

少量缺陷样本情形下医疗针管 刻度质量检测技术研究

严菲¹, 黄海燕², 谢致尧¹, 王晓栋¹

(1. 厦门理工学院 计算机与信息工程学院, 福建 厦门 361024;

2. 广州城市理工学院 计算机工程学院, 广州 510800)

摘要: 针对医疗针管刻度缺陷检测存在样本收集难且缺陷种类不确定的问题, 提出一种少量缺陷样本情形下的医疗针管刻度质量检测方法; 利用真实生产线上采集的大量正常样本, 训练深度刻度分割模型, 通过以针管像素分块为单位构建拉普拉斯矩阵来挖掘针管刻度间相关性, 并利用模糊 C 均值进行无监督缺陷检测; 实验结果表明, 针管刻度质量检测方法可 100% 检测出所有缺陷样本, 对提高医疗针管生产质量具有理论和实践应用价值。

关键词: 缺陷检测; 模糊聚类; 图像分割; 深度学习; 机器学习

Research on Quality Inspection Technology in Medical Syringe Scales with Limited Defective Samples

YAN Fei¹, HUANG Haiyan², XIE Zhiyao¹, WANG Xiaodong¹

(1. School of Computer and Information Engineering, Xiamen University of Technology, Xiamen 361024, China;

2. School of Computer Engineering, Guangzhou City University of Technology, Guangzhou 510800, China;)

Abstract: Aimed at the problems of difficulty in sample collection, and uncertainty of defect types in medical syringe scale defects, a syringe scale quality detection method for limited defective samples is proposed. The large normal samples collected from the actual production line are used to train the deep scale segmentation model. The syringe pixels are divided into blocks as the unit, the Laplacian matrix is constructed to mine their correlation, and the fuzzy C-means is used to carry out the unsupervised defect detection. Experimental results demonstrate that this syringe scale quality inspection method can detect all defective samples, with a precision of 100%, effectively enhancing the production quality of medical syringes.

Keywords: defect detection; fuzzy clustering; image segmentation; deep learning; machine learning

0 引言

医疗针管作为医疗领域中不可或缺的医疗器械, 其刻度准确与否直接关系到医疗质量和患者安全。在医疗针管的生产过程中, 由于制造设备或制造原料缺陷、操作人员失误等原因, 导致针管刻度可能存在缺陷, 给医疗领域带来潜在的风险。因此, 针管刻度缺陷检测在医疗针管生产过程成为不可或缺的一环^[1-3]。

早期的医疗针管刻度缺陷检测主要利用传统机器视觉技术提取手工构造类特征^[4], 如边缘、角点、纹理特征等, 以获取针管刻度的形态、大小、方向等信息。然而, 传统机器视觉检测技术对外界噪声干扰较为敏感, 如光照、背景变化等, 难以适应不同检测场景下的应用需求^[5], 需要

技术人员根据不同应用场景, 单独设计相应检测算法, 消耗大量的人力资源成本。

近年来, 随着深度学习技术的不断发展, 越来越多的研究人员开始尝试将深度学习技术应用于医疗产品缺陷检测中。凭借出色的特征自动学习能力和对复杂多变的外界噪声抗干扰能力, 深度学习技术取得了远超传统手工构造类检测技术的性能。如文献 [6] 提出一种两阶段表面缺陷检测方法, 第一阶段利用分割网络提取缺陷特征, 在第二阶段利用决策网络 (全连接网络) 完成缺陷的分类。与之类似, 文献 [7] 提出一种联合多类型损失函数和多分辨率特征图融合的两阶段缺陷检测技术, 并在金属表面裂纹缺陷检测应用中取得较好效果。文献 [8] 结合多种不同类型的卷积神经网络架构和迁移学习技术设计一种自动裂缝分

收稿日期: 2023-12-28; 修回日期: 2024-02-02。

基金项目: 国家自然科学基金项目 (U1805264); 厦门市科技计划项目 (3502Z20227073); 福建省自然科学基金项目 (2021J011186, 2023J011428); 福建省教育中青年项目 (JAT200486); 福厦泉自创区协同专项 (3502ZCQT2021009); 广州城市理工学院 2022 年度校级青年科研基金项目 (K0222006)。

作者简介: 严菲 (1985-), 女, 硕士生, 高级实验师。

通讯作者: 黄海燕 (1985-), 女, 实验师。

引用格式: 严菲, 黄海燕, 谢致尧, 等. 少量缺陷样本情形下医疗针管刻度质量检测技术研究[J]. 计算机测量与控制, 2024, 32(7): 70-76.

