

基于卷积神经网络的散斑图像位移场测量方法

黄举, 孙翠茹*, 林祥龙

天津大学机械工程学院, 天津 300350

摘要 提出了一种基于卷积神经网络(CNN)的数字散斑图像位移场测量方法。采用给定多种变形模式的精确位移场系列数字散斑图像构建数据集,提出了一种数字散斑图像位移场识别 CNN 模型。模拟散斑图像的验证实验表明,所提方法对随机变形、轴向均匀变形、剪切变形等模式具有良好的计算效率和测试精度。硅胶单轴拉伸验证实验表明,所提方法也可以精确测试真实实验散斑图像位移场并具有较高的计算效率。所提深度 CNN 能够高效、精确地测试数字散斑图像位移场,在材料变形测试中具有良好的应用前景。

关键词 测量; 数字散斑图像; 卷积神经网络; 位移场; 变形测试

中图分类号 O348.1

文献标志码 A

doi: 10.3788/AOS202141.2012002

Displacement Field Measurement of Speckle Images Using Convolutional Neural Network

Huang Ju, Sun Cuiru*, Lin Xianglong

School of Mechanical Engineering, Tianjin University, Tianjin 300350, China

Abstract A method for displacement field measurement of digital speckle images using a convolutional neural network (CNN) is proposed. A series of digital speckle images with their exact displacement fields in multiple deformation modes are used to construct a dataset and CNN model for distinguish displacement field of digital speckle images are proposed. Verification experiments of simulated speckle images show that the proposed method is computationally efficient and achieves high test accuracy for random deformations, axial uniform deformations, shear deformations, and other deformation modes. Moreover, the uniaxial tensile test of silica gel shows that the proposed method accurately measures the displacement field of real speckle images and confirms its high computational efficiency. The proposed deep CNN can be used to efficiently and accurately test the displacement field of digital speckle images, thereby indicating good application prospects for material deformation testing.

Key words measurement; digital speckle image; convolutional neural network; displacement field; deformation test

OCIS codes 120.6150; 120.6650; 100.4996; 100.2000

1 引言

数字图像相关(DIC)作为一种非接触式的变形测量方法,已被广泛应用于物体表面变形测量^[1-3]。该方法一般通过整像素位移搜索和亚像素位移计算 2 个步骤来获得试件表面的位移场,其中亚像素位移计算方法和测试精度密切相关。常用的亚像素位

移计算方法有亚像素灰度插值法^[4]、曲面拟合法^[5]、坐标轮换法^[6]、牛顿-拉普森(N-R)算法^[7]、非迭代灰度梯度算法(NIG-GA)^[8]、灰度梯度迭代算法(IGGA)^[9]、神经网络算法^[10-11]等。潘兵等^[12-13]对各种亚像素位移计算方法的性能进行了对比,结果表明在图像子区大小相同的情况下,基于空域相关函数迭代的 N-R 算法和 IGGA 的结果最为精确稳

收稿日期: 2021-02-05; 修回日期: 2021-04-16; 录用日期: 2021-04-29

基金项目: 国家自然科学基金(11972249)、天津市重点研发计划科技支撑重点(18YFZCSY00900)

通信作者: *carry_sun@tju.edu.cn

定。但这 2 种算法需要进行较为繁琐的迭代运算, 计算效率比其他方法低。除了亚像素位移计算方法, 计算步长的设置、子区大小、位移形函数和拟合方法的选择、迭代初值计算方法等因素^[14-18]也会影响计算速度和计算结果的精度。在实际的情况中, 针对不同实际变形情况, 往往凭借经验选择各参数, 无法达到最优的组合, 方法的广泛适用性受到一定限制。

人工神经网络(ANN)由一系列的神经元高度连接形成, 通过端对端的训练实现输入值到输出值的统计泛化和映射。针对图像变形测试, 刘小勇等^[11]提出了基于反向传播(BP)神经网络的非迭代灰度梯度算法, 使用预测点处的灰度和灰度梯度信息作为网络的输入, 建立了一个简单的三层神经网络。通过使用模拟散斑图像灰度值及其变形数据对 BP 神经网络进行训练, 网络具备了亚像素位移逐点预测能力, 与传统的 NIG-GA 相比, 在大变形和大位移计算方面具有更高的精度。Pitter 等^[10]使用变形前后相关点的子区行列灰度值和对应的亚像素位移值训练多层感知机网络, 使得网络具备亚像素位移计算能力。但是多节点输入输出的全连接神经网络难以学习像素点之间的空间相对位置信息, 同时随着数据维度和网络深度的增加, 网络的训练和学习变得越来越困难。基于卷积神经网络(CNN)的深度学习技术^[19]由于强大的图像处理和分析能力, 近年来被广泛用于各种图像的识别和分类等任务中。Luo 等^[20]使用深度神经网络(DNN)识别交通标志。Park 等^[21]提出了基于 DNN 的材料表面损伤检测方法。在将深度学习技术应用于数字图像变形测量方面, Min 等^[22]为了克服 DIC 方法对迭代方法、插值方法的依赖, 提出了基于 3D 卷积神经网络(3D-CNN)的深度学习模型, 使用薄膜轴向拉伸序列图像的 DIC 计算数据训练网络, 从而实现了对薄膜拉伸图像横向和轴向位移的预测, 但是使用 DIC 计算数据获取训练集的方法效率较低, 且位移计算的精度相较传统的 DIC 方法没有优势。Dosovitskiy 等^[23]提出了基于深度学习的 CNN 模型(FlowNet), 该模型实现了对图像中运动物体光流的计算。苏志龙^[24]基于 FlowNet 提出了一种基于 CNN 的数字散斑图像的位移场计算方法, 但该模型较为复杂, 可能会导致训练的时间成本增加, 实际应用时具有一定的局限性。

