收敛稳定性。

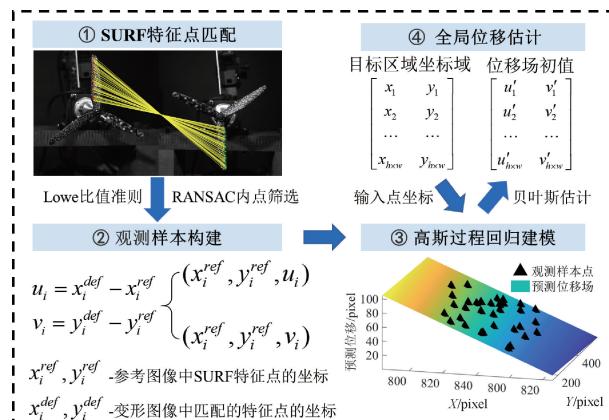


图 4 基于 GPR 的初值估计方法流程

Fig. 4 Flowchart of the GPR-based initial value estimation

高斯过程本质上是对函数 $f: \mathbf{R}^D \rightarrow \mathbf{R}$ 的概率分布描述。该过程由均值函数 $m(x)$ 及协方差函数 $k(x, x')$ 确定, 即:

$$f(x) \sim GP(m(x), k(x, x')) \quad (1)$$

式中: x, x' 表示两个不同观测样本; $m(x)$ 为均值函数, 通常假定为零均值; $k(x, x')$ 为核函数, 它刻画了输入空间中任意两样本间的相似性。

本文以 SURF 特征点的像素坐标 $\mathbf{X} = \{x_i\}_{i=1}^n$ 为输入, 对应的水平或垂向位移 $\mathbf{Y} = \{y_i\}_{i=1}^n$ 为输出, 建立从坐标到位移的回归模型。观测值 \mathbf{Y} 的先验分布如式(2)所示。

$$\mathbf{Y} \sim N(\mathbf{0}, \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I}_n) \quad (2)$$

式中: \mathbf{I}_n 为 n 维单位矩阵; σ^2 为观测噪声方差; $\mathbf{K}(\mathbf{X}, \mathbf{X}) \in \mathbf{R}^{n \times n}$ 代表观测数据间关系的协方差矩阵, 元素满足 $[\mathbf{K}(\mathbf{X}, \mathbf{X})]_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$ 。

对于待预测位置 \mathbf{x}^* , 其位移 \mathbf{y}^* 与已知观测值 \mathbf{Y} 服从联合高斯分布, 即:

$$\begin{bmatrix} \mathbf{Y} \\ \mathbf{y}^* \end{bmatrix} \sim N\left(0, \begin{bmatrix} \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I}_n & \mathbf{K}(\mathbf{x}^*, \mathbf{X})^\top \\ \mathbf{K}(\mathbf{x}^*, \mathbf{X}) & k(\mathbf{x}^*, \mathbf{x}^*) + \sigma^2 \end{bmatrix}\right) \quad (3)$$

式中: $\mathbf{K}(\mathbf{x}^*, \mathbf{X}) \in \mathbf{R}^{1 \times n}$ 代表预测样本与观测样本之间的互协方差矩阵, 元素满足 $[\mathbf{K}(\mathbf{x}^*, \mathbf{X})] = [k(\mathbf{x}^*, \mathbf{x}_1) \ k(\mathbf{x}^*, \mathbf{x}_2) \ \dots \ k(\mathbf{x}^*, \mathbf{x}_n)]$ 。

依据贝叶斯定理, \mathbf{y}^* 的后验分布为:

$$\mathbf{y}^* | \mathbf{X}, \mathbf{Y}, \mathbf{x}^* \sim N(\mathbf{y}_m^*, Var(\mathbf{y}^*)) \quad (4)$$

后验均值与方差分别为:

$$\begin{aligned} \mathbf{y}_m^* &= \mathbf{K}(\mathbf{x}^*, \mathbf{X})(\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I}_n)^{-1} \mathbf{Y} \\ Var(\mathbf{y}^*) &= k(\mathbf{x}^*, \mathbf{x}^*) - \mathbf{K}(\mathbf{x}^*, \mathbf{X})(\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma^2 \mathbf{I}_n)^{-1} \mathbf{K}(\mathbf{X}, \mathbf{x}^*) \end{aligned} \quad (5)$$

式中: 后验均值 \mathbf{y}_m^* 即为该点的预测位移; 后验方差 $Var(\mathbf{y}^*)$ 反映了预测结果的不确定性。

1.2 初值引导的 SSL-DIC 测量方法

1) 网络结构

本文采用的 SSL-DIC 网络架构如图 5 所示。网络主体由 KAN 构成^[23], 相较于 U-Net 等以图像块为输入、通过编码-解码结构间接回归位移场的架构, KAN 通过边上的可学习激活函数, 能够直接实现从连续坐标空间到位移向量空间的函数逼近。这一特性在数学上更接近于使用形函数描述物理场的思想。网络的输入层包含两个节点, 用于逐点建立图像坐标到位移的映射关系。输出层同样为两个节点, 分别输出坐标点的水平位移 u 与垂直位移 v 。

KAN 的理论基础源于 Kolmogorov-Arnold 表示定理。该定理指出: 任何定义在 $[0, 1]^n$ 上的多元连续函数 $f: [0, 1]^n \rightarrow \mathbf{R}^n$, 均可表示为若干一元连续函数的嵌套组合, 即:

$$f(x) = f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_{p=1}^n \phi_{q,p}(x_p) \right) \quad (6)$$

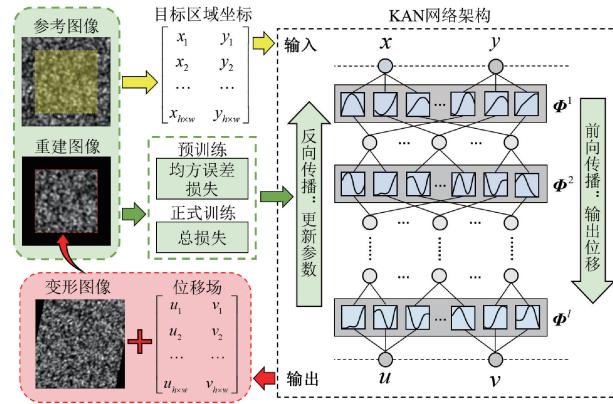


图 5 基于 KAN 的 SSL-DIC 架构

Fig. 5 KAN-based SSL-DIC framework

式中: $\phi_{q,p}$ 为输入变量 x_p 的单元非线性变换函数; Φ_q 表示中间结果的组合。 p, q, n 分别表示为输入变量索引、函数层索引与输入向量维度。