类方法。相较于传统的机器视觉技术,以上方法在多种场景下能取得较好的效果。但此类方法只能用于监督学习,需消耗大量人力资源成本。同时,在多工业缺陷检测应用场景中,由于数据隐私保护、采集难度大、工业生产环境多变等原因,很难收集充足缺陷样本,甚至训练样本。在此情形下,传统监督类学习方法很难在不同应用场景下取得较好效果,模型缺乏可扩展性。为解决以上监督类工业缺陷检测方法过度依赖缺陷样本的问题,文献[1]提出一种无缺陷样本下医疗针管缺陷检测技术,该方法结合了深度图像分割技术和传统机器视觉技术,可有效避免深度学习模型对于缺陷样本的依赖。但该方法在缺陷判断阶段仍需要借助大量手工构造类特征和人工先验知识。

尽管基于深度学习的缺陷检测技术在多种应用中取得了成功^[9-11],但该类技术依赖海量的训练数据^[12],或仍需借助人工经验判断缺陷种类,需耗费大量的人力物力。在医疗针管领域,缺陷样本难以收集且缺陷种类繁多,如直接将现有深度学习技术进行应用,难以取得理想效果。为解决此问题,设计了一种针对少量缺陷样本的医疗针管刻度质量检测方法。首先,该方法利用大量正常样本(无缺陷样本)训练深度针管刻度分割模型,以准确编码和提取针管刻度。然后,以针管像素分块为单位构建拉普拉斯矩阵来挖掘针管刻度间相关性。最后,利用模糊均值进行无监督缺陷检测。通过在真实生产线采集的针管数据检测结果表明,所提方法可100%检测出所有针管刻度缺陷样本,可有效确保医疗针管生产质量,进而证明了该方法的有效性和实用性。

1 系统结构及原理

如前文所述,本文旨在利用机器视觉技术自动检测医疗针管检测线上针管刻度中是否存在缺陷。其中,医疗针管检测线主要采用摄像头检测针管缺陷,具体组成部分如图1所示。从图中可以看出,该系统主要由摄像头、控制台、显示器、输送带、计算台和机柜组成。各组成部分的主要功能如下。

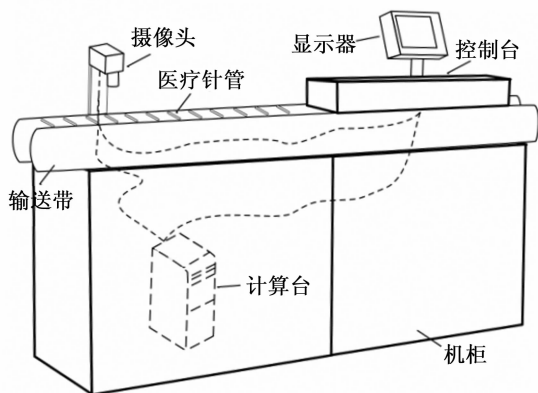


图1 医疗针管检测线示意图

输送带:负责将医疗针管平稳地从一个位置传输到另一个位置,以便后续检测、包装、分拣、存储等工序。

摄像头:位于输送带上,用于捕捉针管图像。这些图像可被实时传输至计算机系统中,用于进一步的分析和处理。

控制台:控制台是设备的操作中心,包含各种按钮、开关和指示灯,用于控制设备的运行状态。操作员可以通过控制台启动、停止设备,或者调整设备的运行参数。

显示器:位于控制台上方,用于显示摄像头捕捉到的针管图像或设备运行状态。

计算台:包含了处理摄像头捕捉到的图像的计算机系统。计算机会对图像进行分析,以检测针管是否存在缺陷。

机柜:机柜位于计算台下方,用于存放设备的电子元件和电源设备。旨在保护内部的设备免受外部环境的影响,如灰尘、湿气等。

检测系统工作流程为:当医疗针管随输送带到达摄像头正下方时,摄像头捕获针管图像,并将之传送至位于机柜中的计算台。计算台中运行有缺陷检测算法,经缺陷检测算法处理后的检测结果会被推送至控制台,控制台将检测结果显示在显示屏上,并根据检测结果中是否存在缺陷以控制生产设备运行状态。

2 医疗针管刻度质量检测方法

为精准地获取针管刻度缺陷,本小节将对针管刻度质量检测方法进行详细描述。该方法大致可分为图像预处理、刻度分割及特征提取和刻度聚类3个过程。首先,对获取的针管原始图像进行纠偏预处理,然后在完成处理后的图像上进行刻度分割,提取刻度特征。最后对刻度特征进行聚类完成质量检测。