本文为了克服传统 DIC 方法对优化方法和插值方法等因素的依赖、现有基于 CNN 图像位移场

测量的训练成本较大、模型效率不高的缺点, 基于模拟散斑原理构建数据集, 提出了一种基于 CNN 的非迭代数字散斑图像位移场计算方法。采用给定精确位移的模拟散斑图像验证了所提方法的可靠性, 最终将所提方法应用于硅胶仿体材料的轴向拉伸测试, 验证了所提方法的有效性。所提方法为数字散斑图像的位移场计算提供了一种新的有效手段。

2 基于 CNN 的位移场计算方法

2.1 神经网络方法的基本原理

神经网络是由多个高度连接的神经元组成的。使用监督学习的方法训练神经网络, 监督学习算法通过观察一个随机特征向量 $\mathbf{x} \in \mathbb{R}^n$ 的若干样本和与之关联的标识向量 \mathbf{y} , 学习关于该特征的条件概率分布 $p(\mathbf{y} | \mathbf{x})$ 。当神经网络的隐藏层数大于 1 时, 可以称为 DNN, 图 1 为包含一个隐藏层的全连接神经网络模型。模型包含三层: 输入层、隐层、输出层。 n, q, m 分别代表输入层、隐层、输出层的节点数。输入层第 i 个数据输入为 x_i , 隐层第 k 个神经元输出为 z_k , 输出层第 j 个神经元的输出为 y_j 。输出层和隐层的连接权重为 $\mathbf{v} \in \mathbb{R}^{n \times q}$, 隐层和输出层之间的连接权重为 $\mathbf{w} \in \mathbb{R}^{q \times m}$ 。 f_1 和 f_2 分别为隐层和输出层的激活函数。则隐层节点的输出^[25]为

$$z_k = f_1\left(\sum_{i=1}^n v_{ki} x_i + a_k\right) \quad (k=1, 2, \dots, q), \quad (1)$$

式中: v_{ki} 为第 i 个输入到隐层的连接权值; a_k 为隐层第 k 个神经元的偏置值。输出层节点的输出^[25]为




图 1 含一个隐藏层的全连接神经网络模型

Fig. 1 Fully-connected neural network model with a hidden layer

$$y_j = f_2 \left(\sum w^T z + b \right) = f_2 \left(\sum_{j=1}^m w_{jk} z_k + b_j \right) \quad (j = 1, 2, \dots, m), \quad (2)$$

式中: w_{jk} 为隐层第 k 个神经元到输出层第 j 个神经元的连接权值; b_j 为输出层第 j 个神经元的偏置值。

$$\begin{cases} I_1(x, y) = \sum_{g=1}^s I_0 \exp \left[-\frac{(x-x_g)^2 + (y-y_g)^2}{\sigma^2} \right] \\ I_2(x, y) = \sum_{g=1}^s I_0 \exp \left[-\frac{(x-x_g-u_0-u_x x-u_y y)^2 + (y-y_g-v_0-v_x x-v_y y)^2}{\sigma^2} \right] \end{cases}, \quad (3)$$

式中: $I_1(x, y)$ 表示变形前模拟散斑图像在坐标 (x, y) 像素点处的光强; $I_2(x, y)$ 表示变形后的模拟散斑图像在坐标 (x, y) 像素点处的光强; s 表示随机分布的高斯光斑的数目; σ 表示高斯光斑的大小; (x_g, y_g) 表示二维随机变量; I_0 表示高斯光斑

网络的结构反映输入输出值的映射关系。网络的学习过程实质就是网络中神经元的连接权重向量 v, w 和神经元的偏置 b 的修正过程, 包括网络的前向计算和误差反向传播。

2.2 数据集的构建

采用模拟散斑图像作为训练集。

的中心光强; u_0, v_0 表示位移分量; u_x, v_x, u_y, v_y 表示应变分量。依据(3)式, 生成的模拟散斑图像能够精确给定变形场和控制图像噪声^[26]。训练集的模拟散斑图像变形模式包含轴向均匀变形、剪切变形、拉剪组合变形, 如图 2 所示。