与之相应, KAN 将可学习的一维非线性函数直接参数化于连接边上。第 l 层至第 $l+1$ 层的映射由函数矩阵 Φ^l 表征, 即:

$$\Phi^l = \begin{pmatrix} \phi_{1,1}^l(\cdot) & \phi_{1,2}^l(\cdot) & \cdots & \phi_{1,n_l}^l(\cdot) \\ \phi_{2,1}^l(\cdot) & \phi_{2,2}^l(\cdot) & \cdots & \phi_{2,n_l}^l(\cdot) \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{n_{l+1},1}^l(\cdot) & \phi_{n_{l+1},2}^l(\cdot) & \cdots & \phi_{n_{l+1},n_l}^l(\cdot) \end{pmatrix} \quad (7)$$

式中: $\phi_{j,i}^l$ 表示连接第 l 层第 i 个节点与第 $l+1$ 层第 j 个节点之间的可学习一维函数。

第 $l+1$ 层第 j 个节点的输出定义为所有传入边函数之和, 即:

$$x_j^{l+1} = \sum_{i=1}^{n_l} \phi_{j,i}^l(x_i^l) \quad (8)$$

本文选用基于泰勒展开的可学习激活函数, 即:

$$\phi(x) = \sum_{k=1}^K c_k (x - a)^k + \beta \quad (9)$$

式中: k 为多项式阶数; 系数 c_k 与偏差项 β 为可学习参数; a 为展开中心, 为简化计算设置为 0。

通过多层函数矩阵的级联, 网络最终输出为:

$$KAN(x) = (\Phi^l \circ \dots \circ \Phi^1 \circ \Phi^0)x \quad (10)$$

前向传播得到全局位移场后, 采用双三次 B 样条插值在变形图像中重采样对应位置的灰度值, 生成重建目标图像。随后结合后文设计的光度一致性损失与正则化约束, 将重建灰度与参考图像真实灰度进行比较, 通过反向传播优化全部激活函数参数, 实现完全自监督的学习过程。

2) 损失函数

为利用 GPR 预测得到的全局初始位移场为网络提

供合理先验,本文设计了两阶段训练策略。

在正式训练前,首先以 GPR 得到的全局初始位移场作为伪标签,对网络进行引导预训练。该阶段采用均方误差(mean square error, MSE)损失,使网络快速收敛至合理的解空间。MSE 损失定义为:

$$L_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N [(u_i - u_i^0)^2 + (v_i - v_i^0)^2] \quad (11)$$

式中: u_i, v_i 为网络在第 i 个像素点输出的位移; u_i^0, v_i^0 为对应位置的 GPR 初始位移。

引导训练结束后,切换至正式训练进行自监督优化。该阶段仅依赖图像自身信息,采用光度一致性损失与平滑正则项驱动的复合损失函数。光度损失选用零均值归一化互相关准则(zero-mean normalized sum squared difference, ZNSSD),其定义如式(12)所示。ZNSSD 对光照线性变化具有强鲁棒性,可提升模型对实际光照扰动的适应能力^[24]。

$$L_{\text{ZNSSD}} = \sum_{i=1}^N \left[\frac{f(i) - f_m}{\sqrt{\sum (f(i) - f_m)^2}} - \frac{g(i) - g_m}{\sqrt{\sum (g(i) - g_m)^2}} \right]^2 \quad (12)$$

式中: $f(i)$ 和 $g(j)$ 分别为参考图像与重建图像在对应位置的灰度值; f_m 和 g_m 分别为区域灰度均值。

为保证位移场空间连续性并抑制噪声放大,引入基于图像梯度的二阶平滑正则项^[25],即:

$$L_{\text{smooth}} = \frac{1}{N} \sum_{i=1}^N \left[\left| \frac{\partial^2 U}{\partial^2 x} \right| \exp \left(- \left\| \frac{\partial I}{\partial x} \right\| \right) + \left| \frac{\partial^2 V}{\partial^2 y} \right| \exp \left(- \left\| \frac{\partial I}{\partial y} \right\| \right) \right] \quad (13)$$

式中 $\partial I/\partial x$ 与 $\partial I/\partial y$ 分别为图像在 x 与 y 方向的梯度; $\partial^2 U/\partial x^2$ 与 $\partial^2 V/\partial y^2$ 为变形场在 x 与 y 方向的二阶梯度。

正式训练阶段的总损失函数为:

$$L_{\text{total}} = L_{\text{ZNSSD}} + L_{\text{smooth}} \quad (14)$$

得益于上述两阶段训练策略,网络首先在引导阶段快速收敛至有效解空间,随后在完全无标注条件下进一步优化,最终实现高精度的大旋转位移测量。

1.3 三维位移测量策略

双目立体视觉系统成像模型如图 6 所示。该系统由左右两台相机同步采集被测对象运动图像,分别获得各测点在左、右相机图像平面上的像素坐标(u_l, v_l)和(u_r, v_r),结合标定得到的相机内参、外参及畸变参数,通过三角测量原理^[26]即可解算出对应点的三维世界坐标(x_w, y_w, z_w),从而实现运动物体全场空间位置重建。

本文试验采用如图 7 所示的立体匹配策略,以获取全场测点的匹配信息。具体流程为:以左相机首帧图像为全局参考帧,分别对左、右相机图像序列独立运用所提出的 GPR-SSL-DIC 方法,进行全场亚像素级运动跟踪,