2.1 针管图像纠偏处理

在医疗针管生产过程中,由于摄像机与医疗针管间存在一定拍摄角度、针管摆放位置不一等原因,拍摄的针管图像会存在不同程度的旋转、偏移等问题,将会增加后续针管刻度缺陷检测的难度。如图2(a)所示,可以看出图中针管管体与图像水平方向存在明显的偏转角,导致针管刻度也与图像垂直方向存在一定偏差。若直接将该图像应用于针管缺陷检测,则很难准确定位刻度和提取刻度特征。为解决此问题,结合针管特点(管体的两个长边平行),设计了简单快速的针管图像纠偏技术。该技术首先利用坎尼(canny)边缘检测算子提取针管图像边缘像素。然后,利用霍夫(hough)直线变换定位针管长边直线(上顶边)(图2(b)所示);最后计算所提取直线与图像y轴间的夹角作为针管偏转角。最后,根据旋转原图像得到最终矫正后图像(如图2(c)所示)。

2.2 刻度分割

刻度分割旨在利用大量无缺陷医疗针管样本训练深度分割模型,以提取针管刻度二值图像。由于针管缺陷检测过程中,摄像头易受到光照、反光、刻度变形等影响,直接利用传统图像处理技术提取针管刻度特征很难取得理想效果。为此,受深度缺陷检测技术启发^{[1][13]},引入深度学习技术分割针管刻度图像。参考文献[1],引入基于卷积神经网络的深度分割网络,其主要结构如图3所示。




图 2 针管图像纠偏处理示意图

如图 3 所示, 采用的深度学习模型主要包括主干子网络、分支子网络和融合子网络三部分。主干子网络旨在利用卷积神经网络提取图像中的局部特征, 共包含 2 个卷积池化块“CONV-BN-RELU-POOL”和 1 个卷积块“CONV-BN-RELU”, 其中 CONV 代表卷积层, BN 代表批归一化层, RELU 代表修正线性单位层, POOL 代表池化层, 共 11 层。常用的池化操作一般有最大池化和平均池化, 由于针管刻度相对细小, 若采用平均池化则其对局部区域取平均值的操作可能导致过多刻度特征被平滑掉, 导致刻度关键信息的丢失。为此, 池化层采用最大池化以尽量保留针管细微特征。分支子网络旨在融合主干子网络不同卷积块特征图。现有研究表明^[2], 深度卷积神经网络低层网络倾向于提取输入图像低阶语义特征, 如边缘、轮廓等, 而高层网络倾向于提取输入图像高阶语义特征, 如类别属性、簇等。为使分割网络有效融合针管刻度细节特征和高阶语义特征, 将不同卷积块输出作为分支子网络的输入, 以实现不同卷积层中不同粒度特征图的信息融合。考虑到不同特征图的分辨率间差异性, 利用反卷积操作将不同特征图还原至输入图像分辨率, 以方便下一阶段特征融合。最后, 融合子网络利用一个 1×1 卷积核融合分支子网络不同输出, 并借助二值化操作得到最终的预测结果。

在深度图像分割领域, 可选的损失函数一般有交叉熵损失 (cross-entropy loss)^[14]、dice 损失 (dice loss)^[15]、平衡交叉熵损失 (BCE, balanced cross-entropy)^[16] 等。考虑到在医疗针管图像中, 针管刻度在整个图像中所占比较小, 即前景像素 (针管刻度) 和背景像素存在严重不平衡问题, 采用 BCE 作为损失函数, 该损失函数的定义如式 (1) 所示:

$$BCE[P(i,j),G(i,j)] = \begin{cases} -\alpha \log(P(i,j)) & \text{if } G(i,j) = 1 \\ -(1-\alpha) \log[1-P(i,j)] & \text{otherwise} \end{cases} \quad (1)$$

其中: i, j 分别代表图像像素的横坐标和纵坐标, P




图 3 医疗针管刻度深度分割网络结构图

(i, j) 和 $G(i, j)$ 分别代表预测结果和标签结果中 (i, j) 位置的像素值, α 为平衡因子。通过设置合适的平衡因子 α , 会给前景像素和背景像素分配合适的权重值, 进而可引导深度分割网络更加关注前景像素。参照文献 [1], 将 α 设置为 0.6。

2.3 刻度特征提取

在采用深度分割模型获得医疗针管的二值化图像后, 需判断该医疗针管图像是否存在缺陷。由于针管缺陷一般较为细小, 如划痕、针管刻线缺失等, 很难直接在 2.2 小节中的分割结果上取得较好分析效果。通过观察针管刻度分割结果, 发现刻度像素一般呈现分块状态。若针管刻度中存在缺陷, 则会引起分割结果中分块面积和数量的变化。基于这一发现, 提出利用前景像素分块属性为处理对象的分析方法。具体而言, 给定分割后的图像, 首先利用图像连通域检测 (文中采用 8 连通域) 获取针管刻度的连通块, 然后计算像素块的外接矩形, 最后计算每一像素块的面积及其中心点坐标。利用以上以像素块为最小处理单元的分析方法, 有助于节约后续分析方法的处理时间, 提高分析效率。同时, 以上方法也有利于提高后续缺陷检测的可区分性, 进而能充分挖掘针管刻度中的结构缺陷, 如刻度线缺陷、多余刻度线等。

