

基于计算机视觉的点刺标注与检测

罗思言¹, 吴豆豆², 刘茜玮², 王心舟³, 饶向荣¹

1. 中国中医科学院广安门医院肾病科, 北京 100053; 2. 北京中医药大学中日友好临床医学院皮肤科, 北京 100029; 3. 同济大学电子与信息工程学院, 上海 201804

【摘要】目的:智能化地识别点刺在舌体不同区域的分布情况。**方法:**首先利用 LoG 算子对舌体图像进行卷积运算, 对舌体上的斑点进行初步检测; 随后利用人工交互的方式微调点刺标注, 并训练卷积神经网络模型 Fast-RCNN。**结果:**将同一舌象仪采集的 240 张图像作为训练集, 60 张图像作为测试集, 达到了 90.78% 的召回率, 优于已有的方法。**结论:**本文提出的数据预标注与人工微调方法将细粒度的点刺标注变为可能。在精确到点刺个体的数据集基础之上, 本文引入卷积神经网络进行亚像素级的点刺分布检测, 其结果可为中医临床诊断提供客观化、量化、自动化的参考依据。

【关键词】机器视觉; 深度学习; 中医舌诊; 点刺检测

【中图分类号】R318; TP183

【文献标志码】A

【文章编号】1005-202X(2023)02-0238-06

Labeling and detection of tongue spots based on computer vision

LUO Siyan¹, WU Doudou², LIU Qianwei², WANG Xinzhou³, RAO Xiangrong¹

1. Department of Nephrology, Guang'anmen Hospital, China Academy of Chinese Medical Sciences, Beijing 100053, China; 2. Department of Dermatology, China-Japan Friendship Hospital, Beijing University of Chinese Medicine, Beijing 100029, China; 3. College of Electronic and Information Engineering, Tongji University, Shanghai 201804, China

Abstract: Objective To identify the distribution of spots in different areas of tongue intelligently. **Methods** After the initial detection of tongue spots by convolving the tongue image with LoG operator, the labeling of spots were fine-tuned by human interaction, and the convolutional neural network model (Fast-RCNN) was trained with the labeled dataset. **Results** With the 240 images collected by the instrument for tongue image as training set and 60 images as test set, a recall rate of 90.78% was obtained, indicating that the proposed method was superior to the existing methods. **Conclusion** The data pre-labeling and manual fine-tuning method proposed in the study makes it possible to label fine-grained spots. Based on the dataset accurate to a spot, convolutional neural network is introduced to detect the spot distribution at sub-pixel level, and the results can provide objective, quantitative and automatic reference for clinical diagnosis of traditional Chinese medicine.

Keywords: machine vision; deep learning; tongue diagnosis; spot detection

前言

舌诊的客观化、量化和精准化研究是中医现代化进程中重要的一环^[1-3]。传统的人工舌诊基于医师对各类舌象的主观判断, 且容易受到照明等外部条件的影响^[4]。而随着近年来计算机视觉技术与深度学习技术的发展, 舌诊的智能化、客观化与自动化正在成为中医现代化领域的研究方向^[5-7]。如杨佳欣

等^[8]结合 Graham 扫描法与道格拉斯-普克点抽稀算法综合分析齿痕数量与齿痕深度, 并在此基础上对齿痕程度进行量化判别。李宗润等^[9]通过引入深度学习模型 U-Net^[10]与 DeeplabV3^[11], 在标准化舌象数据集上进行舌体分割训练, 取得了 91% 的交并比准确度。点刺舌, 中医基础舌象之一, 主要特征为舌上可见大量的红刺, 表明人体血分热或脏腑热。中医评估病情严重程度与点刺的颜色和数量密切相关, 病变脏腑又与点刺分布位置有关。相较于齿痕等特征, 点刺尺寸小、数目多、颜色与舌体相似、形态与淤点相近, 因此点刺识别是一项颇具挑战性的任务。

基于传统计算机视觉的点刺识别技术聚焦于手工设计特征提取器, 对舌体进行特征提取, 随后引入

【收稿日期】2022-10-18

【基金项目】国家自然科学基金(81973683)