图 2 模拟散斑图像的变形模式。(a)轴向均匀变形;(b)剪切变形;(c)拉剪组合变形

Fig. 2 Deformation modes of simulated speckle image. (a) Uniaxial tensile deformation; (b) shear deformation; (c) combined deformation of tension and shear

同时考虑到网络对这些特定变形模式数据集的学习会使得网络更倾向于学习到固定变形模式的特征, 而失去对其他变形模式位移场的计算能力。因此在训练集中加入了随机位移模式的数据。考虑施加的随机位移应满足变形真实规律, 使得变形不发生相互嵌入的情况。考虑一维上的变形点 x_n 和 x_{n+1} 分别为一维序列上变形前相邻的点, x'_n 和 x'_{n+1} 为变形后对应的点, 如图 3 所示。 $u(x_n)$ 和 $u(x_{n+1})$ 分别为紧邻两点产生的位移, 图 3 中箭头长度表示位移的大小, 相互嵌入后的像素点的相对位置发生改变。

避免变形发生相互嵌入, 显然有

$$\frac{u(x_n) - u(x_{n+1})}{x_n - x_{n+1}} < 1, \quad (4)$$

图 3 一维相互嵌入的变形

Fig. 3 Deformation of one dimension embedding each other

成立。当序列上的每个点都满足(4)式时, 图像中的像素点的移动避免了相互嵌入。因此产生随机数据集的方法为

$$u(x_{n+1}) = \text{rand}[u_{\max}, u(x_n) - 1], \quad u(x_n) \in (u_{\max}, u_{\min}), \quad (5)$$

式中: $\text{rand}(\cdot)$ 为随机数生成函数; u_{\max} 和 u_{\min} 是位移的最大值和最小值, 分别为 2 和 -2 个 pixel。同时由于随机采样过程产生的位移场数据点之间的平滑性差, 而真实实验中的位移场在没有裂纹或损伤的情况下, 试样表面位移场往往较为光滑, 因此采用 5×5 大小的模板对给定的随机位移数据进行一次中值滤波和一次均值滤波来增加平滑度。令 $u(x_n) = u_0 + u_x \cdot x + u_y \cdot y$, $u(y_n) = v_0 + v_x \cdot x + v_y \cdot y$, 即可获得对应的模拟散斑图像。模拟散斑图像的大小为 $64 \text{ pixel} \times 64 \text{ pixel}$, 图 4 为按照上述方法构建的变形前后的数字散斑图像以及给定的 u 场和 v 场。




图 4 根据随机变形场 u 场和 v 场生成的变形前和变形后的模拟散斑图像。(a)变形前的模拟散斑图像；(b)给定 v 场云图；(c)施加位移后的模拟散斑图像；(d)给定 u 场云图

Fig. 4 Based on the random deformation field u and v , the simulated speckle images before and after deformation are obtained. (a) Simulated speckle image before deformation; (b) cloud diagram of given field v ; (c) simulated speckle image after displacement; (d) cloud diagram of given field u

模拟散斑方法生成的训练集有 4 组不同变形模式的样本, 4 种变形模式各自包含的样本量如表 1 所示。

表 1 训练集组成

Table 1 Composition of training set

Deformation mode	Number of data
Random displacement	4000
Axial uniform deformation	3721
Shear deformation	3721
Combined deformation of tension and shear	2592
Total	14034

2.3 模拟数字散斑图像位移场识别模型

现有的网络模型为了实现对相关特征进行提取的目的, 使用的方法为 DIC 方法中的逐点相关函数模板计算方法。对于多通道的特征图 f_1 和 f_2 , 特征图的宽、高、通道数分别为 w, h, c 。对于模板大小为 $2k+1$ 的区域, x_1, x_2 分别为参考特征图像和目标特征图像待计算点的坐标, $f(\cdot)$ 为某种相关运算。

$$\text{cor}(f_1, f_2) = f[f_1(x_1 + o), f_2(x_2 + o)],$$

$$o \in [-k, k] \times [-k, k], \quad (6)$$

式中: $\text{cor}(\cdot)$ 为图像的相关运算; o 为临近像素点的坐标值。使用该方法, 参考特征图的每一个像素点都需要和目标特征图中一定范围内的像素点进行相关函数运算, 如果选择相关函数的计算窗口大小为 m_1 , 则一次相关需要 $m_1^2 \times w \times h$ 次相关函数运算。可以看到这种类似于 DIC 方法的相关计算方法的复杂度比较高, 因而模型的计算训练时间成本比较大。对于具有较多通道数特征图像、较大的参数和容量的深度卷积神经网络模型, 训练会变得很困难。故提出了一种更加简单的图像相关特征计算方法, 表达式为