现有研究表明, 数据间的局部相关信息有利于提高模式识别的准确性和对数据结构的理解。为此, 将流形学习技术引入上述刻度像素分块中, 以进一步提取刻度间的深层语义。该方法主要分为相似图构建和特征向量提取两个阶段。相似图构建阶段主要用于根据像素块间的邻接关系捕捉其局部几何结构。特征向量提取阶段则是确定相似图低维嵌入特征, 在保留数据局部相关性基础上实现非线性降维。给定 n 张输入图像的像素块特征图 B_1, B_2, \dots, B_n , 其特征图的数据矩阵为 $\mathbf{X} = [B_1, B_2, \dots, B_n] \in R^{d \times n}$, 其中 d 代表图像像素数, 其相似矩阵 \mathbf{A} 构建如下:

$$\mathbf{A}_{ij} = \begin{cases} \cos(x_i, x_j) & x_j \in N_k(x_i) \\ 0 & \text{其它} \end{cases} \quad (2)$$

其中: $N_k(\cdot)$ 代表 k 近邻函数, $\cos(x_i, x_j)$ 代表 x_i 和 x_j 的余弦相似度。为提取图像的低维特征编码, 基于相似

矩阵 A 构建拉普拉斯矩阵 $L = D - A$, 其中 D 为对角矩阵, D 的第 i 个对角元素 $D_{ii} = \sum_j A_{ij}$, 然后计算拉普拉斯矩阵 L 的特征向量。为减少后续分析方法计算复杂度, 使用前 l 个非零特征值对应的特征向量作为针管像素块特征编码 $V \in R^{n \times l}$ (l 设置为 30)。以上算法具体执行过程如方法 1 所示。

方法 1: 医疗针管像素块特征编码

输入: n 张分割后的针管图像 I_1, I_2, \dots, I_n , 参数 k, l

输出: 针管像素块特征编码 V

1) 对于每张分割后的针管图像 I_i , 利用连通域检测技术获取所有连通块

2) 对于步骤 1 中检测出的每一连通块 b_j , 利用其外接矩形计算连通块的面积 s 和中心点坐标 c

3) 令 B_i 为与 I_i 具有相同大小的全零图, 对于步骤 2 中每一连通块 b_j 的连通块的面积 s_j 和中心点坐标 c_j , 令 $B_i(c_j) = s_j$

4) 利用公式 (2) 计算相似矩阵 A

5) 计算拉普拉斯矩阵 $L = D - A$, 其中 D 为对角矩阵, 其第 i 个对角元素 $D_{ii} = \sum_j \dots A_{ij}$

6) 计算拉普拉斯矩阵 L 的特征向量 e

7) 将特征向量 e 按其对应特征值大小进行升序排序, 其中前 l 个非零特征值对应的特征向量作为针管像素块特征编码 V 。

2.4 刻度聚类

由上文引言中所述, 医疗针管中的刻度缺陷样本稀疏且存在不确定性, 很难收集充足缺陷样本用于监督学习。为此, 引入聚类方法以实现实时无监督缺陷检测, 即将一定时间内采集到的针管图像划分为缺陷和非缺陷两个簇。常用的聚类方法有谱聚类^[17]、K 均值聚类^[18]和模糊聚类^[19]等。综合工业缺陷检测对于检测时效要求, 采用模糊 C 均值聚类方法^[20]。不同于传统 K 均值的“硬”聚类方式(某一样本只能隶属于一个簇), 模糊 C 均值方法引入了模糊因子, 使得任一样本可同时隶属于不同簇。此“软”聚类方式使得模糊聚类对噪声特征和样本更加鲁棒, 且能保留传统 K 均值的执行效率。式 (3) 为模糊 C 均值的目标函数:

$$\begin{aligned} \sum_{i=1}^n \sum_{j=1}^c u_{ij}^m \|x_i - v_j\|_2^2 \\ u_{ij} > 0, \\ \sum_{j=1}^c u_{ij} = 1 \end{aligned} \quad (3)$$

其中: $u_{ij} \in [0, 1]$ 为样本 i 隶属于类别 j 的隶属度, v_j 表示第 j 个簇的聚类中心, m 代表模糊因子, 通过调节该因子, 可有效控制一个数据样本同时隶属于多个类簇的程度, m 的值越大则一个数据样本可同时属于多个类簇, 否则越小(接近 1.0)则式 (3) 间退化为传统 K 均值, 即一个数据样本只能属于一个类簇(文中设置为 1.5)。

