

doi: 10.12194/j.ntu.20210330001

引文格式: 张堃, 李子杰, 瞿宏俊, 等. 基于注意力机制和隐马尔科夫的高精密螺纹全自动精确测量[J]. 南通大学学报(自然科学版), 2021, 20(3):57-66.

基于注意力机制和隐马尔科夫的高精密螺纹全自动精确测量

张 堃^{1,5}, 李子杰², 瞿宏俊³, 吴建国^{4,5}, 华 亮^{1*}

(1. 南通大学 电气工程学院, 江苏 南通 226019; 2. 中科海拓(无锡)科技有限公司, 江苏 无锡 214122;
3. 江南大学 物联网工程学院, 江苏 无锡 214122; 4. 南通理工学院 电气与能源工程学院, 江苏 南通 226002;
5. 南通市智能控制与智能计算重点实验室, 江苏 南通 226002)

摘要:基于机器视觉的螺纹测量易受到工业环境(例如灰尘、铁屑、油渍等)的干扰,且需要人工半自动干预,导致测量结果不稳定。通过加入 Attention 机制对 R2Unet 模型进行改进,提出一种基于 AA R2Unet 深度学习模型和隐马尔科夫模型的高精密螺纹全自动精确测量方法。首先,为了克服工业环境中灰尘、铁屑等因素的干扰,设计了 AA R2Unet 模型对外螺纹进行有效边缘识别与提取;然后,通过计算螺纹边缘点梯度方向特征信息,使用隐马尔可夫模型对螺纹边缘点进行分割,达到螺纹零件在测量过程中可以任意角度放置的目的。通过实际采集工件图像制作数据集进行实验验证,结果表明,基于 AA R2Unet 的螺纹边缘提取方法分割精度达到 95.92%,基于隐马尔可夫模型的螺纹边缘点分类准确率达到 86%以上,外径测量误差在 0.01 mm 以内。

关键词:Unet 模型;注意力机制;隐马尔可夫;螺纹测量

中图分类号: TP391.4;TP24

文献标志码: A

文章编号: 1673-2340(2021)03-0057-10

Automatic and Accurate Measurement of High Precision Thread Based on AA R2Unet and HMM

ZHANG Kun^{1,5}, LI Zijie², QU Hongjun³, WU Jianguo^{4,5}, HUA Liang^{1*}

(1. School of Electrical Engineering, Nantong University, Nantong 226019, China;

2. Hito Technology Co., Ltd., Wuxi 214122, China;

3. Department of Electronic Engineering, Jiangnan University, Wuxi 214122, China;

4. School of Electrical and Energy Engineering, Nantong Institute of Technology, Nantong 226002, China;

5. Nantong Key Laboratory of Intelligent Control and Intelligent Computing, Nantong 226002, China)

Abstract: The thread measurement methods based on machine vision are easily disturbed by the environment (e.g. dust, iron filings, oil stains, etc.), resulting in inaccurate measurement results. This paper improves the R2Unet model by adding the Attention mechanism, and proposes an external thread measurement method based on AA R2Unet and hidden Markov model (HMM). Firstly, to overcome the interference of dust, iron filings et al, the AA R2Unet model was designed to identify and extract the external threads. Secondly, the feature information on gradient direction of

收稿日期: 2021-03-30

基金项目: 江苏省高校自然科学基金项目(18KJB510038); 江苏省“333 工程”项目(BRA2018218); 国家级大学生创新创业训练计划项目(202010304065Z)

第一作者简介: 张堃(1983—), 男, 教授, 博士。

* 通信联系人: 华亮(1979—), 男, 教授, 博士, 博士生导师, 主要研究方向为图像处理、机器人工程。E-mail: hualiang@ntu.edu.cn

thread edge points is calculated, HMM was used to classify the thread edge points so that the threaded parts can be placed at any angle during the measurement. Finally, the method with the gathered dataset was evaluated. The results show that the segmentation accuracy of the thread edge extraction method based on AA R2Unet is 95.92%, the classification accuracy of thread edge points based on HMM is above 86% and the comprehensive measurement error is within 0.01 mm.

Key words: Unet model; Attention mechanism; hidden Markov model; thread measurements

螺纹零件是现代工业产品中常用的高精密零件,在工业生产中有着广泛的应用。它们是机械工业中最重要的连接、紧固和传动部件之一^[1]。螺纹的几何参数和力学性能对工业产品的质量有很大的影响,因此保证螺纹检测的精度和效率至关重要。传统的螺纹检测包括:螺纹规检测、三针法检测等^[2-3]。这些传统的螺纹检测方法检测效率低、成本高,且这些检测方法均为接触式检测会对螺纹造成损伤,不能满足现代工业自动化的要求。

随着螺纹检测技术的发展,非接触测量技术^[4]正逐步取代传统的测量方法。许多研究人员对非接触式螺纹测量进行了研究,例如:文献[5]使用三维扫描仪测量螺纹,但是他们只测量螺纹的内半径和外半径;文献[6]提出了一种基于计算机视觉的非接触式螺纹测量系统,可以测量常见的螺纹类型,但是他们的方法在一定程度上限制了螺纹零件的放置角度(螺纹零件应水平放置);文献[7]提出了一种基于统计的图像分析方法来测量螺距;文献[8]提出了一种基于激光测量技术的螺纹自动测量系统;文献[9]提出了一种通过 Hough 变换自动提取螺纹特征和参数的方法;文献[10]提出了一种基于机器视觉和光学放大的螺纹高精度几何误差测量方法。