【作者简介】罗思言, 硕士研究生, 研究方向: 中西医结合, E-mail: luosiyan8888@163.com

【通信作者】饶向荣, 主任医师, 教授, 研究方向: 中西医结合, E-mail: raoyisheng@163.com

分类算法对特征进行分析^[12]。王昇等^[13]提出了两段式点刺检测流程,首先将舌象灰度图以不同阈值二值化,提取斑点数量、颜色、尺寸、位置等信息,并利用支持向量机(Support Vector Machine, SVM)^[14]及K-means对点刺和淤点进行分类识别。王学民等^[15]从物体显色原理上优化数据库建立流程,将不同光源下采集的舌象数据进行配准与对齐,采用LoG(Laplacian of Gaussian)算子和平行线算法进行点刺识别。何苗等^[16]利用图形学中的Gabor小波纹理分析,对点刺特征进行初步提取,最后利用聚类算法对点刺进行分类。利用传统计算机视觉进行点刺识别的方法对成像条件较为敏感,且数据预处理流程,如校色、对比度调整等也会影响算法的准确性^[17]。此外,人为对算法各项参数进行干预不但会使得整个流程繁琐,而且也在一定程度上引入了主观偏好,这与客观化的要求相冲突。

为解决上述问题,本文将传统计算机视觉的点刺检测算法与深度学习中的卷积神经网络算法相融合。考虑到传统计算机视觉无需数据标注的特点,首先利用LoG算子对分割后的舌体图像进行卷积运算,初步提取出舌象数据集的点刺分布^[17];随后采用人工交互的方式对点刺标注进行微调;最后在标注的数据集上对深度学习模型Fast-RCNN进行训练。相较于传统算法,本文提出的模型更具鲁棒性,解决了传统算法容易在特定设备及特定采集条件下过拟合的问题,也为后续其他深度学习模型的应用和其他下游任务的进行提供了前提条件。

1 实验方法

本文所提出的算法流程如图1所示,主要有2个模块:(1)基于传统机器视觉的LoG边缘检测算子。利用LoG算子对分割后的舌象图像进行边缘特征提取,识别出舌体上的斑点区域,随后人工对标注结果进行微调得到点刺的精确标注;(2)基于深度学习的卷积神经网络模型Fast-RCNN。将点刺的精确标注作为神经网络的训练集训练区域卷积神经网络(Region-based Convolutional Neural Network, RCNN),可得到稳健的点刺识别模型。此时将训练集中未出现过的舌象图像作为测试集,发现该点刺检测算法具备良好的泛化性能。

1.1 舌象数据集

本文采用的舌象数据集包含300张专业舌象仪采集的768×576像素舌象图像^[18](图2)。图像采集过程中患者将面部以标准姿势放入半封闭的暗箱内,通过内部日光色光源及摄影设备得到标准化的舌象图像。随后4位志愿者在Labelme平台上分别