由于以上聚类过程中, 并未引入任何类别信息, 给刻度缺陷的判定带来挑战。考虑到实际工业可收集到极少量

缺陷针管样本和大量正常针管样本的特点, 为进一步提高聚类的准确度和可区分性, 设计了锚点聚类策略。首先收集少量(文中为 5 个)针管刻度缺陷样本 X_d 和若干(文中为 100 个)正常针管样本 X_g , 然后利用 2.2 小节中的深度分割模型求取缺陷样本的针管分割结果 B_d 和正常样本的分割结果 B_g , 最后将 B_d 、 B_g 与分割后待检测样本图像一起进行相似图构建、特征向量提取及聚类。聚类结果中若有样本与 B_d 同一簇则可视其为缺陷针管, 否则视为正常针管。

综上所述, 所设计的少量正样本(缺陷样本)情形下的医疗针管刻度缺陷检测方法如下。

方法 2: 少量正样本下针管刻度缺陷检测方法

输入: n 张针管图像(包括 X_d) O_1, O_2, \dots, O_n , 参数 α

输出: 缺陷检测结果 $F \in R^{n \times c}$

1) 对于每张针管图像 O_i , 利用 2.2 节的深度分割模型获得分割后的针管图像 I_i ;

2) 利用方法 1 获取每一 I_i 对应的针管像素块特征编码 V_i , 其中若 i 和 j 样本均属于缺陷样本, 则其对应的相似矩阵 $A_{ij} = 1$;

3) 求解公式 (3) 中的模糊聚类目标函数, 得到聚类结果 F , 其中与 X_d 属于同一族的为缺陷样本, 否则为正常样本。

3 实验结果与分析

为验证所提出方法有效性, 将其应用在真实的工业医疗针管生产线上收集的多组医疗针管图像进行实验。同时, 针对所提出方法进行了详细消融实验。

3.1 实验环境及参数设置

实验环境为 Ubuntu 18.04 LTS 操作系统, 配置为 Intel (R) Xeon (R) E5-2680 v3 @ 2.50 GHz CPU, 128 G 内存和 4 张 Nvidia TITAN X 显卡的服务器。图像分割模型采用 pytorch (torch 版本 1.6.0) 实现, 方法 1 中的连通域及外接矩形检测, 采用 opencv-python (4.4.0 版本) 实现。

采用文献 [1] 中的方式进行医疗针管图像深度分割模型的训练。具体而言, 在模型训练过程中, 采用水平翻转和垂直翻转作为数据增广的方法。模型共训练 300 个纪元 (epochs), 批处理大小为 2。初始学习率为 0.01, 并在第 50, 110, 180, 260 个纪元, 依次将学习率衰减 0.2。模型优化方法采用 Adam 算法。

3.2 数据描述

数据集收集过程及预处理方法参照文献 [1]。具体而言, 数据集共包含 1 205 张正常医疗针管图像。由于在医疗针管真实生产过程中, 缺陷样本出现的频率较低, 很难收集充足缺陷样本用于方法验证。为此, 在实际生产中采集的正常医疗针管图像基础上人工构造了 6 种缺陷图像, 分别是“刻度划痕”“长度异常”“多余刻度”“宽度异常”“刻度缺失”“其他异常”, 共包含 590 正常样本和 567 缺陷样本。部分缺陷样本如图 4 所示, 图中缺陷刻度已用虚线框标示出来。另外, 从正常样本中随机选取 100 张图像作为锚点负样本, 并从缺陷样本中随机选取 5 张图像作为锚

点正样本。原始采集的图像分辨率为 $1\,292 \times 964$ 且针管仅占整个图像的一小部分。为减少图像分割模型处理时间及减少非针管像素的影响,采用滑动窗方式(滑动窗口大小为 $1\,280 \times 360$)根据滑动窗中的像素值动态变化特性,定位针管并获取最佳感兴趣区域。最终将每一输入图像转换为分辨为 $1\,280 \times 360$ 且仅包含单一针管的图像。




图 4 部分缺陷样本

3.3 评估指标

为评估所提出方法有效性,采用准确度 (accuracy)^[21] 作为聚类性能评估指标,该评估指标的计算如公式 (4) 所示:

$$ACC = \frac{\sum_i^n \delta(s_i, \text{map}(r_i))}{n} \quad (4)$$

其中: n 代表样本数, $\text{map}(r_i)$ 为最佳匹配函数,该函数可将预测结果 r_i 映射到样本的最佳真实标签 s_i , $\delta(x, y)$ 函数定义如下:

$$\delta(x, y) = \begin{cases} 1 & x = y \\ 0 & x \neq y \end{cases} \quad (5)$$

ACC 值越大代表聚类性能越好。

3.4 检测结果与分析

所提出方法在医疗针管数据集下的缺陷检测结果如表 1 所示。从表中可以看出,该方法可成功将所有缺陷类型样本检测出来,且在正常样本取得了 80.40% 的检测准确率。