目前,螺纹的非接触检测方法很多,但大多数技术都存在一定的缺陷,例如:激光位移检测技术需要激光传感器、光栅系统等,成本高,伺服控制要求高;红外探测技术存在精度不高、易受干扰等问题;基于机器视觉的检测方法在进行测量时,往往通过人工标记待测量的螺纹区域或者设计检测视场较小的图像采集系统,来屏蔽图像中非螺纹轮廓的干扰,且为方便在后续分析中获取螺纹牙角顶部点拟合外径线,需要将螺纹零件在水平方向和垂直方向摆放;此外,目前的机器视觉测量方法还易受

工业环境中灰尘等干扰因素的影响导致测量异常^[11]。针对目前机器视觉检测方法需要人为选定螺纹区域,且检测方法抗干扰能力差的问题,本文提出一种基于 AA R2Unet 深度学习模型的螺纹边缘提取方法,在 R2Unet 语义分割模型中加入 Attention 机制提升模型对目标的分割精度,并将其用于自动提取不同类型螺纹零件上的螺纹边缘点,提高检测的自动化程度。该方法利用 AA R2Unet 学习螺纹边缘特征,有效避免了工业环境中载物台可能出现的上异常点(如铁屑、油渍等)与螺纹工件中的不规则牙角而造成的误提取,提高了抗干扰能力。本文还提出一种基于隐马尔可夫模型(hidden Markov model, HMM)的螺纹边缘点分类方法。该方法利用相邻边缘点的梯度方向差信息,将提取的螺纹边缘点划分为 3 种类型,分别为:峰谷型、过渡型和直线型,并以此计算螺纹参数。本文利用 HMM 进行分类,可以避免机器视觉检测方法中螺纹零件需要水平或垂直放置的问题,即使将螺纹零件摆放在一定的角度,螺纹参数仍能准确计算,使整个测量系统具有较好的鲁棒性和泛化能力。本研究检测的部分螺纹工件如图 1 所示。



图 1 螺纹工件图

Fig. 1 Screwed workpiece

本文提出的外螺纹测量系统框架如图 2 所示。其中, AA R2Unet 模型用于识别和定位螺纹的边缘, 省去了标记螺纹区域的过程。然后, 依据 AA R2Unet 模型的提取结果结合原图的灰度信息, 计算螺纹边缘点的梯度方向差作为 HMM 模型的观测数据, 利用 HMM 模型将螺纹边缘点分为 3 种类型: 峰谷型、过渡型和直线型。最终依据分类结果拟合直线计算相应的螺纹参数。

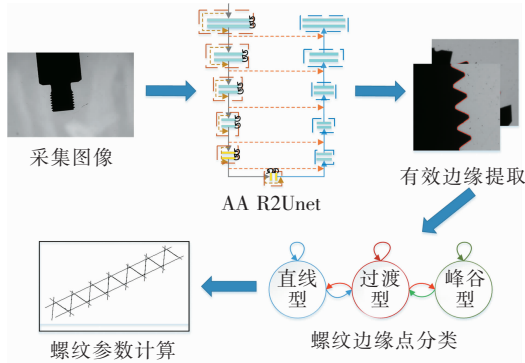


图 2 螺纹测量框架图

Fig. 2 Framework of the proposed approach

1 AA R2Unet 螺纹边缘提取

在工业环境中, 由于现场环境复杂, 采用传统的图像边缘检测方法进行边缘提取会检测出许多的干扰点。检测效果如图 3 所示, 其中图 3(a) 为原始图像, 图 3(b) 为 Canny 算法的效果。图 3(b) 的检测结果中存在的干扰点, 会严重影响后续螺纹边缘的提取。同时, 通过图 3(b) 也可以看出仅通过 Canny 算法进行边缘检测, 不仅会有干扰点的影响, 也检测出了工件中非螺纹边缘的部分, 无法单独提取出螺纹部分进行后续的分析与测量。




图 3 Canny 检测干扰图

Fig. 3 Edge detection effect of Canny algorithm in complex on-site environment

传统的视觉检测技术需要人为选取采集图像中的螺纹区域, 或者采用视场较小的图像采集设备, 调整工件位置使得采集图像中只包含工件的螺纹部分以解决螺纹边缘提取的难点。图 4 为人工选取螺纹区域的图像, 框选区域即为人为选取的螺纹区域。在图 4 中, 可以发现框选区域的左右两边各有一个不规则的螺纹角, 这些不规则的螺纹角特征与中间的正常螺纹牙角十分相似, 容易产生误选取, 使得测量结果异常。而本文提出的 AA R2Unet 螺纹边缘提取方法, 通过训练 AA R2Unet 网络学习螺纹区域的特征, 使得该网络对工件的螺纹边缘与非螺纹边缘进行分类, 实现了螺纹有效边缘的自动提取。与此同时, 对于图 4 中两边的不规则螺纹边缘也有很好的抑制效果, 提升了整个外螺纹测量系统的精度。




