

# 改进 U-Net 的光条纹分割算法

闫文伟<sup>1,2,3,4</sup>, 陈帅<sup>1,2,4\*</sup>, 穆宝岩<sup>1,2,4</sup>, 高亮<sup>1,2,4</sup>

<sup>1</sup>中国科学院沈阳自动化研究所, 辽宁 沈阳 110016;

<sup>2</sup>中国科学院机器人与智能制造创新研究院, 辽宁 沈阳 110169;

<sup>3</sup>中国科学院大学, 北京 100049;

<sup>4</sup>辽宁省智能检测与装备技术重点实验室, 辽宁 沈阳 110179

**摘要** 针对传统基于线结构光的视觉测量系统存在光条纹分割精度低的问题, 提出了一种改进 U-Net 的光条纹分割算法。改进算法使用 VGG16 的卷积池化层代替 U-Net 编码块中的卷积池化层, 在 U-Net 编-解码层间的跳连接中引入坐标注意力机制, 在 U-Net 编码块末端接入金字塔池化模块, 采用 Dice 函数和交叉熵函数的组合作为网络的损失函数, 解决了光条纹占比失衡问题。基于线结构光测量原理, 设计了工件尺寸测量系统。实验结果表明: 改进 U-Net 算法的平均像素准确度 (mpa) 为 95.61%, 平均交并比 (mIoU) 为 89.73%, 均高于其他对比算法; 工件测量尺寸的绝对误差小于 0.1 mm, 相对误差小于 1%, 重复精度小于 0.2%, 满足工件的检测要求。

**关键词** 线结构光; 光条纹分割; 深度学习; 特征点提取; 非接触测量

中图分类号

文献标志码

DOI: 10.3788/LOP202259.1215010

## Fringe Segmentation Algorithm Based on Improved U-Net

Yan Wenwei<sup>1,2,3,4</sup>, Chen Shuai<sup>1,2,4\*</sup>, Mu Baoyan<sup>1,2,4</sup>, Gao Liang<sup>1,2,4</sup>

<sup>1</sup>Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, Liaoning, China;

<sup>2</sup>Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110169, Liaoning, China;

<sup>3</sup>University of Chinese Academy of Sciences, Beijing 100049, China;

<sup>4</sup>Key Laboratory on Intelligent Detection and Equipment Technology of Liaoning Province, Shenyang 110179, Liaoning, China

**Abstract** To improve the accuracy of light stripe segmentation in the traditional vision measurement system based on line-structured light, an improved light stripe segmentation algorithm based on U-Net is proposed. The proposed algorithm uses the convolution pooling layer of VGG16 instead of that in the U-Net coding block, introduces the coordinate attention mechanism in the hop connection between U-Net coding and decoding layers, and connects the pyramid pooling module at the end of U-Net coding block. Additionally, it uses a combination of Dice function and cross entropy function as the loss function of the network, so as to solve the problem of imbalance of light stripe proportion. Based on the principle of line-structured light measurement, a workpiece size measurement system is designed. Experimental results show that the mean pixel accuracy (mpa) of the improved U-Net algorithm is 95.61% and mean intersection over union (mIoU) is 89.73%, which are higher than other comparison algorithms. The absolute error of workpiece measurement size is less than 0.1 mm, the relative error is less than 1%, and the repetition accuracy is less than 0.2%, meeting the inspection requirements of the workpiece.

**Key words** line-structured light; light stripe segmentation; deep learning; feature point extraction; non-contact measurement

收稿日期: 2021-07-08; 修回日期: 2021-08-04; 录用日期: 2021-08-17

基金项目: 中国科学院战略性先导科技专项(C类)(XDC04000000)、国家自然科学基金面上项目(62073312)、辽宁省重点研发计划(2020JH2/10100023)、中国航发自主创新专项资金项目(ZZCX-2018-035)、王宽诚教育基金会、辽宁省“兴辽英才计划”项目(XLYC2002055)

通信作者: \*chenshuai@sia.cn

## 1 引言

随着现代制造业水平的不断提高,大尺寸金属工件越来越多地被作为工程应用中的重要构件,制造行业对大尺寸金属工件的尺寸测量精度也提出了越来越高的要求<sup>[1]</sup>。

机器视觉具有客观、非接触、高精度等优点,被广泛应用于工件尺寸测量领域<sup>[2-4]</sup>。线结构光测量技术是结合结构光的新兴视觉测量技术,通过在待测工件表面投射光条纹,形成表征工件尺寸信息的线结构光光条纹,使用相机采集工件表面的条纹图像,利用图像处理技术获取条纹特征点的像素坐标,基于系统成像模型进行空间尺度变换,完成工件尺寸测量。因此,对光条纹的精准分割是金属工件尺寸测量的关键因素。

随着计算机和图像处理技术的发展,很多图像处理算法被应用在目标分割上<sup>[5]</sup>。传统的图像分割算法主要基于阈值、边缘、区域、聚类进行分割<sup>[6]</sup>,本质是依赖于图像灰度值的梯度信息进行分割,当分割目标灰度梯度不明显时,易造成误分割<sup>[7]</sup>。

近年来,深度学习广泛应用于目标检测、图像分割等领域,并取得了卓越成效,研究者对基于深度学习的目标分割进行了大量研究<sup>[8]</sup>。Simonyan等<sup>[9]</sup>提出的卷积神经网络(CNN)增加了卷积层深度,提高了提取特征的能力,但主要用于图像分类。2015年,Long等<sup>[10]</sup>提出的全卷积神经网络(FCN)是一种语义分割网络,实现了像素级的预测分割,但分割时容易丢失细节信息。Oktay等<sup>[11]</sup>提出了 Attention U-Net,将 Attention Gate 机制接入 U-Net 的跳连接中,该网络对分割目标的边缘细节有较好的保持作用,但容


易忽略特征的通道信息,不能很好地提取编码阶段丰富的语义特征。Zhao等<sup>[12]</sup>提出的金字塔池化模块(PPM)采用不同尺度的核对特征图进行池化,融合上下文信息,提升分割精度。Hou等<sup>[13]</sup>提出的坐标注意力机制将位置信息嵌入到通道注意力中,增强特征提取能力。2015年,Ronneberger等<sup>[14]</sup>提出了 U-Net,该网络基于编码-解码的结构,在小数据集上也能取得较好的图像分割效果。受线结构光光源质量、光线散射、环境光影响,本文测量系统采集的图像中,光条纹受噪声影响易出现局部过亮或过暗现象,光条纹因占比小而类别不平衡,应用 U-Net 进行分割时会出现语义信息提取不全面和上下文信息联系欠缺等问题,造成光条纹分割精度低。

针对上述分割难点,本文提出了一种改进的 U-Net。将 U-Net 的编码块结构改为 VGG16 网络的特征提取结构,通过增加网络深度,整合不同深度层次的特征信息;在 U-Net 编码块与解码块对应层间的跳连接中引入坐标注意力机制,通过对不同特征赋予不同的注意力权重,实现对光条纹特征的增强和提取;在 U-Net 编码块末端接入金字塔池化模块,对图像特征进行多尺度映射,获取全局信息,提高对光条纹的分割精度。将 Dice 损失函数和交叉熵值损失函数的组合函数作为改进网络的损失函数,解决光条纹占比失衡问题。基于线结构光测量原理,设计了工件尺寸测量系统,完成了工件尺寸测量。

## 2 图像采集与分割

### 2.1 图像采集系统

用于网络训练、验证和测试的图像为实时采集的图像,图像采集系统如图 1 所示。



1. image acquisition equipment; 2. industrial control box; 3. camera mounts; 4. industrial cameras & lenses; 5. rotating platform; 6. line structure light source; 7. workpiece; 8. horizontal reinforcement; 9. vertical reinforcement; 10. inclined reinforcement