表 1 在医疗针管数据集下的缺陷检测结果

种类	缺陷样本						正常样本
样本数	99	87	90	93	108	85	490
失败数	99	87	90	93	108	85	96
ACC/%	100	100	100	100	100	100	80.40

图 5 为所提出方法两张错分类负样本针管样例图像。从图中可以看出,这两张错分类的图像主要是由于针管旋转角度过大,将部分针管刻度遮挡起来,导致刻度长度异常。对于所提出方法而言,该长度异常会导致所提取的刻度分块属性,如分块面积和分块中心点坐标,引入误差,进而导致错分类。虽然该方法在处理正常样本上还可能存在一定误检问题,但在缺陷样本上检测成功率为 100%,可以有效避免缺陷针管漏检问题,进而证明该方法可有效保障医疗针管生产的质量和安全生产需求。




图 5 两张错分类负样本针管样例图像

3.5 参数敏感性分析

所提出方法在医疗针管特征编码、聚类过程中涉及多种超参数,如近邻参数、聚类模糊因子 m 、特征向量数和锚点样本数等,本小节将详细分析这些参数的敏感性。表 2 为不同参数的最优设置。

表 2 最优参数设置

参数名称				
k	m	锚点(正样本)	锚点(负样本)	特征向量数
900	1.5	5	100	30

1) 近邻 k :

在医疗针管刻度特征提取过程中,所提出方法采用式 (2) 建立相似矩阵,其中引入近邻控制余弦相似度的计算范围。对某一样本而言, k 的值越大,会有更多该样本的邻近样本被纳入计算中。为探索最佳 k 值,依照文献 [17-18] 中的策略,固定除 k 以外的其他参数值,并采用网络搜索的方式研究模型对于不同 k 的性能差异。参数 k 搜索范围为 [1, 10, 50, 100, 200, ..., 900, 1 000, 1 100], 其余参数按表 2 设置,实验结果如图 6 (a) 所示。如图所示,当 k 值小于 900 时,其相似图计算不够准确,导致检测性能差。反之,当 k 值大于 900,其相似度计算过程中会引入较多非相关的噪声样本,进而影响检测性能。因此,在 $k=900$ 时检测效果最佳。

2) 聚类模糊因子 m :

所提出方法借助模糊 C 均值对未知医疗针管样本聚类,引入模糊因子 m 以控制样本隶属于不同类簇的程度。 m 值越大,样本隶属于不同类簇的概率越接近,否则 m 值越小,样本趋向于只隶属不同类簇中的一个。为验证 m 的重要性,参考文献 [18],仍然采用网络搜索方法寻找其最优值。然而,由于 m 的可取值范围为 $(1, \infty]$,很难精细化扫描所有 m 的值。为此,引入“大步长一小步长”相结合的方式解决这一问题。具体而言,先以大的搜索步长(文中设置为 2)根据聚类性能变化确定 m 的大致范围,再利用小的步长(文中设置为 [0.1, 0.5])定 m 较精确的数值。在确定 m 的大致范围后,将 m 的精细搜索范围设为 [1.1, 1.2, ..., 1.9, 2.0, 2.5, 3.0, ..., 4.5, 5.0]。

图 6 (b) 给出了不同 m 值所对应的聚类性能。如图所示,当 m 值较小时(如 $m=1.1$),聚类性能较低。这可能




图 6 参数敏感性分析

由于 m 值过小会导致样本只能隶属于类簇中的一个, 导致某些处于不同类簇边界的样本过早被错分类。随着 m 值不断增加, 聚类模型对样本属于不同类簇的隶属度更加包容, 使其拥有更多机会调整处于类簇边界的样本, 进而取得较好性能。随着 m 取值不断增大, 聚类模型将逐渐削弱每一样本间差异, 即认为每一样本均等地属于每一个类簇, 丢失其对样本的可区分性, 进而降低降类性能。在 $m = 1.5$ 时, 取得最优聚类性能。

3) 特征向量数量影响:

论文通过计算拉普拉斯矩阵的前 l 个特征向量, 以提取数据内在相关性, 并减少聚类分析复杂度。为验证特征向量数量 l 对聚类的作用, 设置 l 的搜索范围为 $[10, 20, \dots, 100, 200, \dots, 400, 500]$, 其对聚类性能的影响如图 6 (c) 所示。可以看出, 若 l 设置过小 (如 $l = 10$), 则聚类性能较差。这可能是过小的 l 不足以构建具有可区分性的特征导致聚类性能差。反之, 若 l 设置过大 (如 $l = 500$), 则所构建的图中包含过多冗余特征, 同样会降低聚类性能。当 $l = 30$ 时, 聚类方法性能最佳。