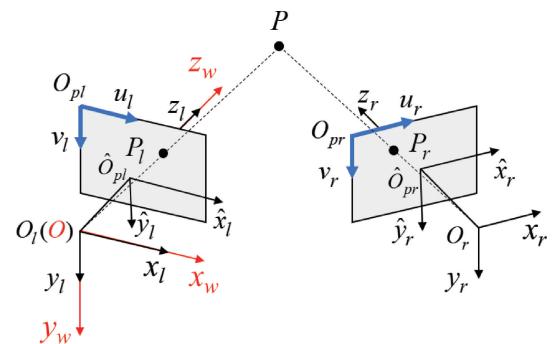


图 6 双目视觉成像模型

Fig. 6 Binocular vision imaging model

获得同一物理测点在左右视图中随时间变化的二维像素坐标序列;随后,将每一时刻的匹配点对代入已标定的双目成像模型,逐点解算其三维世界坐标,最终实现旋转叶片的三维位移场测量。

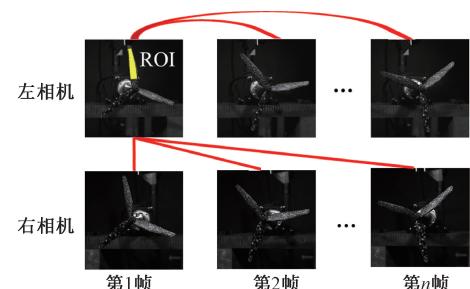


图 7 立体匹配策略

Fig. 7 Stereo matching strategy

2 数值验证

为定量评估 GPR-SSL-DIC 方法在旋转位移场测量中的精度,本节设计了一系列具有已知理论真值的数值模拟试验。

散斑图采用 Zhou 等^[27]提出的高斯散斑生成方法,分辨率为 256 pixels × 256 pixels,包含 3 000 个直径 4 pixels、中心光强为 20 的高斯斑点。基于后向映射法^[28],生成了如图 8 所示的两组刚体旋转图像序列。

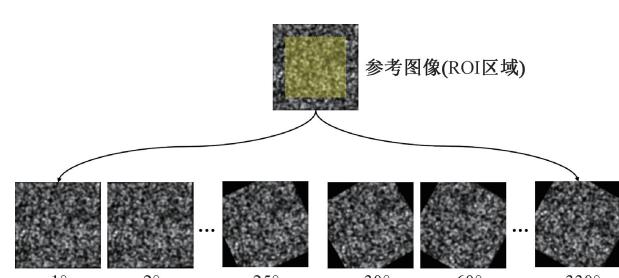


图 8 不同旋转角度模拟散斑图

Fig. 8 Speckle patterns with different rotational angles

针对 $0^\circ \sim 25^\circ$ 的连续旋转序列,本文对比了 5 种代表性方法的测量精度,包括纯 GPR(基于有理二次核(rational quadratic kernel, RQ Kernel),该核可视为多尺度平方指数核的加权组合,能够同时捕捉旋转位移场的全局趋势与局部细节、传统子集类 DIC(Ncorr^[29], 网格步长 1 pixel, 子集半径分别取 11, 21, 31 pixels)、PINN-DIC、基于 KAN 的无初值引导 SSL-DIC 及 GPR-SSL-DIC。其中,KAN 经超参数优化后采用单层 128 节点结构,在表达能力与计算效率之间取得最佳平衡,并基于 PyTorch 1.9.0 实现。为避免传统 DIC 在图像边缘因散斑缺失导致的精度退化,所有方法统一选取中心 180 pixels \times 180 pixels 区域作为 ROI。测量精度采用平均端点误差(average endpoint error, AEE)进行定量评价,定义如式(15)所示。

$$AEE = \frac{1}{N} \sum_{i,j} \sqrt{(u_{i,j}^t - u_{i,j}^p)^2 + (v_{i,j}^t - v_{i,j}^p)^2} \quad (15)$$

式中: $u_{i,j}^t, v_{i,j}^t$ 为该点理论位移; $u_{i,j}^p, v_{i,j}^p$ 为计算位移。

不同方法的测量结果如图 9 所示。

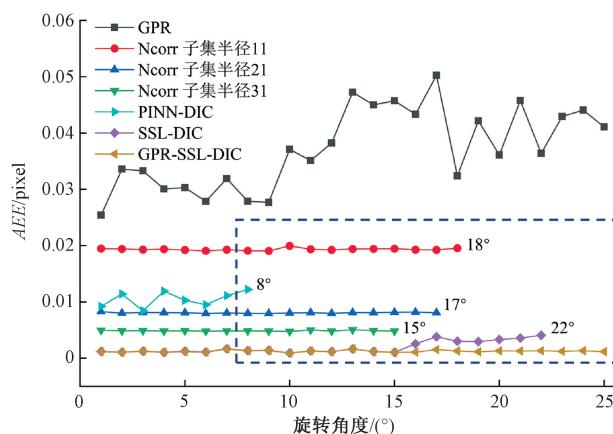


图 9 不同方法在 $1^\circ \sim 25^\circ$ 旋转角下 AEE 结果

Fig. 9 Comparison of AEE results for different methods with rotation angles from 1° to 25°

图 9 结果表明,在刚体旋转这一连续平滑位移场场景中,传统 DIC 的测量精度高度依赖子集尺寸:大子集虽能有效抑制噪声并提升匹配精度,却显著削弱旋转容忍度;小子集虽对旋转更具适应性,但易受噪声干扰导致随机误差增大。具体而言,子集半径为 11 pixels 时,Ncorr 可在 18° 以内保持稳定收敛;当子集半径增至 31 pixels 时,其收敛阈值降至 15° ,超过该角度即发生匹配失效。

对于自监督类方法,基于多层感知机的 PINN-DIC 在旋转角超过 8° 后即出现收敛困难。而无初值引导的 SSL-DIC 凭借 KAN 更强的函数逼近能力,在拟合精度与旋转适应性上优于 PINN-DIC,将可靠测量范围扩展至 22° 。然而,当旋转角度进一步增大时,该方法亦陷入大位移模式学习的局部极小,导致收敛失败。本文通过引入 GPR 预测的全局初始位移场作为先验引导,有效消除

了大旋转工况下的优化“初始盲区”,显著提升了收敛稳定性和大角度测量上限。

计算效率对比如图 10 所示。得益于 KAN 的强拟合能力与 GPR 的收敛引导,GPR-SSL-DIC 在实现最高测量精度的同时,仍保持最优的计算速度,展现出优异的综合性能。