图 4 有效螺纹区域图

Fig. 4 Thread area selection

1.1 Attention Augment

Attention Augment^[12]具体结构如图 5 所示, 其本质为通过查询得到一系列键-值对的映射。首先, 通过对输入大小为 (w, h, c_{in}) 的特征图进行 1×1 卷积输出 QKV 矩阵, 其大小为 $(w, h, 2d_k + d_v)$, 其中 $w, h, 2d_k + d_v$ 分别表示矩阵的宽、长与深度。再从深度通道上对 QKV 矩阵进行分割, 得到 Q (Query)、 K (Key)、 V (Value) 3 个矩阵, 其深度通道大小分别为 d_k, d_k, d_v 。接着, 采用多头注意力机制的结构, 将 Q, K, V 3 个矩阵分别从深度通道上分割为 N 个相等的矩阵进行后续的计算 (本文设置 N 为 2)。这种多头注意力机制将原本单一的 Attention 计算, 扩展为较小且并行独立的多个计算, 使得模型可以在不同的子空间内学习特征信息。对于分割好的 Q, K, V 矩阵进行扁平化处理生成 $Flat_Q, Flat_K, Flat_V$ 3 个矩阵 (即对 Q, K, V 保持深度通道不变, 从长宽方向对其进行压缩到 1 维), 其中前两个矩阵的大小为 (wh, d_k) , 后一个矩阵大小为 (wh, d_v) 。接着,

Attention Augment 保存了原先 Self-Attention 的做法使用 Flat_Q、Flat_K 两矩阵进行矩阵乘法运算,计算出权重矩阵,且在此基础上添加了相对位置嵌入的计算,通过对 Q 矩阵进行长宽两方向的权重计算得到特征图上每个点的相对位置信息,防止因特征位置的变换而降低模型的最终效果。长宽两方向的相关位置信息分别通过 Q 矩阵与权重矩阵 H 和 W 内积得到,记为 S_k 和 S_w,其中权重矩阵 H 和 W 通过模型的训练得出,大小为 (wh, wh, 1)。然后,将得到的 3 个矩阵相加并乘以尺度系数 1/√d_k,以

防止计算结果过大。随后用 Softmax 函数进行处理,即得到最终的特征权重矩阵。最后,将该权重矩阵与 V 矩阵相乘并将结果 Reshape 到原始长宽大小,再进行 1*1 的卷积操作,即可得到最终的注意力特征矩阵 O。将注意力特征矩阵 O 和正常的卷积过程按深度方向进行拼接即可得到 Attention Augment 的结果。注意力特征矩阵 O 的计算公式如下:

$$O = \text{Conv}(\text{Softmax}(\frac{QK^T + S_h + S_w}{\sqrt{d_k}})V)。 \quad (1)$$

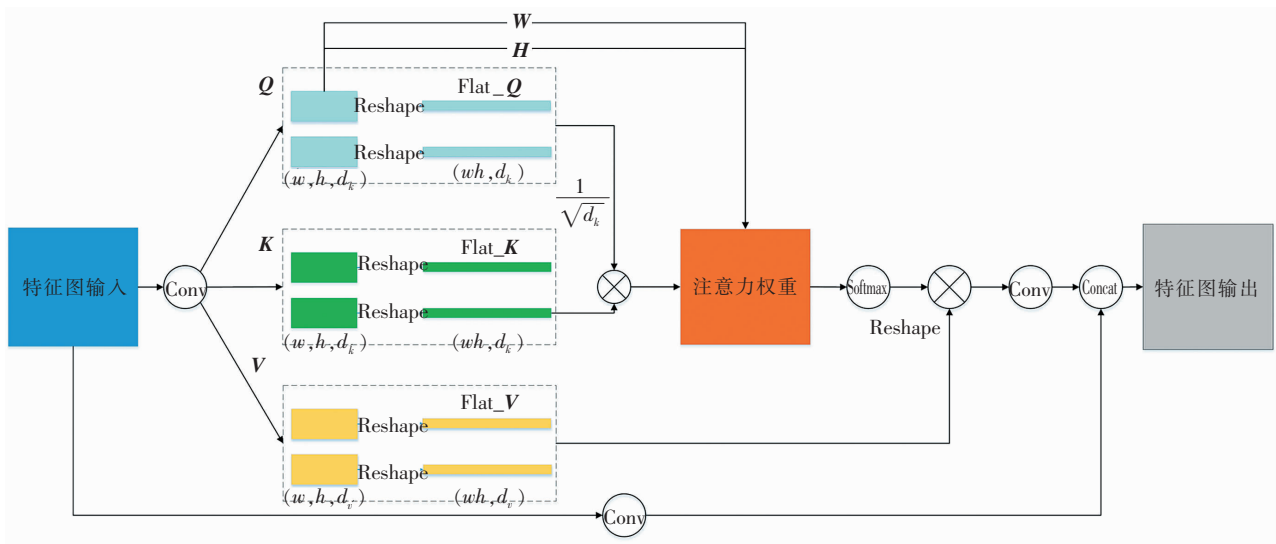


图 5 Attention Augment 框架图

Fig. 5 Framework of Attention Augment

Attention Augment 借鉴了自然语言处理中的 Self-Attention 机制,通过对输入特征进行注意力权重的计算得出注意力特征图像,并将计算出的注意力特征图与原有的卷积结果进行拼接,增强了卷积操作对全局信息的学习能力,提升了模型的识别精度。