4) 锚点样本数影响:

论文使用锚点样本来提高缺陷检测的准确度。锚点样本分为正样本 (缺陷样本) 和负样本 (正常样本)。由于在医疗针管工业生产过程中, 很难收集充分的缺陷样本, 因此, 引入 p 个 ($0 \leq p \leq 5$) 锚点正样本和 q 个 ($10 \leq q \leq 100$) 锚点负样本来测试锚点样本对聚类性能的影响。具体而言, 从 5 个正样本中随机选取 p 个样本和从负样本中随机选取 q 个样本, 分别作为锚点正样本和锚点负样本。

从图 7 可看出, 当将锚点正样本和负样本加入相似矩阵构造过程后, ACC 随着锚点样本数增加逐渐增加, 进而证明了引入锚点样本策略的确有助于提高聚类性能, 进而证明该策略的有效性。另外也可发现, 当锚点负样本数增长至接近 100 张时, 聚类性能将接近平缓。这可能是由于正样本中的缺陷各异, 增加较多缺陷样本可提高聚类模型的可区分能力。但锚点负样本间的可区别性较小, 当其数量超过 100 时, 对聚类模型的可区分力提升有限, 而过多训练样本的增加势必增大模型检测的计算复杂度。因此, 结合工业医疗缺陷检测对于检测性能和检测时效的需求,

锚点正样本数设置为 5, 为锚点负样本数设置为 100。




图 7 锚点样本影响分析

4 结束语

针对医疗针管刻度缺陷检测的问题, 提出了一种基于深度学习和模糊聚类且仅需少量缺陷样本的检测方法。该方法利用大量正常样本训练深度刻度分割模型, 可借助像素分块挖掘针管刻度间相关性, 并利用模糊均值进行无监督缺陷检测。在真实针管数据上的检测结果表明, 所提方法成功检测出所有缺陷样本, 能够满足实际应用需求。在未来的研究中, 将引入更多可区分性特征学习技术, 如多视图学习, 以进一步提高正常样本的检测准确度。

参考文献:

- [1] WANG X, XU X, WANG Y, et al. A robust defect detection method for syringe scale without positive samples [J]. *Visual Computer*, 2023, 39 (11): 5451–5467.
- [2] 罗东亮, 蔡雨萱, 杨子豪, 等. 工业缺陷检测深度学习方法综述 [J]. *中国科学: 信息科学*, 2022, 52 (6): 1002–1039.
- [3] CASTELLANOS M. M, et al. CMC strategies and advanced technologies for vaccine development to boost acceleration and pandemic preparedness [J]. *Vaccines*, 2023, 11 (7): 1153.
- [4] BULNES F G, USAMENTIAGA R, GARCIA D F, et al. An efficient method for defect detection during the manufacturing of web materials [J]. *Journal of Intelligent Manufacturing*, 2016, 27 (2): 431–445.
- [5] XU L, LV S, DENG Y, et al. A weakly supervised surface defect detection based on convolutional neural network [J]. *IEEE Access*, 2020, 8: 42285–42296.
- [6] TABERNIK D, Šela S, Skvarč J, et al. Segmentation-based deep-learning approach for surface-defect detection [J]. *Journal of Intelligent Manufacturing*, 2020, 31 (3): 759–776.
- [7] WANG X, WANG Y, XU X, et al. Two-stage deep neural network with joint loss and multi-level representations for defect detection [J]. *Journal of Electron Imaging*, 2022, 31: 063060.
- [8] DAIS D, BALÍ E, SMYROU E, et al. Automatic crack classification and segmentation on masonry surfaces using convolutional neural networks and transfer learning [J]. *Automation in Construction*, 2021, 125: 103606.
- [9] 赵红颖, 于微波. 计算机视觉技术在发动机缺陷检测系统中的应用 [J]. *光学精密工程*, 2000, 8 (3): 283–286.
- [10] 李彬, 汪诚, 吴静, 等. 改进 YOLOv4 算法的航空发动机部件表面缺陷检测 [J]. *激光与光电子学进展*, 2021, 50 (7): 109–113.
- [11] 张晓晓, 邓承志, 吴朝明, 等. 基于改进 YOLOv4 的磁瓦缺陷检测算法 [J]. *计算机科学*, 2023, 50 (11): 389–395.
- [12] 吕承侃, 沈飞, 张正涛, 等. 图像异常检测研究现状综述 [J]. *自动化学报*, 2022, 48 (6): 1402–1422.
- [13] YANG D, CHEN N, TANG Q, et al. Research on defect detection of toy sets based on an improved U-Net [J/OL]. *Visual Computer*, 2023, 5. <https://doi.org/10.1007/s00371-023-02834-w>.
- [14] FENG L, SHU S, LIN Z, et al. Can cross entropy loss be robust to label noise? [C] //California: International Joint Conferences on Artificial Intelligence Organization, 2020: 2206–2212.
- [15] ZHAO R. Rethinking dice loss for medical image segmentation [C] //Sorrento, Italy, 2020 IEEE International Conference on Data Mining, 2020: 851–860.
- [16] CUI Y, JIA M, LIN T Y, et al. Class-Balanced Loss Based on Effective Number of Samples [C] //Long Beach, CA, 2019 IEEE Conference on Computer Vision and Pattern Recognition, 2019: 9260–9269.
- [17] ZENG Z, WANG X, YAN F, et al. Local adaptive learning for semi-supervised feature selection with group sparsity [J]. *Knowledge Based System*, 2019, 181: 104787.
- [18] WANG X-D, CHEN R C, YAN F, et al. Fast adaptive k-means subspace clustering for high-dimensional data [J]. *IEEE Access*, 2019, 7: 42639–42651.
- [19] ZHANG R, LI X, ZHANG H, et al. Deep fuzzy k-means with adaptive loss and entropy regularization [J]. *IEEE Transactions on Fuzzy Systems*, 2020, 28 (11): 2814–2824.
- [20] BEZDEK J C, EHRlich R, FULL W. FCM: The fuzzy c-means clustering algorithm [J]. *Computer&Geosciences*, 1984, 10 (2): 191–203.
- [21] WANG J, MA Z, NIE F, et al. Entropy regularization for unsupervised clustering with adaptive neighbors [J]. *Pattern Recognition*, 2022, 125: 108517.
- [5] 刘瑞杰. 姿态高动态北斗接收机跟踪环路的设计与实现 [D]. 天津: 中国民航大学, 2016.
- [6] 张嵇, 赵洁, 于世杰, 等. 高动态旋转载体双天线卫星定位接收系统设计 [J]. *信息技术与信息化*, 2020 (6): 123–125.
- [7] 赵梓超. 旋转多模 GNSS 双天线紧组合信息处理平台的设计与实现 [D]. 南京: 东南大学, 2021.
- [8] 袁赫良, 金天, 曲家庆, 等. 旋转条件下非连续卫星导航信号处理技术 [J]. *系统工程与电子技术*, 2021, 43 (9): 2573–2580.
- [9] 王文虎, 高敏, 王毅, 等. 高旋转卫星导航接收机半实物仿真 [J]. *计算机测量与控制*, 2018, 26 (6): 252–256.
- [10] 莫明岗. 旋转制导炮弹用惯性导航系统空中对准方法研究 [D]. 哈尔滨: 哈尔滨工业大学.
- [11] 龚如. 单天线旋转非连续接收条件卫星导航定位方法研究 [D]. 北京: 北京理工大学, 2016.
- [12] 陈跃鹏, 李东光, 杨士义. MIMU 辅助旋转弹丸 GPS 接收机跟踪环路设计 [J]. *中北大学学报 (自然科学版)*, 2010, 31 (2): 173–177.
- [13] 姚长虹, 尹勇, 齐建中. 基于卫星导航系统的导弹姿态测量算法研究 [J]. *航空兵器*, 2017 (3): 13–19.
- [14] 刘旭东, 赵军祥. 旋转载体多天线对 GPS 卫星可见性分析 [J]. *全球定位系统*, 2009, 34 (5): 11–14.
- [15] 杨东凯, 张飞舟, 张波. 软件定义网络的 GPS 和伽利略接收机 [M]. 北京: 国防工业出版社, 2009: 34–60.
- [16] 刘阳. 旋转双天线北斗/MIMU 组合系统关键技术研究 [D]. 南京: 东南大学, 2020.
- [17] LUO J, VANDER V E W, TSENG H W, et al. Single antenna GPS measurement of roll rate and roll angle of spinning platform [P]. U. S.: US949660 (B2), 2016–8–30.
- [18] 韩吉南. 卫星导航接收机载波捕获与跟踪环路关键技术研究 [D]. 哈尔滨: 哈尔滨工程大学, 2017.
- [19] 李耀军, 张江华, 费涛, 等. 基于单天线 GPS 载波幅度的旋转载体滚转角测量 [J]. *火控雷达技术*, 2014, 43 (3): 6–11.
- [20] 曾广裕. 非全向天线旋转条件下导航方法及滚转姿态检测技术 [D]. 北京: 北京理工大学, 2015.

(上接第 69 页)