图 1 图像采集系统

Fig. 1 Image acquisition system

图像采集系统硬件配置:相机采用海康工业相机,图像分辨率为  $1280 \times 960$ ,像元尺寸为  $3.75 \mu\text{m} \times 3.75 \mu\text{m}$ ,镜头焦距为  $5 \text{ mm}$ ;待测金属工件的长和宽分别为  $570 \text{ mm}$  和  $520 \text{ mm}$ ;相机与工件的垂直工作距离为  $950 \text{ mm}$ 。线结构光光源与工件的水平工作距离为  $800 \text{ mm}$ ,垂直工作距离为  $510 \text{ mm}$ ,投射光条纹方向与水平加强筋(编号8)方向成  $90^\circ$ 。金属工件置于工业相机正下方,线结构光光源固定在旋转平台上。实验时,工控箱驱动旋转平台旋转,线结构光光源在工件表面投射光条纹,光源投射方向与金属工件平面成  $30^\circ$ (初始角度)~ $45^\circ$ (结束角度),在光源投射角度从  $30^\circ$  到  $45^\circ$  变换过程中,投射角度每改变  $1^\circ$ ,图像采集设备控制工业相机完成1次图像采集,共采集15张图像。

## 2.2 图像来源

工业相机通过 GigE 接口与图像采集设备连接,每改变一次线结构光光源的投射角度,图像采集设备控制工业相机完成一次图像采集,采集图如图2所示,原始图像尺寸为  $1280 \text{ pixel} \times 960 \text{ pixel}$ 。利用标记工具 Labelme 对图像中的线结构光光条纹和背景进行分类标记,标记图如图3所示。对系统采集




图2 采集图  
Fig. 2 Captured image




图3 标记图  
Fig. 3 Marked map

的15张原始图以及对应的标记图进行随机裁减<sup>[15]</sup>,裁剪成尺寸为  $512 \text{ pixel} \times 512 \text{ pixel}$  的图像,完成数据集扩充,得到135张图,将其中的70%作为训练集,20%作为验证集,10%作为测试集。

## 2.3 图像分割

系统采集的图像存在线结构光光条纹区域、背景区域和反光区域,要实现工件测量,需要获得表征工件尺寸信息的光条纹的细致特征。对基础 U-Net 的结构进行改进,增强网络分割性能,实现光条纹精准分割。使用训练集图像对改进 U-Net 以及对比网络进行训练,经过训练获得对应网络的预测模型,使用验证集图像对各网络模型进行验证,最后使用网络模型对测试集图像进行分割预测。图像分割流程如图4所示。

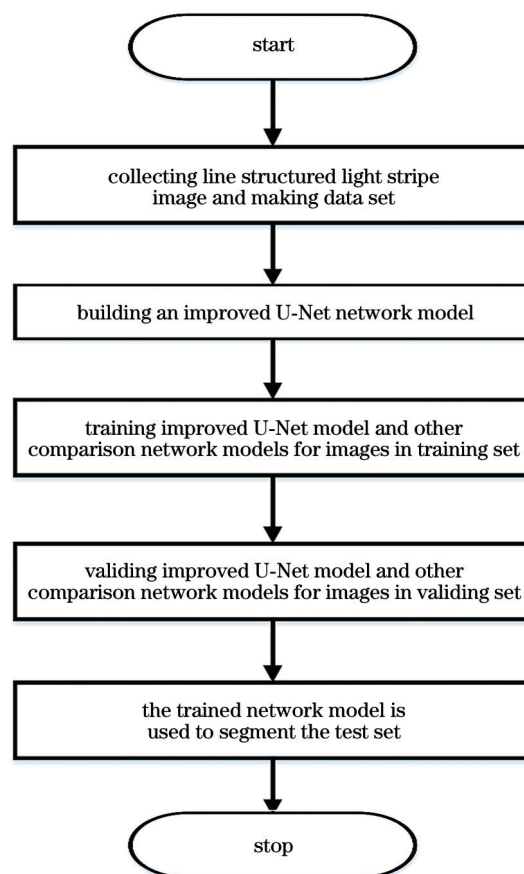


图4 图像分割流程  
Fig. 4 Flow chart of image segmentation

## 3 改进 U-Net

U-Net 是基于全卷积的语义分割网络,具有在小数据集分割任务中分割精度高的优点,主要用于对生物医学图像的分割。本文分割的对象是图

像中细长的光条纹,针对采集图像中的光条纹占比失衡、局部过亮和局部过暗的分割难点,对基础 U-Net 进行网络结构改进,提出一种改进的 U-Net 模型。

### 3.1 U-Net 模型

U-Net 由左侧的编码块和右侧的解码块组成,呈对称结构,编-解码层间是跳连接,U-Net 网络如图 5 所示。图 5 标注了每一层特征图的大小和通道数,图例表示不同含义。从图 5 可知,编码块由卷积层和池化层组成,卷积层提取图像特征并获得初步有效特征图,池化层通过降低特征图的分辨率来增

大感受野和提高全局信息获取能力<sup>[16]</sup>。编码块由 5 个模块组成,前 4 个模块每个模块由 2 个卷积层和 1 个池化层组成,第 5 个模块由 2 个卷积层和 1 个升尺度池化层组成。解码块由升尺度池化层和卷积层组成,其中升尺度池化层用来恢复特征图的分辨率。解码块由 4 个模块组成,前 3 个模块每个模块由 2 个卷积层和 1 个升尺度池化层组成,第 4 个模块由 3 个卷积层组成。编-解码层间的跳连接拼接编码块卷积层提取的特征图和解码块中升尺度池化层输出的特征图,融合底层的位置信息和高层的语义信息<sup>[17]</sup>。