$$\text{cor}(f_1, f_2) = f_1 - f_2, \quad (7)$$

即直接通过参考特征图像和目标特征图像相减的方法来产生图像相关特征。与前面所述的相关特征产生方法相比, 该方法的计算复杂度大大降低。

位移场识别 CNN 模型如图 5 所示, 该模型由 6 个部分组成: 输入层、相关层、下采样层、上采样层、全卷积层、输出层。模型的输入层为两张经过边界 0 灰度值填充后的模拟数字散斑图像, 即变形前的图像 A 和变形后的图像 B, 大小均为 $70 \text{ pixel} \times 70 \text{ pixel}$, A 到 B 位移场的精确给定如图 5 所示。首先分别对两张图像进行一次卷积, 由卷积生成的特征图上的数字显示特征图的尺寸, 分别表示特征图的通道数、竖向分辨率和横向分辨率, 卷积核的大小为 3×3 , 并将通道数扩展至 64 个。图 A 和图 B 经过一次卷积, 各自生成的特征图的尺寸均为 $64 \text{ pixel} \times 68 \text{ pixel} \times 68 \text{ pixel}$ 。在相关层 2 中, 为了实现对图像进行类似 DIC 中的相关运算, 同时避免增加计算的复杂度, 使用经过一次卷积后的两特征图相减的方法进行相关运算, 使用 5×5 大小的卷积核对经过相减的特征图像进行一次卷积, 特征图的尺寸由 $64 \text{ pixel} \times 68 \text{ pixel} \times 68 \text{ pixel}$ 变为 $128 \text{ pixel} \times 64 \text{ pixel} \times 64 \text{ pixel}$ 。较大的卷积核能够实现对更大像素范围的特征进行抽取和学习、对像素点发生较大位移时的特征进行识别。对特征图进行卷积和池化的过程称为下采样, 包含一系列最大值池化和卷积操作。通过最大值池化(模板大小为 2×2 , 特征图像的尺寸变为原来的一半)和卷积对位移场特征信息进行编码, 逐步提取到高维特征的同时降低网络的复杂度。下采样过程使得特征图的通道数增加, 分辨率降低。经过下采样层 3, 特征图的尺寸由 $128 \text{ pixel} \times 64 \text{ pixel} \times 64 \text{ pixel}$ 变为 $1024 \text{ pixel} \times 3 \text{ pixel} \times 3 \text{ pixel}$ 。上卷积能够逐步恢复图像的分辨率, 但是只保留了图像的高维信息, 因此采用通道拼接结合上卷积的方法恢复图像的低维

信息,还原图像的细节特征。每一次上卷积图像的分辨率变为原来的 2 倍,如图 5 所示,经过两次上卷积,特征图的尺寸由 $1024 \text{ pixel} \times 3 \text{ pixel} \times 3 \text{ pixel}$ 变为 $512 \text{ pixel} \times 12 \text{ pixel} \times 12 \text{ pixel}$ 。由于此时被拼接的图像维度并不匹配,因此对来自下采样过程中的特征图边界进行 0 灰度值填充,如图 4 所示,图 5 中间正方形虚线灰色区域为特征图像,边缘为填充的 0 元素。对填充特征图进行拼接的方法与剪裁拼接的方法相比,保留了来自下采样过程中特征图的全部灰

度信息。拼接的特征图主要由下采样层的最大池化特征图和相关层的特征图组成。最大池化提取相应位置的最值信息,有利于网络对与位移相关的灰度最值特征进行学习。经过 5 次上采样运算后,进入全卷积层 5,为了使最终的位移预测结果更加平滑,上采样的输出特征图与全卷积层之间也使用了大小为 5×5 的卷积核进行卷积,全卷积层使用了两次卷积,最终输出层 6 输出的图像的尺寸为 $2 \text{ pixel} \times 64 \text{ pixel} \times 64 \text{ pixel}$,即位移场分量 u 场和 v 场。