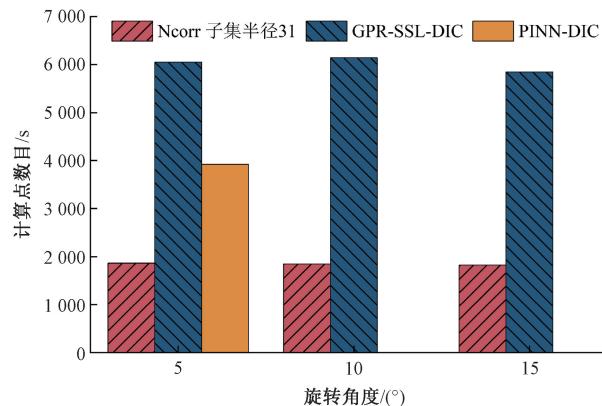


图 10 不同方法的计算效率

Fig. 10 Comparison of computational costs

进一步采用 GPR-SSL-DIC 方法对 $30^\circ \sim 330^\circ$ (步长为 30°)的全周旋转序列进行位移场测量,统计 ROI 内的最大误差(maximum error, ME)与 AEE,结果如表 1 所示。数据表明:在整个旋转范围内,ME 不超过 0.0030 pixels,AEE 稳定保持在 0.0013 pixels 以内,证实了所提方法在连续大旋转工况下具备出色的亚像素级测量精度与全角度鲁棒性。

表 1 GPR-SSL-DIC 在刚体旋转场景下测量误差

Table 1 Measurement errors of GPR-SSL-DIC under rigid rotation at different angles

旋转角度 /(°)	ME/pixel		AEE/pixel
	u	v	
30	0.0029	0.0015	0.0013
60	0.0026	0.0023	0.0013
90	0.0022	0.0014	0.0012
120	0.0016	0.0030	0.0013
150	0.0023	0.0025	0.0013
180	0.0015	0.0021	0.0012
210	0.0030	0.0015	0.0013
240	0.0026	0.0023	0.0013
270	0.0020	0.0015	0.0011
300	0.0016	0.0029	0.0013
330	0.0023	0.0026	0.0013

为进一步模拟旋转结构伴随变形的情况,在原始散斑图上沿 x 、 y 方向分别施加 0.20 与 -0.05 的均匀应变,随后将变形后图像按 30° 步长旋转至 30°~330°,构造大变形与大旋转耦合的复杂测试序列,如图 11 所示。在该极端工况下,GPR-SSL-DIC 的测量误差统计如表 2 所示。结果显示,即便面临大变形与大旋转的叠加扰动,ME 仍仅为 0.003 8 pixels,AEE 控制在 0.001 7 pixels 以内,表明所提方法在大变形旋转复合场景中依然能够保持优异的测量精度与稳定收敛能力。

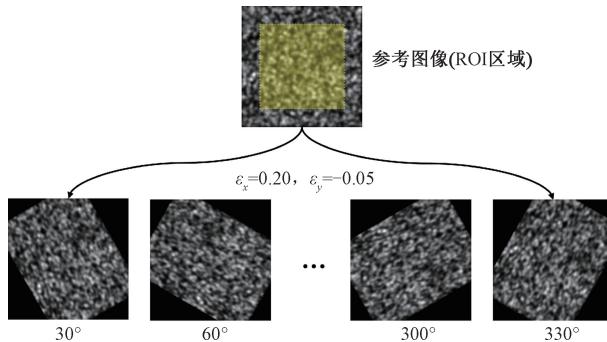


图 11 不同旋转角度下大变形模拟散斑图

Fig. 11 Speckle pattern under large deformation with different rotational angles

表 2 GPR-SSL-DIC 在大变形旋转场景下测量误差

Table 2 Measurement errors of GPR-SSL-DIC under large deformation at different rotation angles

旋转角度 /(°)	ME/pixel		AEE/pixel
	u	v	
30	0.003 7	0.002 3	0.001 7
60	0.003 8	0.001 3	0.001 4
90	0.002 8	0.002 0	0.001 4
120	0.002 2	0.003 8	0.001 7
150	0.001 3	0.003 8	0.001 4
180	0.003 1	0.002 4	0.001 7
210	0.003 8	0.002 4	0.001 7
240	0.003 8	0.001 4	0.001 4
270	0.002 9	0.001 9	0.001 5
300	0.002 3	0.003 7	0.001 7
330	0.001 4	0.003 8	0.001 4

为进一步评估 GPR-SSL-DIC 方法的自适应能力,本文构造了正弦变形与旋转位移叠加的复杂图像,以模拟旋转测量过程中伴随局部高频变形的情形。首先沿 x 方向施加如式(16)所示的正弦位移场。将该正弦位移作为局部变形叠加至参考图像,随后将变形后图像整体旋转 10°,生成测试图像。ROI 区域内的位移场测量结果如

图 12 所示,相应的 ME 与 AEE 统计如表 3 所示。

$$u = 3 \times \sin\left(\frac{2\pi x}{100} - \frac{\pi}{2}\right) \quad (16)$$

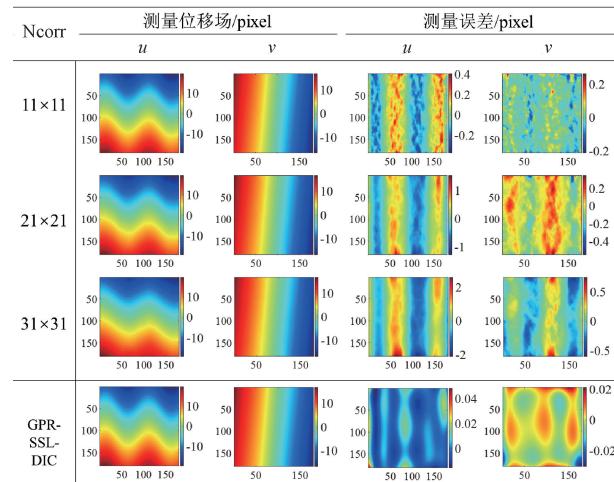


图 12 使用不同子集尺寸 DIC 与 GPR-SSL-DIC 方法测得的位移及误差

Fig. 12 Displacement and error maps measured using DIC with different subset sizes and the proposed GPR-SSL-DIC method