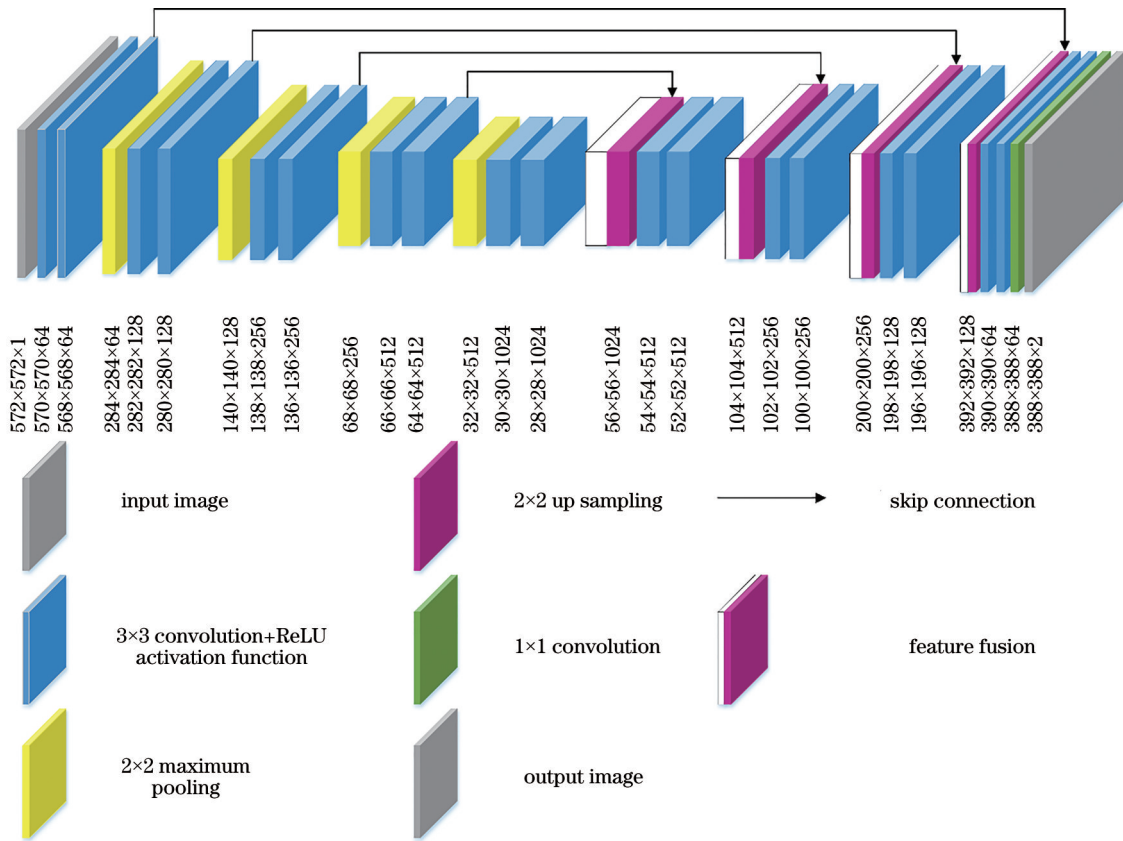


图 5 U-Net 网络

Fig. 5 U-Net network

### 3.2 坐标注意力机制

特征图中每个通道的重要性不同,相同通道上不同位置处像素的重要性也不同。在特征提取中,注意力模块可以增强有意义特征而抑制无意义特征。在 U-Net 编-解码层间的跳连接中接入坐标注意力机制,该模块将位置信息嵌入到通道注意力中,能够有效地提取光条纹特征,坐标注意力机制如图 6 所示。从图 6 可知,坐标注意力机制通过 2 个空间方向的一维特征编码实现特征聚合。坐标注

意力机制分为两部分:坐标信息嵌入和坐标注意力生成。

#### 3.2.1 坐标注意力机制中的坐标信息嵌入

通过一对一维特征编码对空间信息进行全局编码。给定输入  $X^{C \times H \times W}$ ,使用  $(H, 1)$  或  $(1, W)$  的池化核沿水平方向和垂直方向对每个通道进行编码,得到两个空间方向的特征,表达式为

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i), \quad (1)$$

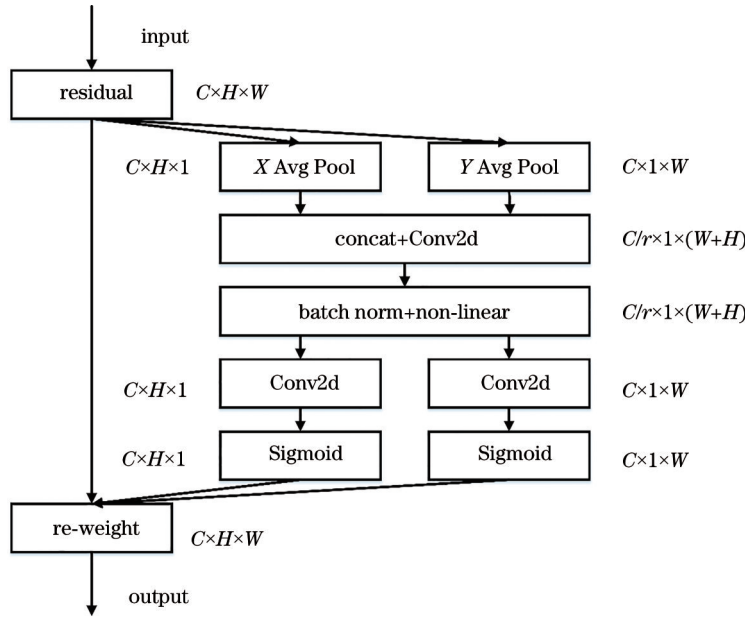


图 6 坐标注意力机制

Fig. 6 Coordinate attention mechanism

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j \leq H} x_c(j, w), \quad (2)$$

式中： $H$ 为图像的高， $W$ 为图像的宽， $C$ 为图像的通道数； $x_c$ 为输入图像； $z_c^h(h)$ 为 $c$ 通道高度 $h$ 处的输出； $z_c^w(w)$ 为 $c$ 通道宽度 $w$ 处的输出。

### 3.2.2 坐标注意力机制中的坐标注意力生成

连接上述的特征，并使用卷积变换和非线性激活获得特征映射 $f$ ，表达式为

$$f = \delta \left\{ F_1 \left( \left[ z^h, z^w \right] \right) \right\}, \quad (3)$$

式中： $[\cdot, \cdot]$ 为连接操作； $\delta$ 为非线性激活函数； $F_1$ 为 $1 \times 1$ 卷积变换； $f$ 为空间信息在水平、垂直方向编码的中间特征映射。

沿着空间方向将 $f$ 分解为2个张量，分别对这2个张量使用卷积变换和Sigmoid激活，获得与输入 $X^{C \times H \times W}$ 具有相同通道数的张量，表达式为

$$g^h = \sigma \left[ F_h(f^h) \right], \quad (4)$$

$$g^w = \sigma \left[ F_w(f^w) \right], \quad (5)$$

式中： $F_h, F_w$ 为 $1 \times 1$ 卷积变换； $f^h, f^w$ 为 $f$ 沿着空间分解的张量； $\sigma$ 为Sigmoid激活函数； $g^h, g^w$ 为与输入具有相同通道数的张量。

对 $g^h$ 和 $g^w$ 进行扩展并将其作为注意力权重，得到输出图像，表达式为

$$y_c(i, j) = x_c(i, j) \times g^h(i) \times g^w(j), \quad (6)$$

式中： $g_c^h, g_c^w$ 为注意力权重； $y_c$ 为输出图像。

### 3.3 金字塔池化模块

金字塔池化模块使用不同尺度的池化核对特征图进行池化，融合局部信息和全局信息。本文在U-Net的编码块末端接入金字塔池化模块，提取具有上下文关联的光条纹特征，金字塔池化模块如图7所示，图例表示不同含义。

从图7可知，金字塔池化模块融合了4种尺度的特征图。输入特征图被4个大小分别为 $1 \times 1, 2 \times 2, 3 \times 3, 6 \times 6$ 的池化核自适应平均池化；其次，利用 $1 \times 1$ 卷积核对各个池化后的特征图进行通道数调整；接着，采用二次线性插值进行上采样，使不同尺度的特征图与输入特征图具有相同的大小；最后将获得的4个特征图与输入特征图堆叠，对堆叠后的特征图进行卷积，完成通道数调整。

### 3.4 VGG16中的特征提取模块

VGG16网络模型包含13个卷积层、5个最大池化层、3个全连接层和1个Softmax层，VGG16网络如图8所示，图中标注出了每一层特征图的大小和通道数，图例表示不同含义。

从图8可知，VGG16网络分为两部分：特征提取网络结构，如实线框所示；分类网络结构，如虚线框所示。VGG16中特征提取模块包含13个卷积层，U-Net中特征提取模块包含10个卷积层，VGG16网络卷积层深度更大，特征提取更好；VGG16采用有填充的卷积方式，U-Net采用无填充的卷积方式，有填充的卷积方式保证了卷积层输入图与输出图的尺寸