1.2 AA R2Unet 模型

本文提出一种基于 AA R2Unet 的螺纹边缘的自动提取方法,旨在简化螺纹区域的标定过程,降低对操作者的要求,提高测量方法的自动化程度。Unet 模型总体呈对称的 U 型结构,在设计时共包含 12 个单元(F₁~F₁₂),其中:F₁~F₅为收缩路径,用于特征的提取;F₆为桥连接路径,用于连接收缩路径和扩张路径;F₇~F₁₂为扩张路径,用于细节的恢复,

实现精准预测。而 R2Unet 则是在 Unet 模型中用 R2 模块代替了原有卷积层,R2 模块如图 6 所示,主要包括残差学习单元和递归卷积。图 6 左侧为残差单元,残差单元的加入可以让模型能够更好地学习恒等映射,避免网络层数过深而引起的过拟合现象,同时也避免梯度爆炸和梯度消失现象的出现。图 6 右侧为递归卷积,通过重复卷积再将结果相加的方式进行有效的特征累积,加强了特征表示,使得模型能够更好地提取非常低级的特征,加强了模型的分割精度。图 6 中的递归卷积表示在 t = 0, 1, 2 时刻以前一层的输出作为输入进行卷积并将结果相加。本文提出的 AA R2Unet 模型具体结构如图 7 所示,由于 Unet 模型的左侧收缩路径用于特征的提取,而右侧的扩展路径用于恢复特征,因此本文将原本左侧中的卷积层全部替换为 R2 模

块, 而未进行所有卷积层的全部替换, 以便在进行有效特征提取的同时尽可能地简化整体的模型。




图 6 R2 结构图

Fig. 6 Structure of R2

在收缩路径和扩展路径的每层单元之间还存在着跳跃链接, 即图 6 中的虚线箭头部分。该部分用于将收缩路径中计算出的特征图传输到扩张路径中与其维度对应的部分进行特征图相融合, 这样的跳跃链接实现了上下文信息的跨层连接, 增强了网络捕获不同大小和不同维度特征信息的能力,

有助于扩张路径对图像细节部分的恢复, 提高预测精度。因为跳跃链接的存在可将收缩路径中 Attention Augment 提取到的全局特征信息传递到扩展路径中, 所以在扩展路径中本文并未用 Attention Augment 替代卷积操作。在网络的最后使用了 1×1 的卷积核进行特征维的压缩卷积, 将 F_{11} 输出的 32 通道特征矢量映射到 2 通道, 即螺纹边缘点与非螺纹边缘点。最终, F_{12} 输出一个与原图像相同大小的预测概率矩阵, 包含了原图像对应位置像素属于螺纹边缘点和非螺纹边缘点的概率, 并以此提取螺纹边缘点^[13-15]。

在 AA R2Unet 的训练过程中, 输入图像中的螺纹边缘和非螺纹点 (像素) 的数量严重不平衡, 螺纹边缘点只占总像素的小部分。这种不平衡的情况使得在训练过程中螺纹边缘点的贡献被稀释, 而非螺纹点的贡献占据了主导地位, 影响预测精度。我们认为在训练过程中应该平衡螺纹边点和非螺纹点的贡献, 因此本文采用了 Class Balanced loss, 以增加螺纹边点的贡献, 抑制非螺纹点的贡献。损失函数为

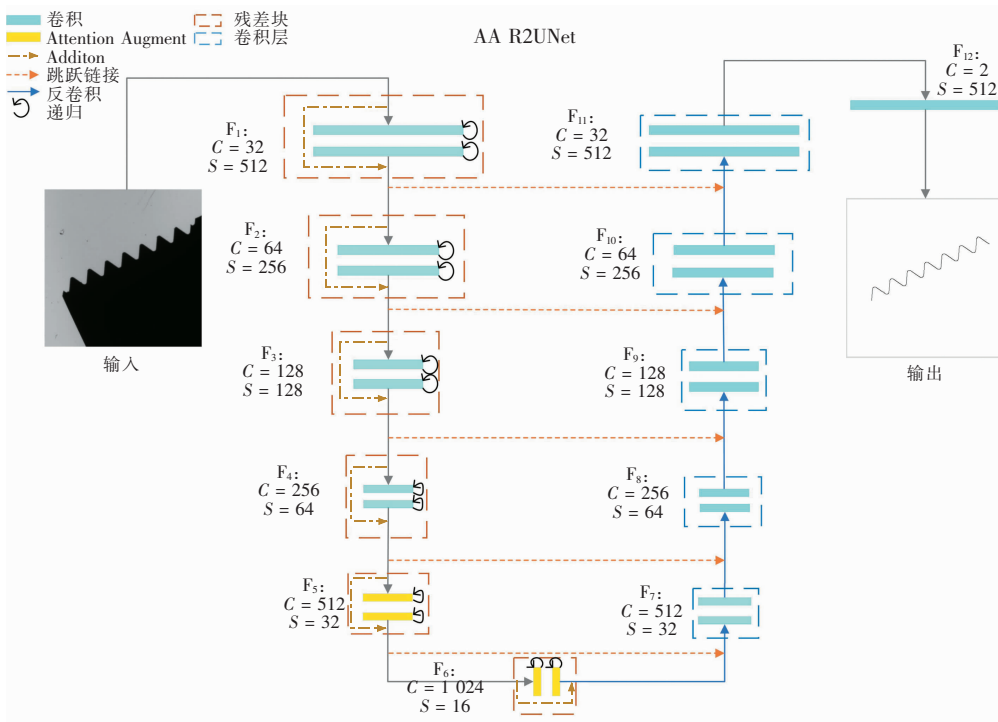


图 7 AA R2Unet 框架图

Fig. 7 Framework of AA R2Unet

$$\text{loss} = \frac{1 - \beta}{1 - \beta^{n_i}} \log p_i, \beta = \frac{N - 1}{N}, \quad (2)$$