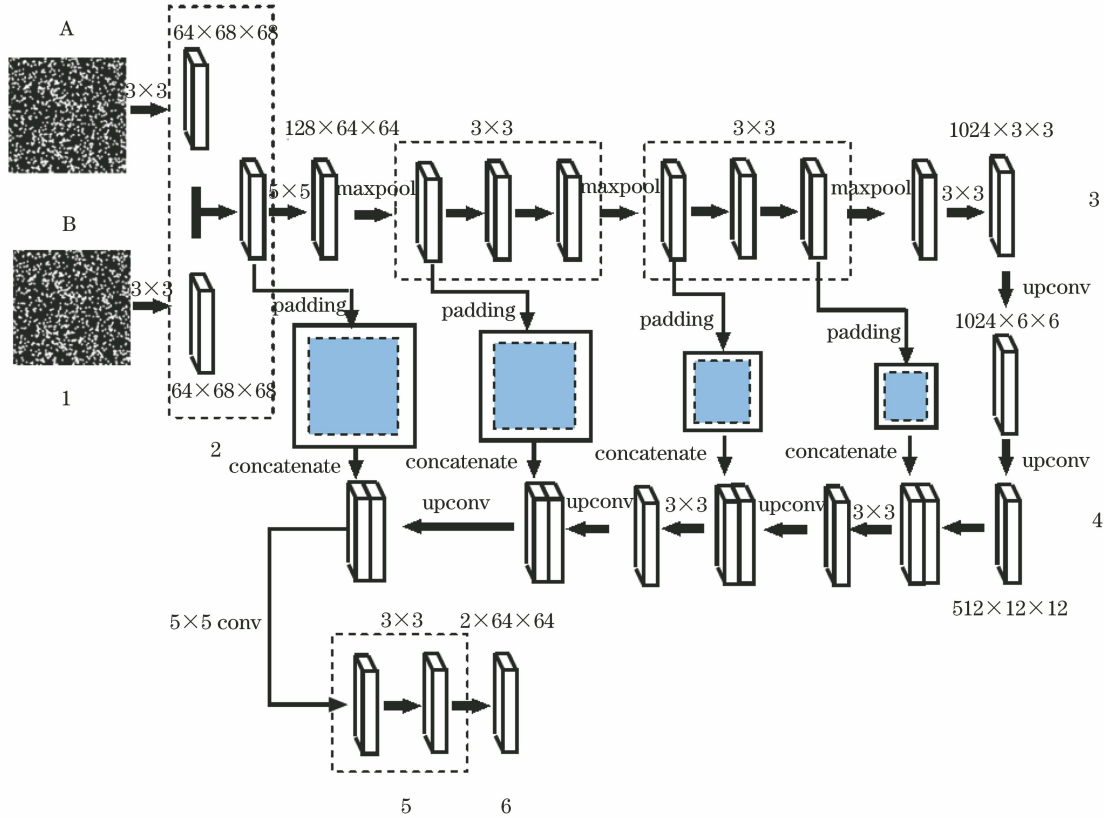


图 5 数字散斑图像位移场识别 CNN 模型

Fig. 5 CNN model for displacement field recognition of digital speckle image

深度网络模型的训练过程为按批次的前向计算和误差反向传播更新网络参数的过程。需要定义误差函数,计算网络输出的位移场和给定位移场之间的误差。使用均方误差函数作为网络的损失函数:

$$L_{\text{loss}} = \sum_{v=1}^p \sum_{j=1}^{m_2} \frac{1}{m_2} (t_j^v - y_j^v)^2, \quad (8)$$

式中: p 为一个训练批次样本的个数; m_2 为网络输出像素点的个数; t_j^v 为给定的第 v 个样本的第 j 个输出值; y_j^v 为第 v 个样本的第 j 个网络输出值。基于深度学习框架 Pytorch 编写图 5 模型的代码,通过网络的按批次前向和误差反向传播,使用随机梯度下降方法对网络进行训练。采用 GPU(GeForce GTX 1050 Ti,NVIDIA)训练模型。根据经验选择多

个参数值观察网络训练误差趋势,确定最佳的参数。模型训练的参数设置:学习率为 1×10^{-4} ;数据批次大小为 2;训练次数为 50。激活函数选择双曲正切函数,模型训练的时间约为 10 h,大约经过 350400 轮训练后,损失值下降至 0.002 时停止训练模型。

3 可靠性验证

3.1 数值模拟实验对比验证

为了验证所提 CNN 方法的有效性和鲁棒性,采用模拟散斑方法构建测试数据集,测试集有 448 对模拟散斑变形前后图像和给定的位移场数据,包含 4 种变形模式。采用均方误差和相对误差来评价网络的学习效果。由于网络的参数已经被训练好,

因此计算过程只是数据在模型中的前向计算。表 2 是网络计算的结果。结果表明:网络不仅在训练数据集上的均方误差较小,在测试数据集上也能保持

较低的均方误差,在 4 种变形模式下,计算得到位移场的相对误差都低于 10%,表明网络的学习效果较好,泛化能力较强。

表 2 CNN 在测试数据集上的表现

Table 2 Performance of CNN on test dataset

Deformation mode	Displacement v		Displacement u	
	Mean square error /pixel	Relative error /%	Mean square error /pixel	Relative error /%
Random	$0.017 \pm 6.7 \times 10^{-6}$	-2.8 ± 0.17	$0.021 \pm 8.6 \times 10^{-6}$	-2.5 ± 0.1
Axial uniform	$0.011 \pm 1.4 \times 10^{-4}$	1.8 ± 2.5	$0.013 \pm 1.7 \times 10^{-4}$	3.4 ± 2.5
Shear	$0.009 \pm 2.0 \times 10^{-4}$	2.5 ± 4.5	$0.011 \pm 2.7 \times 10^{-4}$	4.1 ± 4.6
Composite	$0.008 \pm 2.7 \times 10^{-4}$	2.5 ± 4.5	$0.011 \pm 2.7 \times 10^{-4}$	4.1 ± 4.6