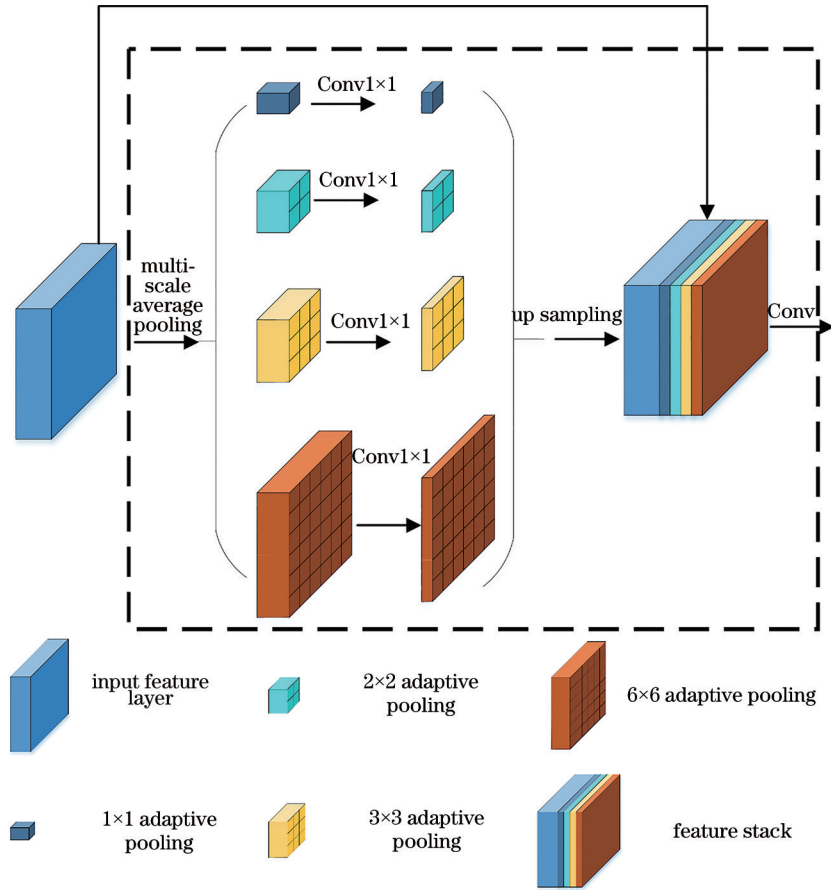


图 7 金字塔池化模块

Fig. 7 Pyramid pooling module

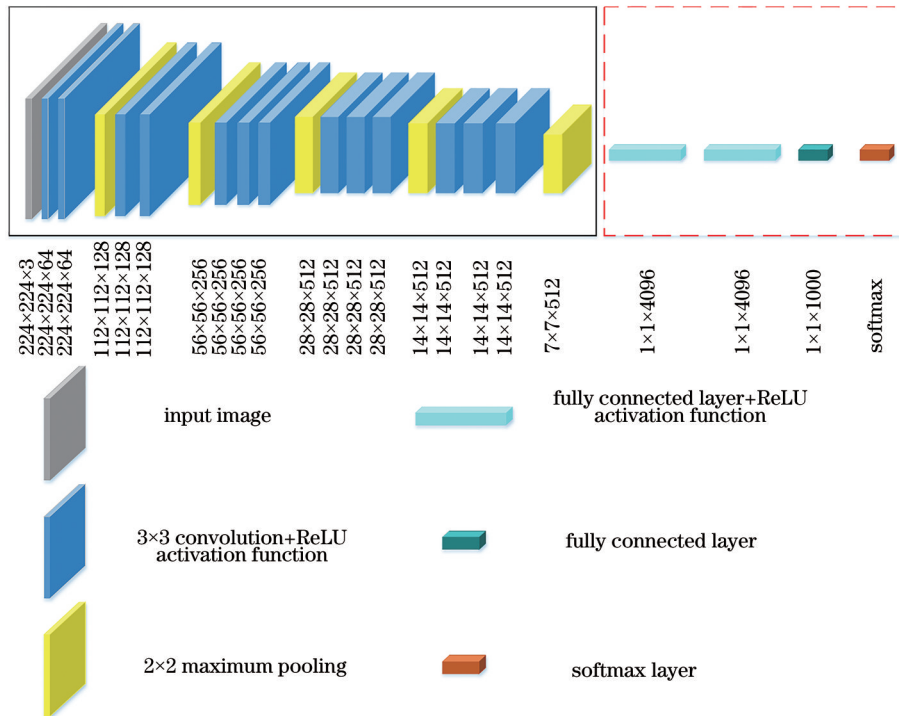


图 8 VGG16 网络

Fig. 8 VGG16 network

一致,对图像边界的处理更好。本文将 U-Net 的编码块替换为 VGG16 网络的特征提取模块。

VGG16 网络的特征提取结构中,输入图像先后经过 5 个模块,前 2 个模块每个模块由 2 个卷积层和 1 个池化层组成,后 3 个模块每个模块由 3 个卷积层和 1 个池化层组成。

### 3.5 改进 U-Net 模型

根据上述提到的结构,在 U-Net 基础上,融合坐标注意力机制、金字塔池化模块,并将 U-Net 的编码块结构替换为 VGG16 网络的特征提取结构,得到改进的 U-Net,如图 9 所示,图中标注出了每一层特征图的大小和通道数。

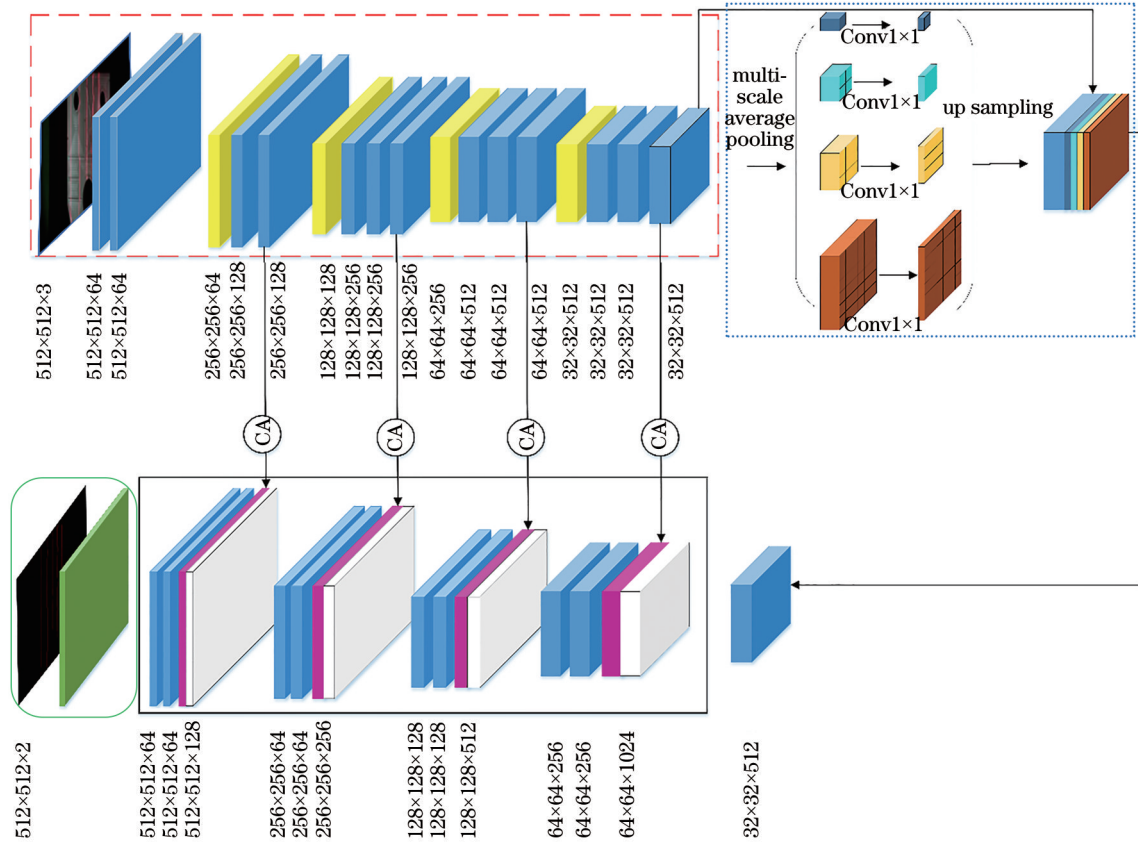


图 9 改进的 U-Net 网络

Fig. 9 Improved U-Net network

从图 9 可知,改进的 U-Net 包括 5 部分:特征提取结构,如虚线框所示;加强特征提取结构,如实线框所示;分割预测结构,如椭圆框所示;跳跃连接结构;金字塔池化结构,如点虚线框所示。