表 3 传统 DIC 与 GPR-SSL-DIC 方法的测量误差

Table 3 Measured errors using traditional DIC and the GPR-SSL-DIC method

测量方法	ME/pixel		AEE/pixel
	u	v	
11×11	0.403 1	0.262 8	0.113 1
Ncorr	21×21	1.537 2	0.358 0
	31×31	2.585 0	0.664 6
GPR-SSL-DIC	0.048 3	0.030 3	0.007 4

从图 12 可见,在位移梯度剧烈变化的正弦场中,传统 DIC 受子集窗口的内在平滑效应(相当于低通滤波)制约;大子集虽能抑制噪声,但无法分辨高频正弦分量,导致显著匹配误差;小子集虽对局部复杂变形更具敏感性,却易受噪声放大。相比之下,GPR-SSL-DIC 能够精准捕捉并重建高频正弦特征,其 AEE 较最佳传统 DIC(子集半径 11 pixels)降低了 93.5%,充分彰显了该方法在旋转工况下对复杂局部变形的出色自适应性与测量精度。

3 试验验证

本研究以直径为 17.8 cm 的碳纤尼龙叶片为对象,开展了真实旋转条件下的位移测量试验,试验场景如

图 13(a)所示。采用两台 Revealer 504 相机(分辨率为 $1\,664 \text{ pixels} \times 1\,664 \text{ pixels}$)搭建立体视觉系统,通过硬件触发实现同步拍摄。镜头焦距 17 mm,光圈 F2.8,工作距离约为 0.5 m。

叶片表面喷洒白色哑光油漆制备随机散斑,如图 13(b)所示。散斑平均直径为 5.2 pixels,分布密度 44.1%。照明系统采用两台 300 W 金贝 EFII-300 直流 LED 光源,置于叶片表面约 1 m 处,提供均匀、无闪烁的恒定照明,叶片表面实测照度 90 lux。相机曝光时间设为 100 μs ,所采集散斑图像对比度为 41.6%,满足 DIC 分析的图像质量要求。

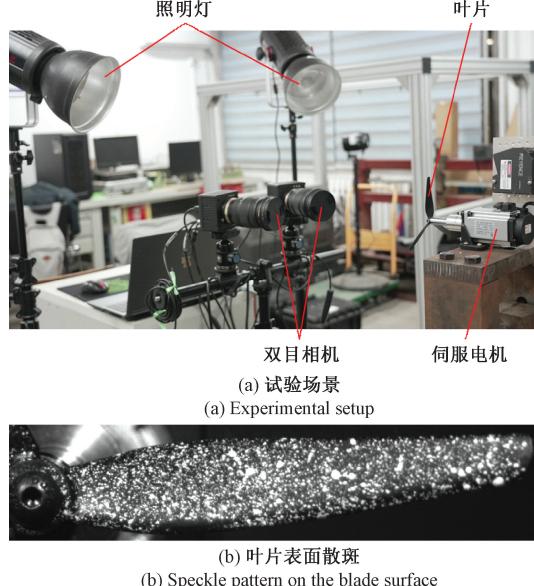


图 13 叶片旋转位移测量试验

Fig. 13 Rotational displacement measurement experiment of the blade

叶片由 60 伺服电机驱动,相机以 120 fps 帧率采集不同转速下的运动视频。本试验选取 180 与 600 rpm 两种工况开展叶片位移跟踪试验,其中 180 rpm 工况用于评估在小旋转角度下方法的测试精度与稳定性;600 rpm 工况用于检验方法在大角度旋转下的测试能力。

为定量评价高速旋转下的成像清晰度,采用基于边缘能量的 KBlur 模糊指标^[30](取值范围为 0~1,数值越大图像越清晰)进行评估。结果显示:180 rpm 工况下,左、右相机 KBlur 系数分别为 0.965 和 0.963;600 rpm 工况下分别为 0.947 和 0.945,表明成像系统能够获取清晰的散斑图像,为后续高精度三维位移测量提供了可靠的图像基础。

在 180 rpm 工况下,采用 Correlated Solutions 公司的 VIC-3D 软件与所提 GPR-SSL-DIC 方法对叶片全场三维位移进行跟踪对比。VIC-3D 子集大小设置为 31 pixels。

在叶片表面选取 3 个代表性关注点(points of interest, POI)A、B、C,其位置如图 14(a)所示。各点在 X、Y、Z 这 3 个方向的位移时域曲线分别如图 15(a)~(c)所示,整体呈现出刚体旋转运动特征。

对两种方法获得的三维运动轨迹进行圆拟合后得到的旋转半径如图 16 所示。与实际物理测量值相比,GPR-SSL-DIC 方法和 VIC-3D 的平均相对误差分别为 1.32% 和 1.42%。各时刻 A、C 两点间距离计算结果如图 17 所示。其中,VIC-3D 测量结果的标准差为 0.035 mm,而 GPR-SSL-DIC 方法为 0.016 mm,较前者降低了