图 6 为网络计算的位移场分量和给定的位移场分量对比图。图 6(a)~(d) 为给定位移场,图 6(e)~(h) 为网络测试位移场。其中图 6(e) 和图 6(f) 分别为随机位移场分量 v 场和 u 场,均方误差分别为 0.013 和 0.016,逐点相对误差为 $-2.3\% \pm 1.4\%$ 和 $3.6\% \pm 2.2\%$ 。图 6(g) 和图 6(h) 分别为

轴向均匀变形的位移场分量 v 场和 u 场,均方误差分别为 0.003 和 0.005,逐点相对误差为 $5.3\% \pm 3.7\%$ 和 $2.8\% \pm 5.4\%$ 。从图 6 可以看出,无论是随机变形还是轴向均匀变形,网络都实现了位移场的准确识别,网络计算的位移场分布和给定的位移场分布十分接近。




图 6 CNN 方法模拟散斑图像位移场测试结果。(a)~(d) 给定的位移场;(e)~(h) 网络计算的位移场

Fig. 6 Simulated speckle image displacement field test results by CNN method. (a)~(d) Given displacement field; (e)~(h) measured displacement field by CNN

目前 N-R 算法计算的精度较高,但是由于涉及复杂的矩阵迭代运算,计算效率较低。在一些特定的情况下,NIG-GA 具有与 N-R 算法相当的测试精度却有着更高的计算效率,因而应用越来越广泛^[2,12],因此对所提方法与 NIG-GA 进行比较。从测试集中随机选取 4 幅包含 4 种变形模式的图像作为测试对象,对比 CNN 方法和 NIG-GA 方法。表 3 为 2 种方法计算模拟散斑位移场的相对误差。从表 3 可知,除了随机变形场的 v 场的相对误差,其他位移场的计算精度 CNN 方法均优于 NIG-GA 方法。造成这种现象的原因可能是模型的训练样本数量不足,导致网络没有充分地学习到随机变形场的分布;也有可能是由于该模式位移场数据不够平滑,导

致网络对于该位移特征的学习较为困难。相较于其他三种位移模式,随机位移分布更加复杂,网络需要学习的参数也越多,也就是网络的模型容量可能存在不足。对于 64×64 个像素点,CNN 方法一次位移场计算的时间约为 0.08 s[GPU 为 Intel(R) Core(TM) i7-8700,基于 Python],而 NIG-GA 方法所用的时间约为 156 s[GPU 为 Intel(R) Core(TM) i7-8700,逐点计算,步长为 1,相关模板的大小设置为 $19 \text{ pixel} \times 19 \text{ pixel}$,相关函数为零均值归一化互相关函数,整像素搜索的窗口大小为 $9 \text{ pixel} \times 9 \text{ pixel}$,基于 Matlab]。由计算结果可知,CNN 方法同时具有较高的模拟散斑位移场测试精度和计算效率。

表 3 CNN 方法和 NIG-GA 方法位移场计算的相对误差

Table 3 Relative error of displacement field calculated by CNN method and NIG-GA method

Deformation mode	CNN method		NIG-GA method	
	Displacement v	Displacement u	Displacement v	Displacement u
Random	0.05 ± 0.01	0.009 ± 0.03	0.02 ± 4.29	-2.03 ± 4.03
Axial uniform	0.07 ± 0.01	0.02 ± 0.08	0.08 ± 1.51	1.61 ± 5.12
Shear	-0.04 ± 0.04	0.03 ± 0.04	0.12 ± 16.58	0.42 ± 15.96
Composite	-0.01 ± 0.02	-0.06 ± 0.03	0.07 ± 1.54	0.90 ± 1.68
Total computing time /s	0.35		627.21	
Average time for once /s	0.08		156	

图 7 为两种方法计算的随机位移场和轴向均匀变形(变形梯度 $u_x = -0.01, v_y = 0.02$)位移场图像。从两种方法计算得到的位移场云图来看:对于随机位移场, CNN 方法计算的结果明显优于 NIG-GA 方法, CNN 较为准确地计算出位移场,同时也

可以看出 CNN 预测的位移场的平滑程度和分布趋势更加接近给定位移场;对于随机位移场的计算, NIG-GA 方法的计算结果较差,是固定形式的变形假设和位移形函数导致的。




图 7 CNN 方法和 NIG-GA 方法的位移场计算结果。(a)~(d)给定的位移场;