**特征提取结构:**U-Net 网络编码块中的 5 个模块每个模块均由 2 个卷积层组成,改进的 U-Net 网络第 1/2 个模块均采用 2 个卷积层,第 3/4/5 个模块均采用 3 个卷积层,增加网络深度,提升网络的特征提取能力;改进 U-Net 网络的卷积层采用像素填充的卷积方式,增强网络对图像边缘信息的提取,保证卷积后的输出特征图与输入图尺寸一致,使网络更具通用性。

**加强特征提取结构:**对特征图进行两倍上采样,并与特征提取结构获得的初步有效特征图进行融合。**分割预测结构:**卷积层的卷积核大小为  $1 \times 1$ ,

对加强特征提取结构的输出特征图进行通道数调整。

**跳连接结构:**U-Net 网络将特征提取结构获得的初步有效特征图直接与加强特征提取结构上采样后的特征图融合,改进 U-Net 网络将特征提取结构获得的初步有效特征图通过坐标注意力机制,增强光条纹特征提取,然后将其与加强特征提取结构上采样得到的特征图融合。

**金字塔池化结构:**在特征提取结构末端接入金字塔池化模块,对特征提取结构的输出特征图进行多尺度池化,获得不同感受野下的全局信息;调整各个池化后的特征图,使其与输入特征图具有相同的大小,进行特征图融合。

### 3.6 损失函数

图像中光条纹占比失衡,光条纹的分割属于小目标分割。直接使用二分类交叉熵值损失函数时,光条纹信息容易被忽略,Dice 损失函数可以减轻类不平衡问题<sup>[18]</sup>。所提改进 U-Net 网络使用 Dice 损失函数与二分类交叉熵值损失函数的组合函数作为网络的损失函数,表达式为

$$L_{\text{loss}} = l_{\text{Ce\_loss}} + l_{\text{Dice\_loss}}, \quad (7)$$

$$l_{\text{Ce\_loss}} = -[y \log_{10} \hat{y} (1 - y) \log_{10} (1 - \hat{y})], \quad (8)$$

$$l_{\text{Dice\_loss}} = 1 + \frac{-2 \times (|X \cap Y| + 1)}{|X| + |Y| + 1}, \quad (9)$$

式中: $l_{\text{Ce\_loss}}$  为二分类交叉熵值损失函数; $l_{\text{Dice\_loss}}$  为 Dice 损失函数; $X$  为预测为光条纹的像素数; $Y$  为光条纹实际像素数; $y$  为真实样本的标签, $y = 1$  表示真实标签为光条纹, $y = 0$  表示真实标签为背景; $\hat{y}$  为像素预测为光条纹的概率, $1 - \hat{y}$  为像素预测为背景的概率。

## 4 模型训练

实验计算平台配置: Intel (R) Core (TM) i7-8700 CPU@3.20 GHz 处理器、GeForce GTX 1660 SUPER 型号的 NVIDIA 显卡、操作系统 Windows10、CUDA 11.1、Python 3.8, 使用 Pytorch1.8.1 深度学习框架进行网络的搭建和训练。网络训练过程中,使用 Adam 优化器更新训练权重,网络训练 epoch 次数为 100,学习率为 0.0001, batch size 为 4。batch size 是机器学习中的重要参数,代表网络一次性载入的数据,在合理的范围之内,batch size 越大,下降方向越准确,振荡越少。

网络每次迭代的训练损失 (training loss) 和训练精度 (training accuracy) 曲线如图 10 所示,验证损失 (validation loss) 和验证精度 (validation accuracy) 曲线如图 11 所示。

从训练和验证过程中的损失值与精度值曲线图可知,随着迭代次数增加,网络的损失值逐渐降低并趋于稳定,网络的精度值逐渐升高并趋于稳定。网络没有出现拟合或欠拟合,网络可靠。

## 5 实验与结果分析

### 5.1 线结构光光条纹分割实验

#### 5.1.1 不同分割算法对比

选择传统图像分割算法、U-Net 算法、VGG16+U-Net 算法、Attention U-Net 算法、

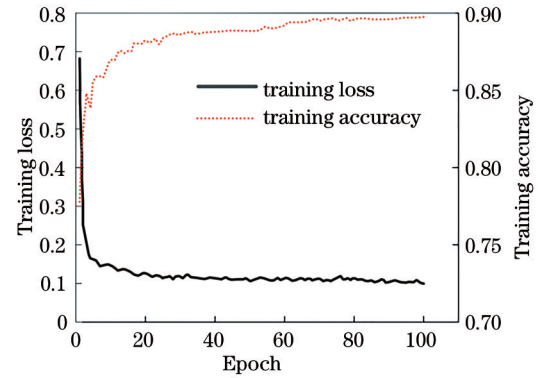


图 10 训练损失值和精度值

Fig. 10 Training loss value and accuracy value

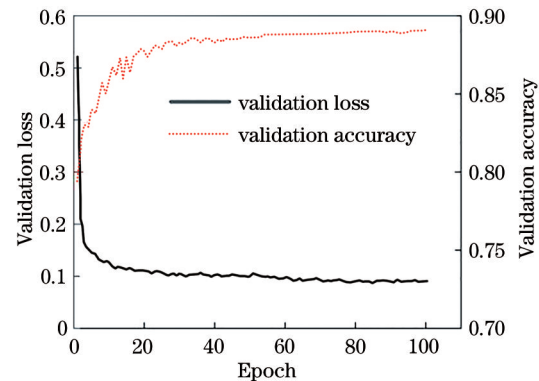


图 11 验证损失值和精度值

Fig. 11 Validation loss value and accuracy value

VGG16+Attention U-Net 算法、PSPNet 算法、ENet 算法、所提改进 U-Net 算法分别对测试集图像进行分割对比实验。为验证所提改进 U-Net 算法的准确性和鲁棒性,随机选择 3 个测试图像进行预测分割。不同算法的分割结果如图 12 所示。

由于受到工件反光、环境光及线结构光光源的影响,传统图像分割算法的光条纹分割结果存在以下问题:利用图像浅层区域和边界信息,通过阈值设定进行光条纹分割,由于阈值设定困难,易将背景误分割为光条纹。U-Net 算法的光条纹分割结果存在以下问题:背景像素错判为光条纹像素,如虚线框所示;间断的光条纹之间出现误连接,如实线框所示;连续的光条纹出现特征丢失,如双划线框所示。相比 U-Net 算法,VGG16+U-Net 算法在连续光条纹区域的特征提取准确率得到提高,但仍存在以下问题:背景像素错判为光条纹像素,如虚线框所示;间断的光条纹之间出现误连接,如实线框所