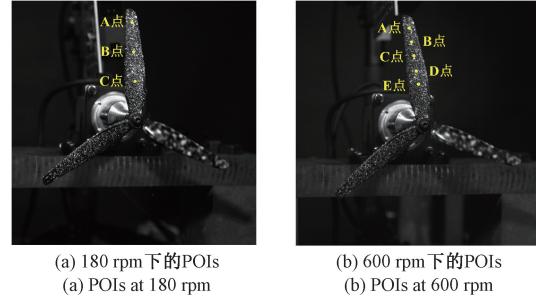
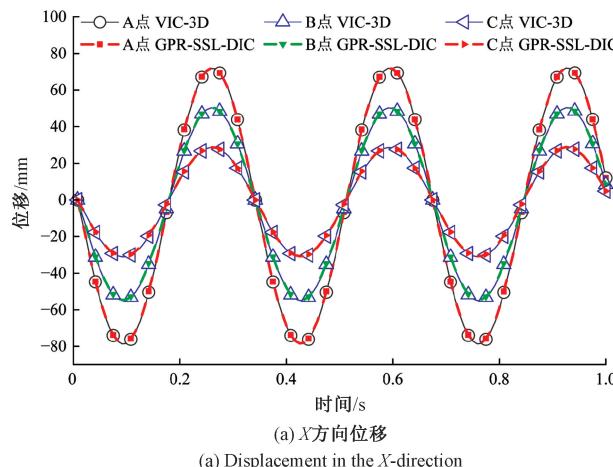
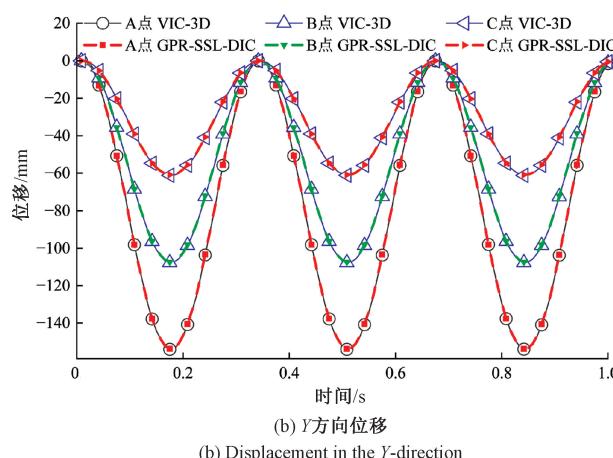


图 14 POIs 位置示意图

Fig. 14 Location of the POIs



(a) Displacement in the X-direction
(a) X 方向位移



(b) Displacement in the Y-direction
(b) Y 方向位移

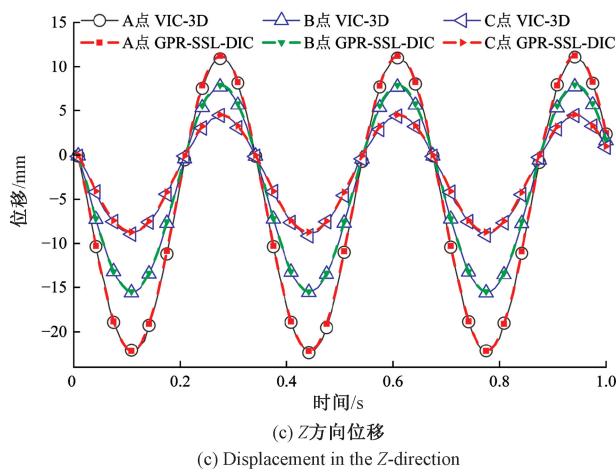


图 15 180 rpm 下 POIs 三维运动曲线

Fig. 15 Three-dimensional motion of the POIs at 180 rpm

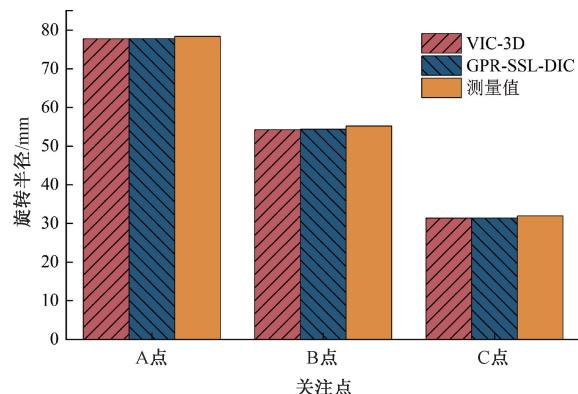


图 16 旋转半径比较

Fig. 16 Comparison of rotation radius measurements

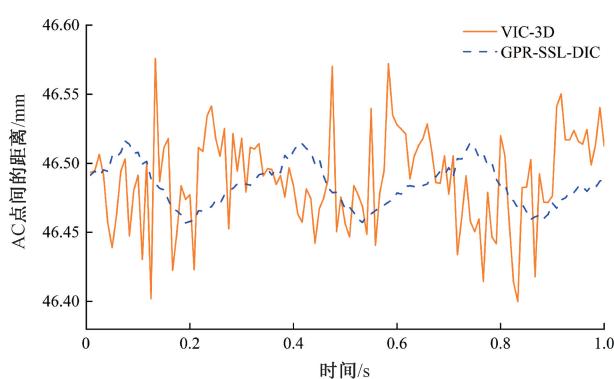


图 17 点间距测量结果对比

Fig. 17 Comparison of measured point-to-point distances

54.3%。这表明所提方法在保证更高测量精度的同时，具备更优的测量稳定性。

当转速为 600 rpm 时，相邻帧间叶片旋转角度为 30°，VIC-3D 已无法实现有效跟踪。采用本文方法对叶

片进行全场位移跟踪，选取叶片上 5 个关注点（位置如图 14(b)所示），其三维空间中运动轨迹如图 18 所示。轨迹清晰再现了各点之间的相对位置关系及整体空间排布，准确反映了叶片的旋转运动特性。

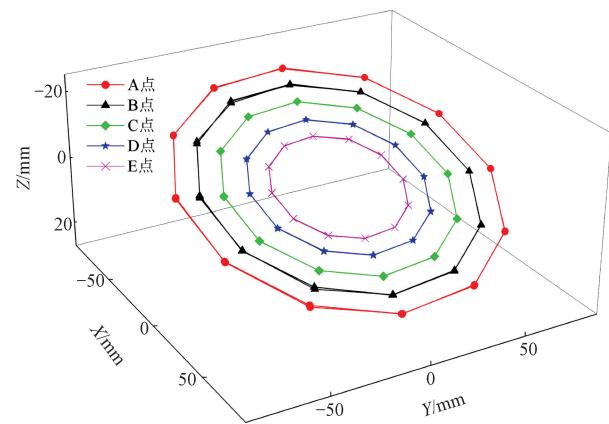


图 18 POIs 运动轨迹

Fig. 18 Trajectories of the POIs

进一步对各点的空间运动轨迹进行拟合，得到旋转半径，结果如图 19 所示。拟合半径的平均相对误差为 1.46%，表明所提方法在大角度旋转工况下仍具有较高的测量精度。随后提取了叶片在旋转相位为 90°、180°、270° 及 360° 时刻下的 Z 向位移分布，如图 20(a)~(d) 所示。结果反映了叶片结构的形态特征及其随旋转角度呈现的周期性变化规律，验证了 GPR-SSL-DIC 方法在真实大角度旋转场景下的有效性。