式中: N 表示像素总数; n_i 表示样本标签中该分类的数量; p 表示相应点的预测概率。通过对于两个类别权重的调整,将螺纹点和非螺纹点的贡献趋于平衡,以提升AA R2Unet的提取效果。

2 基于隐马尔可夫的螺纹边缘点分类

在获取螺纹边缘点后,需要对其进行直线拟合才能计算相应外径、牙角等数据,因而需要将螺纹边缘点进行再拟合。通常,为简化分类过程,往往对螺纹零件的放置角度有着较高的要求(如要求螺纹部分水平或垂直放置)。本文提出了基于HMM的螺纹边缘点分类方法,旨在使得待测零件的摆放不再受约束,简化操作步骤,提升检测系统的自动化程度。

HMM^[16]包含两个随机过程:马尔可夫链和观测变量的随机过程。根据观测随机变量的连续性或离散性,HMM可分为连续HMM和离散HMM两种模型^[17-19]。由于本文以螺纹边缘的梯度方向差为观测对象,所以采用连续HMM。螺纹边缘点的分类如图8所示。




图8 边缘点类型

Fig. 8 Point types

HMM模型由5个部分组成:

1) 隐藏状态序列 根据梯度方向的不同,将螺纹边缘点分为3种隐藏状态:峰谷型、过渡型和直线型,记为 $m = \{m_1, m_2, m_3\}$ 。一般情况下,峰谷型点的梯度方向差值最大,过渡型点的梯度方向差值次之,直线型点的梯度方向差值最小。峰谷型的点可用于拟合螺纹的外径线和内径线,计算其外径;直线型的点用于拟合螺纹角的两边,以计算牙角参数;过渡型的点则用于剔除螺纹边缘上的弧线部

分,提高直线的拟合精度。隐藏状态的序列表示为 $S = \{s_1, s_2, \dots, s_i\}, s_i \in m_0$ 。

2) 观测序列 螺纹的梯度方向示意图,如图9所示。图9中像素点的颜色代表该点梯度方向,可以发现3种类型的边缘点梯度方向有明显差异。计算由AA R2Unet方法识别的边缘点梯度方向,记为 θ_i 。为消除螺纹零件放置角度引起的梯度方向变化,使得观测特征具有旋转不变性,本文将相邻边缘点的梯度方向取差值作为观测值,记为 a_i 。观测值计算公式为

$$S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, S_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}, \quad (3)$$

$$g_x(k) = S_x \times I(k), g_y(k) = S_y \times I(k), \quad (4)$$

$$\theta_i = \arctan \frac{g_y(k)}{g_x(k)}, \quad (5)$$

$$a_i = |\theta_i - \theta_{i-1}|, \quad (6)$$

其中: S_x 和 S_y 是Sobel算子在水平和垂直方向的梯度模板; I 为图像矩阵。




图9 梯度方向图

Fig. 9 Gradient direction

3) 初始概率分布 初始概率分布表示初始状态下每个隐藏状态出现的概率,记为 $\pi_i = P(s_1 = m_i)$ 。假设观测序列的样本量为 N ,且隐藏状态 s_i 出现的次数为 N_i ,则该隐藏状态的初始概率为 $\pi_i = N_i/N$ 。

4) 状态转移矩阵 状态转移矩阵表示当前隐藏状态 s_i 转移到下一个隐藏状态的概率。HMM隐藏状态的转移满足下面的马尔可夫性质:

$$P(s_{t+1} | s_t, s_{t-1}, \dots, s_1) = P(s_{t+1} | s_t), \quad (7)$$

即转换到下一个隐藏状态的概率仅取决于当前的隐藏状态。隐藏状态之间的转换由转换概率矩阵 \mathbf{A} 表示, 其中 α_{mm} 表示当前状态 m_i 转换到下一个状态 m_j 的概率。

$$\mathbf{A} = \begin{bmatrix} \alpha_{11} & \alpha_{12} & \cdots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \cdots & \alpha_{2m} \\ \vdots & \vdots & & \vdots \\ \alpha_{m1} & \alpha_{m2} & \cdots & \alpha_{mm} \end{bmatrix}. \quad (8)$$

HMM 状态转移图如图 10 所示。本文中, 每个隐藏状态都存在自转移, 且峰谷点和直线点之间没有直接的转移。



图 10 HMM 状态转移图

Fig. 10 HMM state transition diagram

5) 观测值发生概率 由于观测值 o_t 是一个连续型随机变量, 本文使用连续型隐马尔可夫模型来推断隐藏状态序列。本文假设对应相应隐藏状态的观测值遵循高斯分布, 其高斯密度函数的均值和方差如下:

$$\mu_i = \frac{1}{N_i} \sum_{t=1}^{N_i} a_i(t), \quad (9)$$

$$\sigma_i^2 = \frac{1}{N_i - 1} \sum_{t=1}^{N_i} (a_i(t) - \mu_i)^2, \quad (10)$$