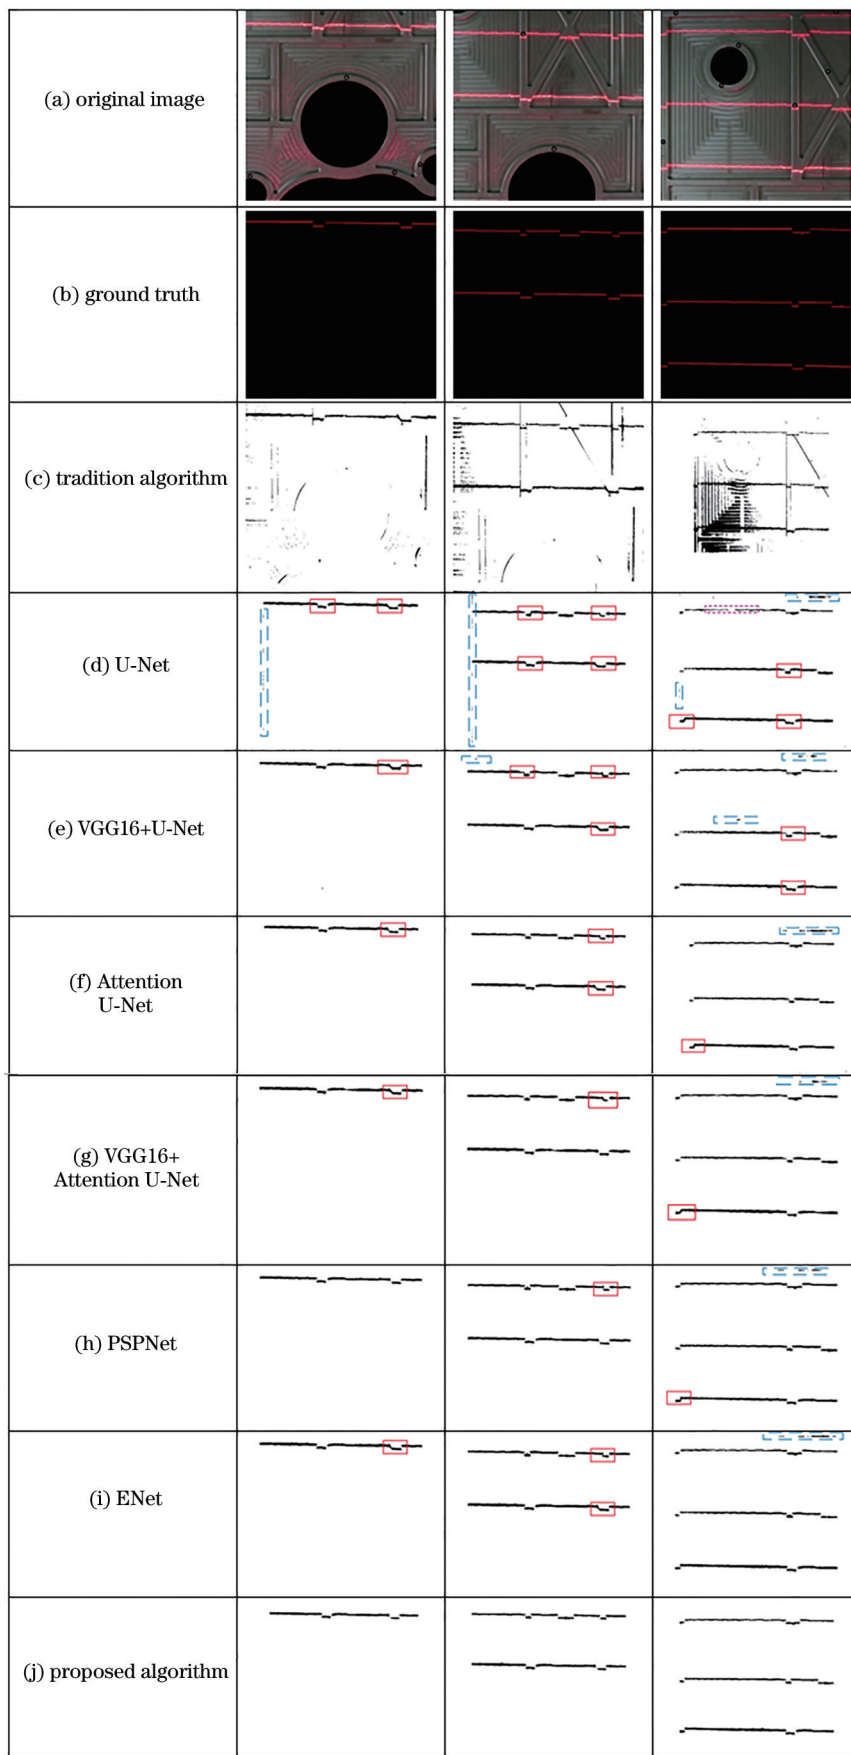


图 12 不同算法的分割结果

Fig. 12 Segmentation results of different algorithms

示。相比 Attention U-Net 算法, VGG16+Attention U-Net 算法分割准确率有所提高, 但仍有少量背景像素错判为光条纹像素, 如虚线框所示; 间断的光条纹之间也有少量误接, 如实线框所示。PSPNet 算法和 ENet 算法在光条纹分割中存在背景像素错判为光条纹像素的情况, 如虚线框所示; 存在间断的光条纹之间出现误连接的情况, 如实线框所示。所提改进 U-Net 算法在网络的特征提取结构中增加了卷积层深度, 增强光条纹特征提取, 减少光条纹特征丢失, 分割结果中连续的光条纹被完整分割出来; 在网络编码块与解码块瓶颈处接入金字塔池化模块, 增强局部光条纹特征与全局信息的联系, 减

少背景像素错判为光条纹像素的现象, 分割结果中光条纹像素和背景像素被准确区分; 在网络跳跃连接中加入坐标注意力机制, 加强光条纹特征的使用, 抑制其他干扰特征, 减少间断光条纹之间的误连接, 分割结果中间断光条纹的分割区域互不相交, 改进 U-Net 算法的分割结果更接近于金标准标注图。结果说明, 所提改进 U-Net 分割算法的准确性和鲁棒性更高。

为验证所提改进 U-Net 分割算法的鲁棒性和准确性, 使用所提改进 U-Net 算法对复杂场景下的采集图像进行光条纹分割实验, 分割结果如图 13 所示。

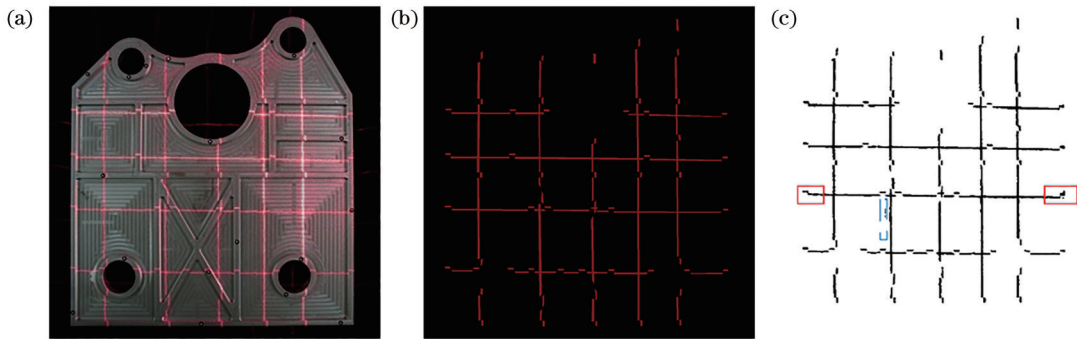


图 13 复杂场景下改进 U-Net 算法的条纹分割图。(a) 原图; (b) 金标准标注图; (c) 改进 U-Net 算法的分割结果

Fig. 13 Fringe segmentation of improved U-Net algorithm in complex scene. (a) Original image; (b) ground true; (c) segmentation result of improved U-Net algorithm