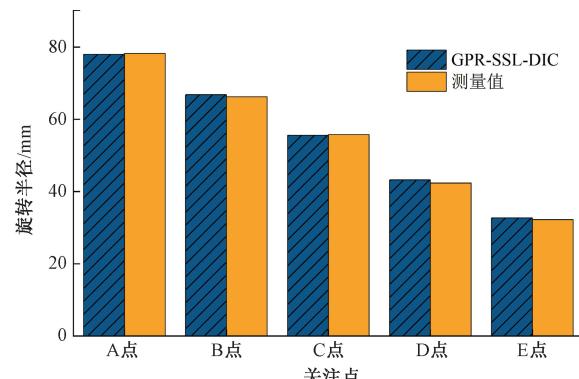
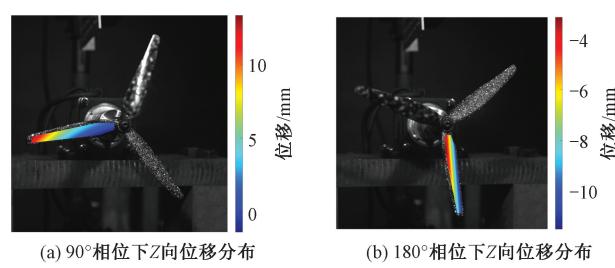


图 19 旋转半径比较

Fig. 19 Comparison of rotation radius measurements

(a) 90° 相位下 Z 向位移分布
(a) Z-direction displacement at 90°(b) 180° 相位下 Z 向位移分布
(b) Z-direction displacement at 180°

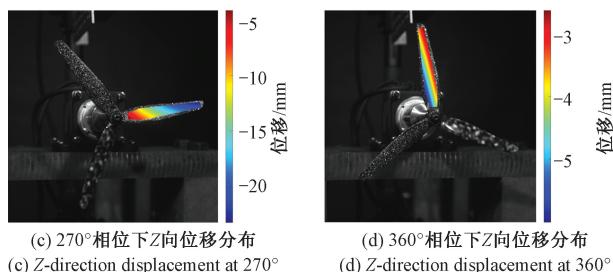


图 20 不同相位下叶片 Z 向位移分布

Fig. 20 Z-direction displacement distribution of the blade at different phases

4 结 论

本研究提出了一种基于初值引导的自监督数字图像相关方法,实现了全周旋转条件下的高精度、密集位移场测量。主要结论为:

1)通过将 KAN 网络与自监督学习框架相结合,摆脱了传统 DIC 方法子集匹配与形函数参数的束缚,实现了位移场的自适应表征;进一步引入基于旋转不变 SURF 特征与 GPR 构建的全局初值引导策略,有效解决了大旋转引起的优化“初始盲区”问题,使自监督网络在极端旋转工况下仍能快速、稳定收敛。

2)数值模拟表明,所提方法在刚体旋转、大变形及正弦变形耦合旋转的场景下,平均端点误差不超过 0.007 4 pixels,在全角度范围内稳定保持亚像素级精度,测量精度与自适应性优于传统 DIC 方法。

3)旋转叶片位移测量试验进一步验证了方法的有效性。在帧间旋转角达 30°的高速工况下,传统 DIC 方法已失效,而 GPR-SSL-DIC 仍能可靠重建叶片三维位移分布,将系统的测量上限扩展至更高转速工况。

所提方法为高速旋转结构的动态位移响应监测提供了新的技术路径。后续研究将结合位移分解策略,重点开展旋转工况下形变的提取及精度验证工作,以实现对高速旋转结构的形变表征与健康状态监测。

参考文献

- [1] HUANG J SH, ZHOU K Y, XU J L, et al. Flap-wise vibrations of non-uniform rotating cantilever beams: An investigation with operational experiments [J]. Journal of Sound and Vibration, 2023, 553: 117648.
- [2] WANG Y F, GAO Z R, FANG ZH, et al. Rotating vibration measurement using 3D digital image correlation [J]. Experimental Mechanics, 2023, 63(3): 565-579.
- [3] 潘济宇, 张水强, 苏志龙, 等. 基于数字图像相关的水下螺旋桨三维变形测量 [J]. 光学学报, 2021, 41(12): 108-116.
- PAN J Y, ZHANG SH Q, SU ZH L, et al. Measuring three-dimensional deformation of underwater propellers based on digital image correlation [J]. Acta Optica Sinica, 2021, 41(12): 108-116.
- [4] HUÑADY R, PAVELKA P, LENGVARSKY P. Vibration and modal analysis of a rotating disc using high-speed 3D digital image correlation [J]. Mechanical Systems and Signal Processing, 2019, 121: 201-214.
- [5] GUAN B L, SU ZH L, YU Q F, et al. Monitoring the blades of a wind turbine by using videogrammetry [J]. Optics and Lasers in Engineering, 2022, 152: 106901.
- [6] FENG W W, YANG D, DU W X, et al. In situ structural health monitoring of full-scale wind turbine blades in operation based on stereo digital image correlation [J]. Sustainability, 2023, 15(18): 13783.
- [7] 王永红, 陈婉琳, 侯冰菲, 等. 基于三维数字图像相关法的刚体位姿估计 [J]. 光学学报, 2024, 44(8): 114-122.
- WANG Y H, CHEN W L, HOU B F, et al. Position and pose estimation of rigid body based on three-dimensional digital image correlation [J]. Acta Optica Sinica, 2024, 44(8): 114-122.
- [8] SHAO X X, HE X Y. Real-time 3D digital image correlation for large deformation and rotation measurements based on a deformation transfer scheme [J]. Experimental Mechanics, 2021, 61: 951-967.
- [9] YANG D, SU ZH L, ZHANG SH Q, et al. Real-time matching strategy for rotary objects using digital image correlation [J]. Applied Optics, 2020, 59(22): 6648-6657.
- [10] TURNER D Z. Digital image correlation engine (DICe) reference manual [R]. Livermore: Sandia National Laboratories, 2015: SAND2015-10606O.
- [11] HUANG J SH, ZHOU K Y, CHEN W, et al. A pre-processing method for digital image correlation on rotating structures [J]. Mechanical Systems and Signal Processing, 2024, 152: 106901.