式中, $a_i(t)$ 表示相应隐藏状态的样本数据。由于不同状态对应的高斯密度函数均值和方差不同, 样本数据在不同隐藏状态下出现的概率也各不相同。给定观测值的发生概率如下:

$$P(o_t | s_t) = \frac{1}{\sqrt{2\pi} \sigma_m} e^{-\frac{(o_t - \mu_m)^2}{2\sigma_m^2}}. \quad (11)$$

对于给定的 HMM 和观测序列 $O = \{o_1, o_2, \dots, o_t\}$, 我们需要推断出可能性最大的隐藏状态序列。为了寻找最优的隐藏状态序列 $S = \{s_1, s_2, \dots, s_t\}$, 本文使用 Viterbi 算法。在 Viterbi 算法中, 定义 $\delta_t(i)$ 为

对于给定观测序列的隐藏状态的最大概率, 并定义 $\psi_t(i)$ 为一个后向指针, 它记录了 Viterbi 路径上的状态。Viterbi 算法的递归可以描述如下:

初始化:

$$\delta_1(i) = P(o_1 | m_i) \cdot \pi_i, \psi_1(i) = 0. \quad (12)$$

递归:

$$\delta_t(i) = \max_{1 \leq j \leq m} (P(o_t | m_i) \alpha_{ji} \cdot \delta_{t-1}(j)), \quad (13)$$

$$\psi_t(i) = \arg \max_{1 \leq j \leq m} (P(o_t | m_i) \alpha_{ji} \cdot \delta_{t-1}(j)).$$

终止:

$$h_T = \arg \max_{1 \leq j \leq m} (\delta_T(i)), s_T = m_{h_T}. \quad (14)$$

回溯:

$$h_{t-1} = \psi_t(h_t), s_{t-1} = m_{h_{t-1}}. \quad (15)$$

本文使用 Viterbi 算法来推断每个点的隐藏状态, 并合并相同状态的相邻点, 然后拟合直线, 计算相应的螺纹参数。

3 实验结果与分析

本文搭建了图像采集平台, 如图 11 所示。该平台主要由远心图像采集装置和升降台两部分组成。同时, 针对不同类型螺纹的测量, 本文还设计了自动升降平台, 该升降台由载物台、步进电机、控制器、丝杆和直线导轨等部分组成。首先通过上文所述的 AA R2Unet 方法进行螺纹边缘粗提取, 进而得

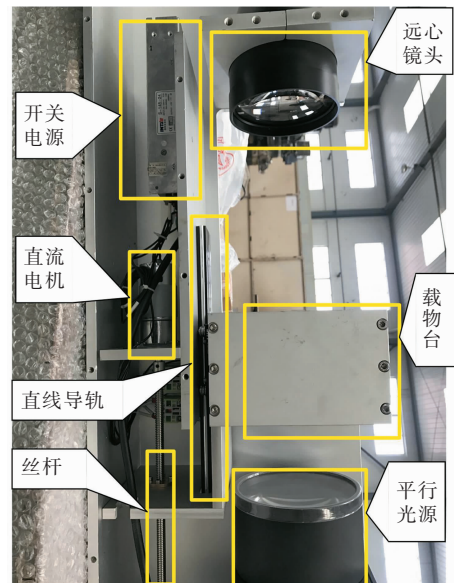


图 11 图像采集平台

Fig. 11 Optical platform

到大致的螺纹区域,再对螺纹区域进行梯度幅值分析,调整物体距离,以找到一个清晰度的极值,适应不同类型的螺纹工件,获得最清晰的图像。

此外,在精度方面还与同类型的测量装置基恩士轮廓测量仪 IM-7000 进行了横向对比。IM-7000 轮廓测量仪同样采用视觉测量的方式,测量视野为 125 mm × 125 mm,测量精度为±0.004 mm。

3.1 基于 AA R2Unet 的螺纹边缘点识别实验

本节实验主要包括了 AA R2Unet(Class Balanced loss)、AA R2Unet、Unet、R2Unet 这 4 种语义分割模型的评价指标对比,验证 AA R2Unet 模型相较于其他模型在分割精度上的优势和本文所添加的 Attention Augment 和 Class Balanced 损失函数对于 R2Unet 模型精度上的提升。后续对基于 AA R2Unet 螺纹提取方法的分割效果进行了展示。表 1 为多种语义分割网络的螺纹边缘点提取结果,通过对比可以发现:R2Unet 模型的实验结果比 Unet 优异;加入 Attention Augment 后 R2Unet 模型的预测精度得到了提升,交并比指标(即预测结果与标签并集与交集的比值,IOU)从原本的 93.54% 提升到 94.40%,再使用 Class Balanced loss 替换原先损失函数后,模型精度再次得到了提升,达到 95.92%。由此验证了本文提出的 AA R2Unet 提取螺纹边缘点的精度,同时证明了本文将 Class Balanced loss 与 Attention Augment 加入 R2Unet 模型,实际提升了其预测精度。

表 1 多种语义分割网络的螺纹边缘点提取结果对比

Tab. 1 Comparison of different semantic segmentation networks

方法	IOU/%
AA R2Unet (Class Balanced loss)	95.92
AA R2Unet	94.40
Unet	91.08
R2Unet	93.54