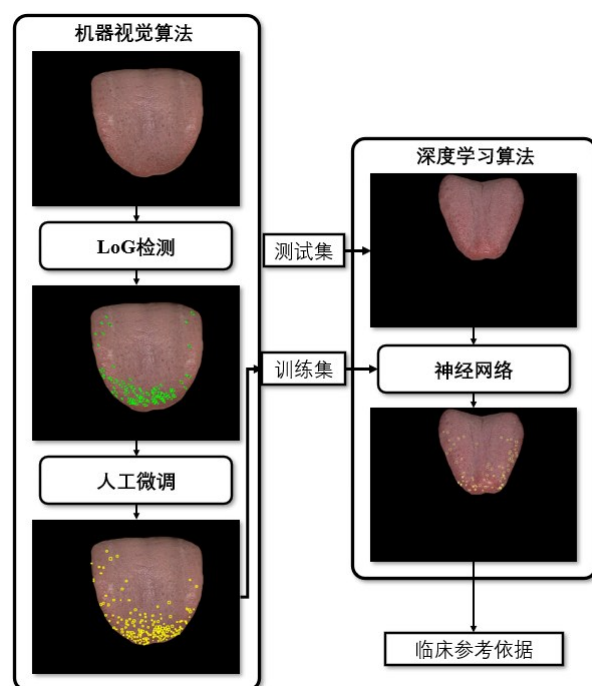


图1 点刺识别流程

Figure 1 Spot detection process

对舌体轮廓以多边形的形式进行细粒度的分割,并选出最佳结果^[19]。通过标准化流程将图像映射到标准正态分布上,作为后续算法的训练及测试样本。由于图像采集的照明条件、相机内参外参、快门速度、感光度等都以统一标准进行,因此无需进行图像校色或配准。此外,考虑到图像中大部分点刺尺寸分布在5×5像素左右,不利于对其进行检测,因此采用BiCubic插值算法将图像上采样到1536×152像素^[20],其插值公式如下:

$$S(x) = \begin{cases} 1 - 2|x|^2 + |x|^3, & 0 \leq |x| < 1 \\ 8|x| + 5|x|^2 - |x|^3, & 1 \leq |x| < 2 \\ 0, & |x| \geq 2 \end{cases} \quad (1)$$

1.2 点刺形态学特征与临床意义

现代医学认为舌上点刺的产生与蕈状乳头的肿胀增生凸起以及丝状乳头的萎缩减少有关,其中蕈状乳头肿胀增生及丝状乳头的萎缩减少的外在表现被中医称之为点,而蕈状乳头密集增大凸起被称之为刺,两者通常同时出现,此类舌象被称之为点刺舌。点刺舌是中医舌诊里面的基础舌象之一,多提示脏腑热盛或血分热极,如《辨舌指南》中所云“若红舌中更有点如虫碎之状者,热毒炽甚也”。点刺分布位置、颜色、数量都具有临床意义。从位置而言,舌尖与心相关,舌边与肝胆相关,舌中与胃肠相关。从颜色而言,可再细分为色鲜红与绛紫。点刺颜色鲜红多为内热炽甚或阴虚火旺,而色绛紫意味着热入营血且气血阻滞,病情较重。从数量而言,点刺越多,热邪越盛。在人工智能辅助中医

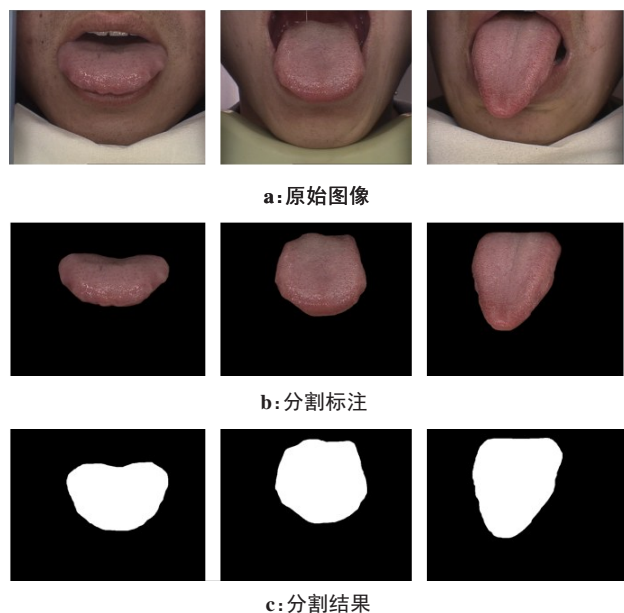


图2 舌象数据集
Figure 2 Tongue image dataset

舌诊领域,相较于舌体上裂纹、齿痕等特征,点刺尺度更小、分布更广、数量更多,因此其检测更为困难。但从辅助临床诊断来说,点刺的分布位置、数目、颜色等信息能为中医临床诊断的精准化、客观化提供有力的参考依据。

1.3 LoG点刺检测与筛选

在图形学中斑点被定义为数字图像中特征与周围临近区域有显著差异的区域,如黑暗区域中的亮斑或红色区域中黑点;同时斑点内部特征也应保证具有统一性。界定斑点的属性选取直接决定了斑点检测的结果。对于点刺来说,其与舌体背景之间最大的区别在于颜色,因此将RGB图像转化为灰度图进行检测,基于人眼色彩感知的灰度转换公式如下:

$$\text{Grey} = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (2)$$

LoG算子^[21],也称为高斯-拉普拉斯算子,是一种基于拉普拉斯算子求导的微分边缘检测器。拉普拉斯算子可用于求解多元函数的二阶导数,其定义如下:

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (3)$$

通过求解图像RGB值的二阶导数可以检测出颜色变化较为剧烈的像素,此即为不同区域的边界处。考虑到实际图像中存在噪点,若直接求取二阶导数,则结果极易受到噪声的干扰而形成伪边界,因此引入高斯函数对其进行平滑滤波。二维高斯分布如下所示:

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (4)$$

其中, σ 表示高斯分布的方差,在LoG边缘检测算法中 σ 控制了所检测斑点的尺寸。利用高斯平滑函数对图像进行滤波,再求取其二阶导数,结果如下:

$$\nabla^2(G(x, y, \sigma) \otimes f(x, y)) = \frac{1}{\pi\sigma^4} \left(\frac{x^2 + y^2}{2\sigma^2} - 1 \right) \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \otimes f(x, y) \quad (5)$$

其中, \otimes 为卷积运算符。计算舌象图像RGB空间中的LoG响应值,并遍历空间中的每一个像素点,若该像素点的值为邻域中极大(极小)值,则该点被识别为点刺。

利用上述算法检测出的舌体斑点不仅包含点刺,还包含了淤点、裂纹附近的凹陷点等。为初步对上述干扰点进行筛选,本文引入了颜色、面积、圆度和惯性比对识别出的斑点进行选择,其中色差为斑点平均RGB值与人工采样的50个点刺RGB平均值的欧氏距离;圆度约束了斑点接近于圆的程度;惯性比约束了斑点最短轴与最长轴之比。通过上述流程可初步识别出舌体上的点刺区域,但该方法对照明条件较为敏感,且未利用点刺的位置、点刺周边像素语义等高级信息。

1.4 基于深度学习的点刺检测

为综合分析图像中点刺的颜色、形状等低级特征及点刺的相对位置、周边像素语义信息等高级特征,本文引入深度学习模型Fast-RCNN对点刺进行更加细粒度的检测^[22]。对于深度学习模型来说,其核心问题是数据集的建立,将深度学习模型引入点刺检测领域的最大阻碍便是数据集的标注。点刺舌图像上的点刺数量往往有上百个,若以矩形Bounding-box对每个点刺进行位置标注,则需要耗费大量时间。本文通过上述传统机器视觉方法与人工交互相结合的方式,快速构建出了训练所需数据库,并在此基础上对神经网络进行训练。

Fast-RCNN主要由特征提取网络、RoI池化层及多层感知机(Multilayer Perceptron, MLP)组成,如图3所示。首先利用以ResNet架构为基础的特征提取器^[23],将舌象从高维的RGB空间映射到低维的特征空间。该过程利用先验知识对图像信息进行压缩,得到的特征向量表征了原始图像的高级属性。随后利用Region Proposal技术生成一系列候选检测框(Region of Interest, RoI)^[24],并将尺寸各异的候选框输入RoI池化层当中,映射出其在特征图中尺寸一致的特征向量。最后将候选框特征向量送入由多层感知器构成的分类器和回归器当中,分类器负责预测候选框中物体存在的概率,回归器负责对候选框的尺寸及位置进行进一步修正。