(e)~(h) CNN 方法的测试结果; (i)~(l) NIG-GA 方法的测试结果

Fig. 7 Displacement field calculated results by CNN method and NIG-GA method. (a)~(d) Given displacement field; (e)~(h) measured results by CNN method; (i)~(l) measured results by NIG-GA method

3.2 实验验证

为了验证所建立的 CNN 模型对真实的散斑图像进行位移场计算识别的有效性,使用了表面喷斑的硅胶片材(长 30.3 mm,宽 7.38 mm,高 2 mm)进行原位单轴拉伸实验,实验过程中采用 CCD 相机拍摄,选取变形前后两帧图像作为计算的参考图像和目标图像,参考图像对应的伸长量 $L = 0.35$ mm,拉力 $F = 0.23$ N,目标图像的伸长量 $L = 0.40$ mm,拉力 $F = 0.24$ N。目标图像比参考图像伸长了 0.05 mm,如图 8 所示。

在参考图像中选取长为 15.36 mm,宽为 5.12 mm 的感兴趣区域,共 128 pixel \times 512 pixel,

如图 8 所示。网络每次计算的区域大小为 64 pixel \times 64 pixel,共有 2×8 个计算区域,分别使用 CNN 测试,计算总用时为 1.32 s。计算所得的 u 场结果如图 9 所示,可以看到,镜头中心点左半部分的 u 为负值,右半部分 u 为正值,越远离中心区域,位移值越大,与原位单轴拉伸规律一致。左端计算区域中位移的均值为 -0.0216 mm,右端计算区域中位移的均值为 0.0226 mm,即总的伸长量约为 0.0442 mm,接近于实验机给定的两端卡头位移 0.05 mm,充分证明了所提 CNN 方法的可靠性,略小于给定卡头位移是所选感兴趣区域的两端距离卡头还有一定距离导致的。




图 8 硅胶材料的单轴拉伸图像。(a) $L=0.35$ mm, $F=0.23$ N 的图像; (b) $L=0.4$ mm, $F=0.24$ N 的图像; (c) 选取的位移场计算区域

Fig. 8 Uniaxial tensile image of silica gel. (a) Image when $L=0.35$ mm, $F=0.23$ N; (b) image when $L=0.4$ mm, $F=0.24$ N; (c) selected calculation area of displacement field




图 9 实验图像的 CNN 方法 u 场计算结果

Fig. 9 Displacement field u for experiment image calculated by CNN method

4 结 论

提出了一种基于卷积神经网络的数字散斑图像位移场计算方法,构建了数字散斑图像位移场识别的深度卷积神经网络,通过在网络中引入独特的相关层,简化了网络结构,降低了网络的计算和训练成本。使用模拟数字散斑图像构建包含各种变形模式的数据集,成功地训练并测试了该网络,结果表明,该网络模型具备了对数字模拟散斑图像位移场进行计算识别的能力。同时与数字图像相关非迭代灰度梯度方法相比,所提深度网络方法在模拟散斑的位移计算上不仅具有更小的相对误差,同时计算效率也有所提高。硅胶单轴拉伸验证实验表明,所提方法也可以精确测试真实实验散斑图像位移场并具有

较高计算效率,为基于卷积神经网络的数字散斑图像的位移测量提供了一种新的方法和思路。研究结果表明,所提方法相较于传统方法在材料的变形测试方面具有一定的优势和较广阔的发展前景。

参 考 文 献

- [1] Pan B, Qian K M, Xie H M, et al. Two-dimensional digital image correlation for in-plane displacement and strain measurement: a review [J]. Measurement Science and Technology, 2009, 20(6): 062001.
- [2] Wang M, Cen Y W, Hu X F, et al. A weighting window applied to the digital image correlation method[J]. Optics & Laser Technology, 2009, 41(2): 154-158.
- [3] Zhang X C, Wang Y, Guo N, et al. Effect of ferrite/pearlite banded structure on the local deformation and crack initiation at notches in pipeline steel [J]. Engineering Fracture Mechanics, 2020, 237: 107244.
- [4] Yu Q F. Image based precision measurement and motion measurement [M]. Beijing: Science Press, 2002: 1-10.
于起峰. 基于图像的精密测量与运动测量[M]. 北京: 科学出版社, 2002: 1-10.
- [5] Wang C Y, He X Y. Curved surface approximation in correlation recognition method [J]. Journal of Experimental Mechanics, 2000, 15(3): 280-285.
王琛影, 何小元. 相关识别中的曲面拟合法[J]. 实验力学, 2000, 15(3): 280-285.
- [6] Rui J B, Jin G C, Xu B Y. A new digital speckle correlation method and its application [J]. Acta Mechanica Sinica, 1994(5): 599-607.
芮嘉白, 金观昌, 徐秉业. 一种新的数字散斑相关方法及其应用[J]. 力学学报, 1994(5): 599-607.
- [7] Bruck H A, McNeill S R, Sutton M A, et al. Digital image correlation using Newton-Raphson method of partial differential correction [J]. Experimental Mechanics, 1989, 29(3): 261-267.
- [8] Davis C Q, Freeman D M. Statistics of subpixel registration algorithms based on spatiotemporal gradients or block matching[J]. Optical Engineering, 1998, 37: 1290-1298.
- [9] Meng L B, Jin G C, Yao X F. Application of iteration and finite element smoothing technique for displacement and strain measurement of digital speckle correlation [J]. Optics and Lasers in Engineering, 2007, 45(1): 57-63.
- [10] Pitter M C, See C W, Somekh M G. Subpixel microscopic deformation analysis using correlation and artificial neural networks [J]. Optics Express,