使用 AA R2Unet(Class Balanced loss)模型对不同类型的螺纹工件进行边缘提取,且选择不同位置和角度对螺纹零件进行识别。图 12 显示了螺纹边缘识别的结果,从左到右分别为原始图像、Canny 边缘检测图、本文模型提取结果图和标签。由于现场

环境复杂,输入子图像中存在许多干扰(如灰尘、铁屑、油污等),在 Canny 边缘检测图像中,可以清楚地看到这些干扰点被保留^[20],且由于没有做螺纹区域的截取,Canny 边缘检测图中还存在工件的非螺纹轮廓,这使得后续的螺纹边缘识别变得困难。与 Canny 边缘检测相比,本文模型预测图像消除了输入图像中的干扰点,准确地识别出了螺纹边缘。

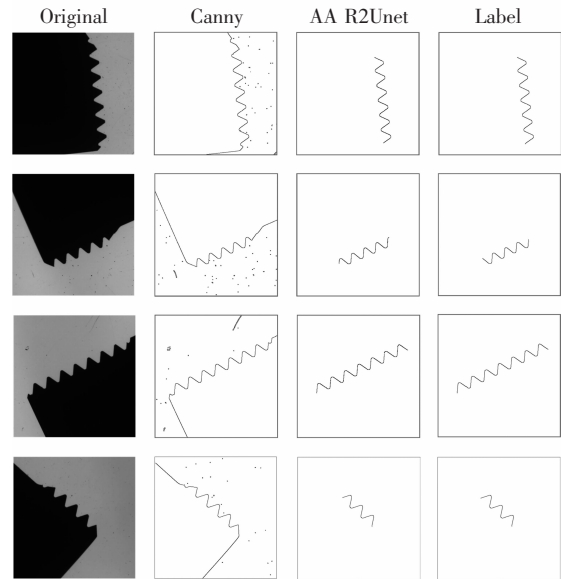


图 12 螺纹边缘识别结果

Fig. 12 Results of thread edge recognition

3.2 基于 HMM 的螺纹边缘点分类方法实验

为了测量外径和计算螺纹牙角的参数,需要在上述实验的基础上提取直线点和峰谷点。研究发现,螺纹边缘点的梯度方向与它的类型有关,直线型的螺纹点具有相似的梯度方向,而峰谷型的相邻点具有不同的梯度方向且差异较大。因此,本实验根据相邻点的梯度方向差值对螺纹边缘点进行分类。同时,在直线型和峰谷型之间增加过渡型来划分梯度方向差值变化不大的点,以此提升分类的精度。

在本实验中,利用基于隐马尔可夫模型的螺纹边缘点分类方法来划分螺纹的边缘点。分类与直线拟合效果如图 13 所示:用螺纹顶峰点拟合外径线,用低谷点拟合内径线,以此计算螺纹的外径;用直线拟合螺纹角两侧边缘直线,以计算螺纹角。本文将螺纹零件以不同的角度放置进行实验,以验证基于隐马尔可夫模型的螺纹边缘点分类方法的旋转不变性,同时以此计算螺纹参数以验证整体测量方法

的精度。表 2 显示了每种类型的分类准确率。

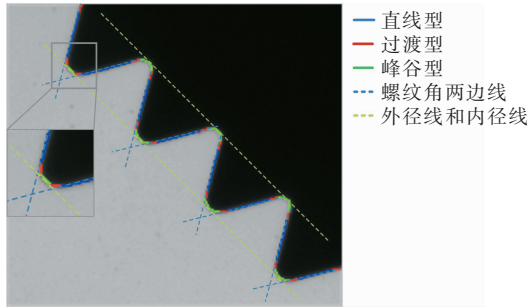


图 13 HMM 分类效果示意图

Fig. 13 HMM classification diagram

表 2 HMM 分类准确率

Tab. 2 HMM classification accuracy

类型	准确率/%
直线型	96.8
过渡型	86.7
峰谷型	93.3

从 HMM 分类结果图和分类准确率可以看出,基于 HMM 的螺纹边缘点分类方法取得了良好的效果。为了进一步验证本文方法的测量精度,我们依据 HMM 的分类结果,计算出螺纹的外径和牙角,并且进行了 200 个螺纹工件的测量精度实验,表 3~表 4 为从中抽取的部分实验数据,表 3 为螺纹外径对比数据,表 4 为螺纹牙角对比数据。经实验统计,本方法螺纹外径测量值误差在 0.01 mm 内,牙角误差在 0.6°以内,且从同类型 IM-7000 所检测的误差来看,本方法的精度也符合要求,且本文方法自动化程度更高,抗干扰能力更强。

表 3 螺纹外径参数

Tab. 3 Major diameter mm

序号	人工测量值	本文方法		IM-7000	
		测量值	误差	测量值	误差
1	13.867	13.865	-0.002	13.869	0.002
2	13.817	13.813	-0.004	13.814	-0.003
3	13.891	13.889	-0.002	13.887	-0.004
4	13.936	13.940	0.004	13.939	0.003
5	13.943	13.941	-0.002	13.940	-0.003
6	19.927	19.922	-0.005	19.931	0.004
7	19.887	19.886	-0.001	19.886	-0.001
8	19.837	19.839	0.002	19.832	-0.005

表 4 螺纹牙角参数

Tab. 4 Thread angle (°)