- sing, 2021, 152: 107494.
- [12] WANG L P, BI S L, LU X, et al. Deformation measurement of high-speed rotating drone blades based on digital image correlation combined with ring projection transform and orientation codes[J]. Measurement, 2019, 148: 106899.
- [13] GU J W, LIU G, YANG Q SH, et al. Improved SURF method in digital image correlation for estimation of large rotation angle[J]. Measurement, 2023, 207: 112372.
- [14] XIE P, LU Z R, LIN G, et al. A ring-projection-based two-scale approach for accurate digital image correlation of large translations and rotations [J]. Experimental Mechanics, 2024, 64(6): 875-893.
- [15] WU R, ZHAO SH L, LIU Y, et al. Strain accuracy enhancement of stereo digital image correlation for object deformation with large rotations [J]. Measurement Science and Technology, 2022, 33(5): 055003.
- [16] 萧红, 李成南, 冯明驰. 基于深度学习的散斑图像大变形测量方法[J]. 光学学报, 2023, 43(14): 123-135.
XIAO H, LI CH N, FENG M CH. Large deformation measurement method of speckle images based on deep learning[J]. Acta Optica Sinica, 2023, 43(14): 123-135.
- [17] WANG Y, ZHAO J Q. DIC-Net: Upgrade the performance of traditional DIC with Hermite dataset and convolution neural network [J]. Optics and Lasers in Engineering, 2023, 160: 107278.
- [18] CHENG X N, MA Q W, ZHOU SH CH, et al. Using unsupervised learning based convolutional neural networks to solve digital image correlation [J]. Optics and Laser Technology, 2025, 180: 111414.
- [19] LI B D, ZHOU SH CH, MA Q W, et al. Physics-informed neural network based digital image correlation method[J]. Experimental Mechanics, 2025, 65: 221-240.
- [20] 张蕾, 石岩, 卢文雍, 等. 基于 SURF-OKG 特征匹配的三维重建技术[J]. 光学精密工程, 2024, 32(6): 915-929.
ZHANG L, SHI Y, LU W Y, et al. 3D reconstruction technique based on SURF-OKG feature matching [J]. Optics and Precision Engineering, 2024, 32(6): 915-929.
- [21] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60: 91-110.
- [22] LI G, ZHANG Y M, XU Z L, et al. Marker-free full-field approach for structural 3D vibration response measurement based on Gaussian process regression and pyramidal optical flow[J]. Journal of Sound and Vibration, 2025, 610: 119133.
- [23] LIU Y CH, ZHANG X, ZHANG Z T, et al. Adaptive Taylor Kolmogorov-Arnold network for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2025, 18: 17944-17960.
- [24] 郑好, 段发阶, 白子博, 等. 一种基于重投影和 3D-DIC 的曲面变形测量方法[J]. 仪器仪表学报, 2024, 45(8): 268-285.
ZHENG H, DUAN F J, BAI Z B, et al. A surface deformation measurement method based on reprojection and 3D-DIC[J]. Chinese Journal of Scientific Instrument, 2024, 45(8): 268-285.
- [25] YANG J SH, FENG Y H, WANG L P. Efficient and robust deformation measurement based on unsupervised learning[J]. Measurement, 2025, 242: 115908.
- [26] HAO F N, ZHANG Y M, XU Z L, et al. A novel method for three-dimensional liquid surface topography measurement: combining binocular vision with deep learning-based digital image correlation[J]. Optics and Lasers in Engineering, 2025, 191: 108993.
- [27] ZHOU P, GOODSON K. Subpixel displacement and deformation gradient measurement using digital image/speckle correlation (DISC) [J]. Optical Engineering, 2001, 40(8): 1613-1620.
- [28] 苏勇, 高越, 鄢泽仁, 等. 光绘:自由开源的数字散斑图像生成和评价软件[J]. 实验力学, 2021, 36(1): 17-28.
SU Y, GAO Y, GAO Z R, et al. Glare: A free and open source software for generation and assessment of digital speckle pattern[J]. Journal of Experimental Mechanics, 2021, 36(1): 17-28.

- [29] BLABER J, ADAIR B, ANTONIOU A. Ncorr: Open-source 2D digital image correlation Matlab software [J]. *Experimental Mechanics*, 2015, 55: 1105-1122.
- [30] WU H L, SUN CH ZH, YU ZH J, et al. Three-dimensional deformation measurement of aeroengine high-speed rotating blade surface based on stroboscopic structure digital image correlation method [J]. *Structural Control and Health Monitoring*, 2022, 29(12): 3117.

作者简介



金旭, 2023 年于西南交通大学获得学士学位, 现为西安交通大学硕士研究生, 主要研究方向为基于计算机视觉的装备振动监测与评价。

E-mail: xu_jin@stu.xjtu.edu.cn

Jin Xu received his B. Sc. degree from Southwest Jiaotong University in 2023. He is currently a master student at Xi'an Jiaotong University. His main research interest is vision-based vibration monitoring and evaluation of equipment.



徐自力(通信作者), 分别于 1989 年和 1992 年获得西安交通大学学士和硕士学位, 1995 年获得哈尔滨工业大学博士学位, 现为

西安交通大学航天航空学院教授, 主要研究

方向为基于计算机视觉的装备振动监测与

评价、流固耦合高效算法及应用、动力与推进装备结构强度与振动。

E-mail: zlxu@mail.xjtu.edu.cn

Xu Zili (Corresponding author) received his B. Sc. and M. Sc. degrees both from Xi'an Jiaotong University in 1989 and 1992, respectively, his Ph. D. degree from Harbin Institute of Technology in 1995. He is currently a professor in the School of Aerospace Engineering at Xi'an Jiaotong University. His main research interests include vision-based vibration monitoring and evaluation, efficient fluid-structure interaction algorithms and applications, and structural strength and vibration of power and propulsion equipment.