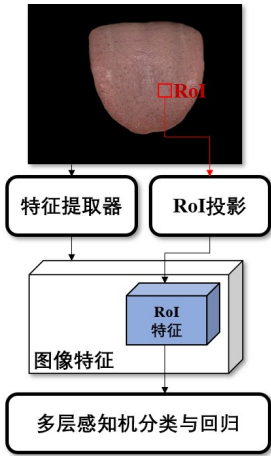


图3 点刺检测网络结构
Figure 3 Structure of spot detection network

2 实验结果

2.1 实验平台

LoG 斑点检测模型的实现采用了 Scikit-learn (<https://scikit-learn.org/stable>) 机器学习工具库中的 image 模块;人工交互使用了麻省理工学院开发的 LabelMe (<http://labelme.csail.mit.edu>) 计算机视觉标注工具;而深度学习模型的实现采用了香港中文大学多媒体实验室的开源计算机视觉框架 OpenMMLab (<https://github.com/open-mmlab/mmdetection>) 中的目标检测模块。该框架采用模块化设计,使用者不介入模型底层实施细节便可探索不同骨干网络与检测器在特定任务下的精度。LoG 斑点检测及 RCNN 的训练、测试均在安装 Ubuntu 18.04.1 LTS 操作系统的远程服务器上进行。该远程服务器 CPU 为 Intel(R) Xeon(R) Gold 6240 CPU @ 2.60 GHz; GPU 为 4 张 NVIDIA RTX3090;内存为 256 GB。

2.2 实施细节

舌象仪采集的原始数据为 bmp 格式的 RGB 图像,图像中除了舌体外,还包括患者的部分面部以及舌象仪内部场景。对于深度学习模型来说,这些无关信息并不会对识别精度产生太大影响,但对于基于传统机器视觉的 LoG 斑点检测算法来说,除了舌体上的斑点外,人面部以及周围环境固有的或因噪声产生的斑点也会被识别在内。因此本文首先利用数据集已有的标注,将舌体单独分割出来送入 LoG 斑点检测算法进行识别。并利用颜色、面积、圆度和惯性比将淤点、裂纹附近的凹陷点等斑点滤除,只留下所需的点刺标注,参数设置如表 1 所示。

利用 LoG 初步检测出舌体上的点刺之后,再以人工交互的方式在 LabelMe 平台上对检测结果进行

表 1 点刺筛选条件
Table 1 Screening conditions for spots

筛选参数	筛选条件
色差	$D(x, y) < 30$
面积	$< 40 \text{ pixels}$
圆度	> 0.8
惯性比	> 0.8

微调。每一张照片上的点刺由一位具有执业医师资格的志愿者进行微调,并由另一位志愿者在保持点刺的评判指标与标注用显示器一致的情况下进行校验。随后将标注结果作为标签构成深度学习模型的训练集和测试集。此外,本文还引入微软常见物体数据集 (Microsoft Common Objects in Context, MS COCO)^[25]对网络模型进行预训练。

深度学习模型采用计算机视觉领域常用的预训练-微调范式,首先在 MS COCO 数据集上对 Fast-RCNN 进行预训练。MS COCO 数据集由超过 30 万张图片构成,包含了超过 80 类常见物体。通过在数据集上对模型进行视觉预训练,可以在无需为特定任务标注的情况下提升模型对图片低级特征,如几何形态、纹理、颜色等的理解。随后针对本文特定的点刺检测任务,以较低的学习率在点刺训练集上对模型进行进一步微调。相较于预训练模型,微调后的模型具备对舌体及点刺语义信息的理解能力,隐式地将点刺颜色、形状、位置等因素进行综合分析,最终得到点刺的具体位置。

2.3 结果分析

考虑到点刺检测任务的密集性,本文利用召回率 (Recall) 对点刺检测精度进行评估,其定义如下:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

(6)

其中,TP 为 True Positive,即正确检测出的点刺数目;FN 为 False Negative,即未被检测出的点刺数目。召回率表征了模型对图像中点刺的检出能力。在训练集上完成训练的深度学习模型在包含 60 张舌象图像的测试集上进行性能评估,其结果如图 4 所示,平均每张点刺舌上大有约 96 个点刺,而利用本文算法正确检测出的点刺平均为 87 个,召回率为 90.78%。从召回率来看,本文提出的深度学习模型可以有效地分辨出舌体上的点刺,并精准标注出每一个点刺的位置和点刺在舌体不同区域的分布情况。仔细对比识别结果与人工标注结果,可以发现本文所提出的方法可以有效地区分点刺与淤点。相较于舌体中央,舌体边缘处分布的点刺识别率相对较低,其原因