- 2001, 8(6): 322-327.
- [11] Liu X Y, Gong Y, Li R L, et al. Non-iterative gray-gradient algorithm based on BP artificial neural network in digital image correlation [J]. *Machine Tool & Hydraulics*, 2018, 46(1): 7-11.
刘小勇, 宫岩, 李荣丽, 等. 基于 BP 神经网络的数字图像相关非迭代灰度梯度算法 [J]. *机床与液压*, 2018, 46(1): 7-11.
- [12] Pan B, Xie H M, Xu B Q, et al. Development of sub-pixel displacements registration algorithms in digital image correlation [J]. *Advances in Mechanics*, 2005, 35(3): 345-352.
潘兵, 谢惠民, 续伯钦, 等. 数字图像相关中的亚像素位移定位算法进展 [J]. *力学进展*, 2005, 35(3): 345-352.
- [13] Pan B, Xie H M, Xu B Q, et al. Performance of sub-pixel registration algorithms in digital image correlation [J]. *Measurement Science and Technology*, 2006, 17(6): 1615-1621.
- [14] Wang X B, Dong W, Yang M, et al. Inhomogeneous strain measurement based on least absolute deviation fitting for digital image correlation [J]. *Acta Optica Sinica*, 2020, 40(3): 0312001.
王学滨, 董伟, 杨梅, 等. 基于最小一乘拟合的非均匀应变的数字图像相关测量 [J]. *光学学报*, 2020, 40(3): 0312001.
- [15] Liu Y, Xiao S D, Zhang R, et al. Initial estimation of digital image correlated deformation based on genetic algorithms [J]. *Laser Technology*, 2020, 44(1): 130-135.
刘禹, 肖世德, 张睿, 等. 基于遗传算法的数字图像相关变形初值估计 [J]. *激光技术*, 2020, 44(1): 130-135.
- [16] Zhang X C, Chen J L, Wang Z T, et al. Digital image correlation using ring template and quadrilateral element for large rotation measurement [J]. *Optics and Lasers in Engineering*, 2012, 50(7): 922-928.
- [17] Zhu T T, Fu Z N, Zhang M, et al. Initial value estimation of digital image correlation method in deformation measurement based on feature matching [J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 181012.
朱天天, 付中男, 张梅, 等. 基于特征匹配的数字图像相关法在变形测量中的初值估计 [J]. *激光与光电子学进展*, 2020, 57(18): 181012.
- [18] Ye P, Zhang M, Ma W L, et al. Improved climbing algorithm for digital image correlation displacement measurements [J]. *Laser & Optoelectronics Progress*, 2020, 57(2): 021506.
叶沛, 张梅, 马万龙, 等. 用于数字图像相关位移测量的一种改进爬山算法 [J]. *激光与光电子学进展*, 2020, 57(2): 021506.
- [19] 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.
- [20] Luo H L, Yang Y, Tong B, et al. Traffic sign recognition using a multi-task convolutional neural network [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(4): 1100-1111.
- [21] Park J K, Kwon B K, Park J H, et al. Machine learning-based imaging system for surface defect inspection [J]. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 2016, 3(3): 303-310.
- [22] Min H G, On H I, Kang D J, et al. Strain measurement during tensile testing using deep learning-based digital image correlation [J]. *Measurement Science and Technology*, 2020, 31(1): 015014.
- [23] Dosovitskiy A, Fischer P, Ilg E, et al. FlowNet: learning optical flow with convolutional networks [C]// 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 2758-2766.
- [24] Su Z L. Research on deformation measurement method based on feature recognition [D]. Nanjing: Southeast University, 2019: 99-121.
苏志龙. 基于特征识别的变形测量方法研究 [D]. 南京: 东南大学, 2019: 99-121.
- [25] Yue Y, Wang B. Deep learning [M]. Beijing: Publishing House of Electronics industry, 2016: 20-21.
乐毅, 王斌. 深度学习 [M]. 北京: 电子工业出版社, 2016: 20-21.
- [26] Peng Z, Goodson K E. Subpixel displacement and deformation gradient measurement using digital image/speckle correlation (DISC) [J]. *Optical Engineering*, 2001, 40(8): 1613-1620.