序号	人工测量值	本文方法		IM-7000	
		测量值	误差	测量值	误差
1	59.97	60.29	0.32	59.70	-0.27
2	60.50	61.10	0.60	60.47	-0.03
3	60.30	60.36	0.06	60.08	-0.22
4	59.09	59.07	-0.02	58.60	-0.49
5	59.93	60.34	0.41	59.47	-0.46
6	59.37	59.76	0.39	59.54	0.17
7	60.48	60.49	0.01	60.40	-0.08
8	59.39	59.78	0.39	59.44	0.05

4 结论

为了提高螺纹检测系统的自动化程度和鲁棒性,本文提出了基于 AA R2Unet 的螺纹边缘点识别方法和基于 HMM 的螺纹边缘点分类方法。首先,训练 AA R2Unet 网络用于提取螺纹边缘点;随后,建立了一个隐马尔可夫模型,计算相邻螺纹边缘点的梯度方向差值,并将其作为 HMM 的观察序列,得出边缘点分类;最后,根据 HMM 分类结果计算螺纹参数。

该方法的主要贡献在于两点:一是采用 AA R2Unet 进行螺纹边缘识别,省去了螺纹区域的标记过程,提高了检测过程的自动化程度,且在复杂的环境下仍然可以准确地提取螺纹边缘点;二是提出了一种基于隐马尔可夫模型的螺纹边缘点分类方法,降低了检测过程中螺纹零件的放置要求。结果表明,在复杂环境下,该方法可以实现螺纹参数的测量,外径测量精度在 0.01 mm 以内。

参考文献:

- [1] ZAWADA-TOMKIEWICZ A, WIERUCKA I. A case study in technological quality assurance of a metric screw thread [J]. Measurement, 2018, 114:208-217.
- [2] PRADHAN S U, ZHANG Y Y, LI J Y, et al. Tailored granule properties using 3D printed screw geometries in twin screw granulation[J]. Powder Technology, 2019, 341:75-84.
- [3] WANG W C, GUAN F N, MA S Y, et al. Measurement system of gear parameters based on machine vision[J]. Mea-

- surement and Control, 2015, 48(8):242-248.
- [4] 陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报, 2021, 47(5):1017-1034.
- [5] FARANA R, SIOMA A, SULIGA P, et al. A method of screw thread measurement using a 3D vision system[J]. Journal of Machine Construction and Maintenance, 2018(2):7-14.
- [6] GADELMAWLA E S. Computer vision algorithms for measurement and inspection of external screw threads[J]. Measurement, 2017, 100:36-49.
- [7] JOHNSON D K, BOTH A T R, ELS P S. Real-time side-slip angle measurements using digital image correlation[J]. Journal of Terramechanics, 2019, 81:35-42.
- [8] JING M, DU Y B. Flank angle measurement based on improved Sobel operator[J]. Manufacturing Letters, 2020, 25:44-49.
- [9] LEE Y C, YEH S S. Using machine vision to develop an on-machine thread measurement system for computer numerical control lathe machines[C]//Proceedings of the International MultiConference of Engineers and Computer Scientists, March 13-15, 2019, Hong Kong, China. Hong Kong: IMECS, 2019:1-6.
- [10] MIN J. Measurement method of screw thread geometric error based on machine vision[J]. Measurement and Control, 2018, 51(7/8):304-310.
- [11] 包能胜, 方海涛. 连续运动螺纹尺寸自适应机器视觉检测[J]. 计量学报, 2020, 41(9):1062-1069.
- [12] BELLO I, ZOPH B, LE Q, et al. Attention augmented convolutional networks[C]//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27 - November 2, 2019, Seoul, Korea (South). New York:IEEE Xplore, 2019:3285-3294.
- [13] YANG C Z, FANG L C, WEI H. Learning contour-based mid-level representation for shape classification[J]. IEEE Access, 2020, 8:157587-157601.
- [14] YU Z D, FENG C, LIU M Y, et al. CASNet: deep category-aware semantic edge detection[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York:IEEE Xplore, 2017:1761-1770.
- [15] WANG Y P, ZHAO X, LI Y, et al. Deep crisp boundaries: from boundaries to higher-level tasks[J]. IEEE Transactions on Image Processing, 2019, 28(3):1285-1298.
- [16] RABI M, AMROUCH M, MAHANI Z. Cursive arabic handwriting recognition system without explicit segmentation based on hidden Markov models[J/OL]. Journal of Data Mining & Digital Humanities, 2018[2021-03-01]. <https://hal.archives-ouvertes.fr/hal-01458216>.
- [17] JIANG Z H, CROOKES D, GREEN B D, et al. Context-aware mouse behavior recognition using hidden Markov models[J]. IEEE Transactions on Image Processing, 2019, 28(3):1133-1148.
- [18] CHEN Y K, YE J B, LI J. Aggregated Wasserstein distance and state registration for hidden Markov models[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(9):2133-2147.
- [19] RAHUL M, AGRAWAL R, KOHLI N. Layered recognition scheme for robust human facial expression recognition using modified hidden Markov model[J]. Journal of Multimedia Processing and Technologies, 2019, 10(1):18.
- [20] 史宝丽, 周亚美, 庞志峰. 各向异性全变分图像去噪算法[J]. 南通大学学报(自然科学版), 2019, 18(4):24-33.

(责任编辑:张燕)