由图 13 可知, 复杂场景下改进 U-Net 算法依旧可以对光条纹进行高精度分割。由于所提改进 U-Net 算法的平均交并比(mIoU)为 89.73% 和平均像素准确度(mpa)为 95.61%, 当图像中光条纹受线结构光源质量、光线散射、环境光等影响严重时, 条纹分割结果出现局部误连接(如实线框所示)和局部误判(如虚线框所示)。

### 5.1.2 评价指标

采用 mpa 和 mIoU 两个指标对光条纹分割结果进行定量分析<sup>[19]</sup>, 计算公式分别为

$$P_{mpa} = \frac{1}{2} \left( \frac{N_{TP}}{N_{TP} + N_{FP}} + \frac{N_{TN}}{N_{TN} + N_{FN}} \right), \quad (10)$$

$$P_{mIoU} = \frac{1}{2} \left( \frac{N_{TP}}{N_{TP} + N_{FN} + N_{FP}} + \frac{N_{TN}}{N_{TN} + N_{FN} + N_{FP}} \right), \quad (11)$$

式中: TP 为真阳性,  $N_{TP}$  表示光条纹被正确分割的像素数目; TN 为真阴性,  $N_{TN}$  表示背景被正确分割的像素数目; FN 为假阴性,  $N_{FN}$  表示光条纹被误分割为背景的像素数目; FP 为假阳性,  $N_{FP}$  表示背景

被误分割为光条纹的像素数目。

### 5.1.3 光条纹分割实验

传统图像分割算法、U-Net 算法、VGG16+U-Net 算法、Attention U-Net 算法、VGG16+Attention U-Net 算法、PSPNet 算法、ENet 算法、所提改进 U-Net 算法的评价指标值如表 1 所示, 加粗项为对应指标的最好值。

表 1 不同算法的指标值

Table 1 Index values of different algorithms

| Algorithm              | mIoU / %     | mpa / %      |
|------------------------|--------------|--------------|
| Tradition algorithm    | 49.43        | 72.68        |
| U-Net                  | 84.28        | 93.59        |
| VGG16+U-Net            | 84.39        | 93.8         |
| Attention U-Net        | 84.29        | 94.45        |
| VGG16+ Attention U-Net | 86.55        | 94.88        |
| PSPNet                 | 88.32        | 94.95        |
| ENet                   | 87.32        | 94.09        |
| Proposed algorithm     | <b>89.73</b> | <b>95.61</b> |

由表 1 可知, 传统图像分割算法、U-Net 算法、VGG16+U-Net 算法、Attention U-Net 算法、VGG16+Attention U-Net 算法、PSPNet 算法、ENet

算法、所提改进 U-Net 算法的 mIoU 值分别为 49.43%、84.28%、84.39%、84.29%、86.55%、88.32%、87.32%、89.73%，mpa 值分别为 72.68%、93.59%、93.8%、94.45%、94.88%、94.95%、94.09%、95.61%。对比其他算法，所提改进 U-Net 算法的评价指标值更高，能够对光条纹进行更精确的分割。

### 5.2 金属工件尺寸测量实验

完整的线结构光测量系统包括：图像采集、光条纹分割、表征待测结构尺寸信息的目标光条纹提取、目标光条纹特征点获取、系统成像模型建立<sup>[20]</sup>。通过搭建采集系统完成图像采集，采用改进 U-Net 算法实现光条纹分割。要想完成工件尺寸测量，还需完成目标光条纹提取和条纹特征点获取、系统成

像模型建立，以上两部分实现过程如下。

#### 5.2.1 目标光条纹提取及条纹特征点获取

由于工件待测加强筋是凸起结构，光条纹在加强筋处出现折断。基于加强筋结构特性，选取折断处的光条纹作为目标光条纹表征加强筋尺寸信息。

表征金属工件加强筋尺寸信息的目标光条纹具有一定像素宽度，需要将具有宽度的光条纹量化为测量点，这个过程就是光条纹特征点获取。目标光条纹特征点的获取方法：求取目标光条纹区域的最小外接矩形，选取外接矩形的角点，作为光条纹特征点。不同方向加强筋对应的光条纹的特征点提取如图 14 所示。图中半划线为加强筋界线，虚线区域表示目标光条纹，实线框表示光条纹外接矩形，叉号为外接矩形角点。




图 14 不同方向加强筋对应的光条纹特征点提取。(a)水平加强筋条纹特征点提取；(b)倾斜加强筋条纹特征点提取；(c)竖直加强筋条纹特征点提取

Fig. 14 Extraction of light stripe feature points corresponding to stiffeners in different directions. (a) Feature point extraction of horizontal stiffener stripes; (b) feature point extraction of inclined stiffener stripes; (c) feature point extraction of vertical stiffener stripes

#### 5.2.2 成像模型建立

目标条纹特征点是图像中的点，为确定空间物体表面某点的位置与其在图像中对应点之间的关系，需要建立相机成像模型，获得成像模型参数的过程就是相机标定。通过张正友标定算法获得相机的内外参数，成像模型表达式为

$$s \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & u_0 \\ 0 & f_y & v_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \mathbf{R} & \mathbf{T} \\ 0 & 1 \end{bmatrix} \begin{bmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{bmatrix}, \quad (12)$$

式中： $\mathbf{R}$ 为旋转矩阵， $\mathbf{T}$ 为平移矩阵； $f_x, f_y$ 为 X、Y 轴方向上的像素焦距； $(u_0, v_0)$ 为相机主点坐标， $(u, v)$ 为像素坐标， $(X_w, Y_w, Z_w)$ 为世界坐标。

#### 5.2.3 加强筋尺寸测量实验

测量的金属工件如图 15 所示。为验证测量方法的精度和鲁棒性，对多个加强筋进行测量实验，以图 15 中 a、b、c、d 的测量为例。

采用绝对误差和相对误差两个测量指标对测量精度进行定量分析。绝对误差、相对误差表达式




图 15 金属工件

Fig. 15 Metal workpiece

分别为

$$\Delta = l - L, \quad (13)$$

$$\epsilon = \frac{\Delta}{l} \times 100\%, \quad (14)$$

式中： $l$ 为测量值； $L$ 为标准值； $\Delta$ 为测量值与标准值之间的绝对误差； $\epsilon$ 为相对误差。

金属工件沿不同方向的加强筋测量结果如表 2

所示。为验证工件尺寸测量系统的稳定性,对工件位

表 2 金属工件沿不同方向的加强筋测量结果

Table 2 Measurement results of stiffeners in different directions of metal workpiece

| Measuring position | $L / \text{mm}$ | $l / \text{mm}$ | $\Delta / \text{mm}$ | $\epsilon / \%$ |
|--------------------|-----------------|-----------------|----------------------|-----------------|
| a                  | 10.02           | 9.95338         | -0.0666              | -0.665          |
| b                  | 9.98            | 9.91998         | -0.06002             | -0.601          |
| c                  | 9.96            | 9.91839         | -0.04161             | -0.418          |
| d                  | 10.00           | 9.92784         | -0.07216             | -0.722          |

置 a 处的加强筋进行重复精度验证。重复精度表达式为

$$\sigma = \sqrt{\frac{\sum (l - l_{\text{ave}})^2}{n - 1}}, \quad (15)$$

$$\delta = \frac{\sigma}{x} \times 100\%, \quad (16)$$

式中: $l_{\text{ave}}$ 为多次测量的平均值; $n$ 为测量次数; $\sigma$ 为标准差; $\delta$ 为重复精度。

金属工件 a 处的加强筋重复精度如表 3 所示。

表 3 金属工件 a 处加强筋重复性测量

Table 3 Repeatability measurement of stiffener at position a of metal workpiece

| Measuring position | $n$ | $l / \text{mm}$ | $l_{\text{ave}} / \text{mm}$ | $\sigma$ | $\delta / \%$ |
|--------------------|-----|-----------------|------------------------------|----------|---------------|
| a                  | 1   | 9.95338         | 9.94765                      | 0.01347  | 0.14          |
|                    | 2   | 9.93935         |                              |          |               |
|                    | 3   | 9.96358         |                              |          |               |
|                    | 4   | 9.93430         |                              |          |               |

尺寸值大于 500 mm 的工件属于大尺寸工件。大尺寸工件精度要求:尺寸公差 $\pm 1$  mm,按 1/10 公差值计算,允许误差为 0.1 mm。当测量尺寸的绝对误差小于 0.1 mm 时,测量满足工件要求。

由表 2、3 数据可得,所提测量方法应用在金属工件加强筋尺寸测量实验中,测量值的绝对误差小于 0.1 mm,相对误差小于 1%,重复精度小于 0.2%,测量结果满足工件检测要求,所提测量方法具有高精度和高鲁棒性。

## 6 结 论

提出一种改进 U-Net 网络。首先,改变 U-Net 网络编码块中的卷积池化层结构,增加网络深度,获取更多的光条纹特征;其次,在 U-Net 网络编码块与解码块对应层间的跳连接中引入坐标注意力机制,增强光条纹特征利用,抑制干扰特征;然后,在 U-

Net 网络编码块与解码块瓶颈处接入金字塔池化模块,增强局部光条纹特征与全局信息的联系;为解决采集图像中光条纹占比失衡的分割难点,融合二分类交叉熵值损失函数和 Dice 损失函数作为网络的损失函数,实现对光条纹的精确分割。基于线结构光测量原理,设计了工件尺寸测量系统,建立了系统成像模型,实现空间多尺度变换,完成工件尺寸测量。

所提改进的 U-Net 算法的分割精度指标 mpa 值为 95.61%,mIoU 值为 89.73%,两个指标值均高于对比算法,所提改进的 U-Net 算法对光条纹的分割精度更高。系统测量尺寸的绝对误差小于 0.1 mm,相对误差小于 1%,重复精度小于 0.2%,测量结果满足工件检测要求。所提测量方法在金属工件尺寸测量领域有很大的应用前景。

## 参 考 文 献

- [1] 冯西,吴静静,安伟.基于机器视觉的大尺寸工件自动测量系统[J].传感器与微系统,2019,38(4):104-107. Feng X, Wu J J, An W. Research on automatic measurement system of large size workpiece based on machine vision[J]. Transducer and Microsystem Technologies, 2019, 38(4): 104-107.
- [2] 赵海文,郑锦云,张雅丽.基于视觉的大尺寸板材冲孔质量检测系统设计[J].仪表技术与传感器,2020(11):79-83. Zhao H W, Zheng J Y, Zhang Y L. Design of vision-based punching quality detection system for large-size sheet metal[J]. Instrument Technique and Sensor, 2020(11): 79-83.
- [3] 陈宇昊,彭力,朱良俊.基于机器视觉的汽车紧固件检测系统设计[J].制造业自动化,2021,43(4):125-131. Chen Y H, Peng L, Zhu L J. Design of inspection system for automobile fastening components based on machine vision[J]. Manufacturing Automation, 2021, 43(4): 125-131.
- [4] 任永强,涂德江,韩暑.基于机器视觉的柴油机缸套尺寸测量[J].组合机床与自动化加工技术,2020(9):151-153. Ren Y Q, Tu D J, Han S. Dimension measurement of diesel cylinder liner based on machine vision[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(9): 151-153.
- [5] 戴相昆,王小深,杜乐辉,等.基于三维 U-NET 深度卷积神经网络的头颈部危及器官的自动勾画[J].生物医学工程学杂志,2020,37(1):136-141.

- Dai X K, Wang X S, Du L H, et al. Automatic segmentation of head and neck organs at risk based on three-dimensional U-NET deep convolutional neural network[J]. *Journal of Biomedical Engineering*, 2020, 37(1): 136-141.
- [6] 牟海维, 郭颖, 全星慧, 等. 基于改进 U-Net 的磁共振成像脑肿瘤图像分割[J]. *激光与光电子学进展*, 2021, 58(4): 0410022.
- Mu H W, Guo Y, Quan X H, et al. Magnetic resonance imaging brain tumor image segmentation based on improved U-Net[J]. *Laser & Optoelectronics Progress*, 2021, 58(4): 0410022.
- [7] 陈进, 韩梦娜, 练毅, 等. 基于 U-Net 模型的含杂水稻籽粒图像分割[J]. *农业工程学报*, 2020, 36(10): 174-180.
- Chen J, Han M N, Lian Y, et al. Segmentation of impurity rice grain images based on U-Net model[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2020, 36(10): 174-180.
- [8] 杨丹, 刘国如, 任梦成, 等. 多尺度卷积核 U-Net 模型的视网膜血管分割方法[J]. *东北大学学报(自然科学版)*, 2021, 42(1): 7-14.
- Yang D, Liu G R, Ren M C, et al. Retinal blood vessel segmentation method based on multiscale convolution kernel U-Net model[J]. *Journal of Northeastern University (Natural Science)*, 2021, 42(1): 7-14.
- [9] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04) [2021-02-03]. <https://arxiv.org/abs/1409.1556>.
- [10] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 3431-3440.
- [11] Oktay O, Schlemper J, Folgoc L L, et al. Attention U-net: learning where to look for the pancreas[EB/OL]. (2018-04-11) [2021-02-03]. <https://arxiv.org/abs/1804.03999>.
- [12] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6230-6239.
- [13] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 13708-13717.
- [14] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [15] 任秉银, 李智勇, 代勇. 手机屏幕轻微划痕检测方法[J]. *哈尔滨工业大学学报*, 2021, 53(1): 29-36.
- Ren B Y, Li Z Y, Dai Y. Method for detection of slight scratch of mobile phone screen[J]. *Journal of Harbin Institute of Technology*, 2021, 53(1): 29-36.
- [16] 于宁波, 刘嘉男, 高丽, 等. 基于深度学习的膝关节 MR 图像自动分割方法[J]. *仪器仪表学报*, 2020, 41(6): 140-149.
- Yu N B, Liu J N, Gao L, et al. Auto-segmentation method based on deep learning for the knee joint in MR images[J]. *Chinese Journal of Scientific Instrument*, 2020, 41(6): 140-149.
- [17] 张瑞瑞, 夏浪, 陈立平, 等. 基于 U-Net 网络和无人机影像的松材线虫病变色木识别[J]. *农业工程学报*, 2020, 36(12): 61-68.
- Zhang R R, Xia L, Chen L P, et al. Recognition of wilt wood caused by pine wilt nematode based on U-Net network and unmanned aerial vehicle images[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2020, 36(12): 61-68.
- [18] 杨国亮, 赖振东, 王杨. 基于多尺度密集块网络的皮肤病变图像分割算法[J]. *激光与光电子学进展*, 2020, 57(18): 181020.
- Yang G L, Lai Z D, Wang Y. Skin lesion image segmentation algorithm based on multi-scale DenseNet [J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 181020.
- [19] 李立凯, 卢焱华, 邹斌. 基于深度学习的目标检测与可行域分割研究[J]. *激光与光电子学进展*, 2020, 57(12): 121013.
- Li L K, Lu C H, Zou B. Research on target detection and feasible region segmentation based on deep learning[J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 121013.
- [20] 方志强, 熊禾根, 肖书浩, 等. 基于单目视觉多种平面尺寸的规则工件测量系统[J]. *机械设计与制造*, 2020(11): 241-245, 249.
- Fang Z Q, Xiong H G, Xiao S H, et al. Regular workpiece measurement system with multiple plane dimensions based on monocular vision[J]. *Machinery Design & Manufacture*, 2020(11): 241-245, 249.