可能是舌体边缘点刺所处的语义环境与舌体中央的点刺不一致,且其数目较少,导致训练数据不平衡。

此时模型训练时其梯度具备一定的倾向性,因此对舌体边缘识别率相对较低。

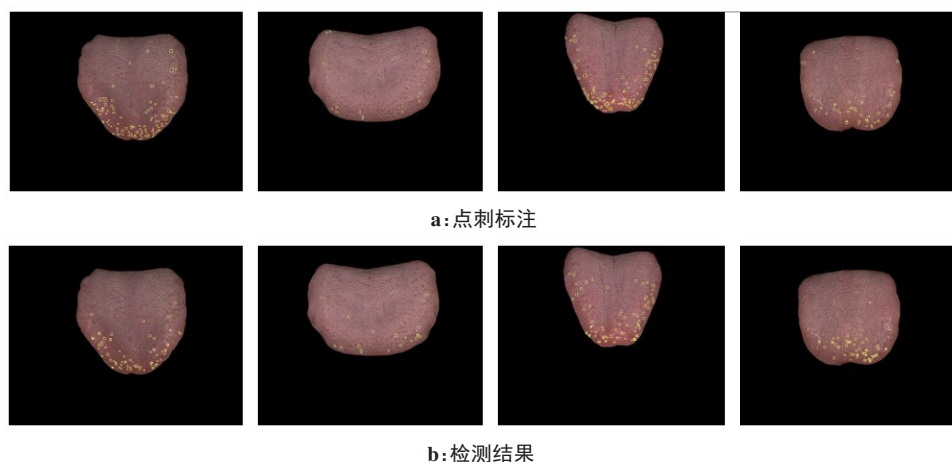


图4 点刺检测结果

Figure 4 Spot detection results

3 总结与展望

点刺作为中医辨证的重要参考依据,其检测的定量化、智能化、客观化是中医现代化的重要一环。本文提出的基于计算机视觉的点刺标注及检测流程主要包括3步。首先利用机器视觉中的LoG算子对分割后的舌体图像进行边缘检测,进而得到图像中斑点的位置,对斑点进行形态学上的初步筛选以剔除淤点和裂纹处凹点的干扰;随后在LabelMe标注工具中利用人工交互的方式筛选掉无关斑点,并对点刺的检测框位置及大小进行进一步微调;将上述带标注数据分为训练集和测试集,首先在包含各类常见物体的MS COCO数据集对深度学习模型RCNN进行预训练,并在本文的点刺训练集上进行进一步微调,最后在测试集上进行性能的评估。本文提出的基于机器视觉的点刺检测模型可以达到90.78%的召回率。

在医疗大数据的背景下,深度学习以其强大的表征学习与特征抽取能力助力中医的信息化与智能化。相较于基于传统机器视觉的点刺检测算法,本文将深度学习模型引入到点刺检测任务当中,除开点刺本身的形态、颜色信息,还充分利用了点刺周围区域的语义信息,包括点刺所处位置、舌体形态、舌体颜色等,达到了更高的检测精度。对点刺大小、位置分布的精确化描述可以为中医辨证提供客观定量的参考依据,也为后续其他深度学习理论的应用和其他下游任务的进行提供了前提条件。从现代科学的角度验证诠释中医“望闻问切”,不仅仅是中医现代化的重要一步,也是推动中医被广泛接受的助力。

中医讲究“未病先防”、“上工治未病”,现代医学亦提出“亚健康”理念,都说明了提前发现身体不健康状态并提前干预的重要性,但是在实际情况中,极少人能够在疾病出现趋势尚未恶化时前往就医。在这样的现状之下,基于深度学习的中医现代化使身体健康评估更加方便快捷且精准,在为医生提供了诊断辅助同时,也为亚健康群体自我检测身体健康水平提供了工具。

【参考文献】

- [1] 徐熊,宋海贝,温川颢,等. 基于智能信息处理的舌诊客观化研究[J]. 电脑知识与技术, 2020, 16(22): 182-184.
Xu X, Song HB, Wen CB, et al. Progress in objectification of tongue diagnosis based on intelligent information processing[J]. Computer Knowledge and Technology, 2020, 16(22): 182-184.
- [2] Hajirasouliha I, Elemento O. Precision medicine and artificial intelligence: overview and relevance to reproductive medicine[J]. Fertil Steril, 2020, 114(5): 908-913.
- [3] 许家伦,张志枫,严竹娟,等. 自然光条件下基于色差校正方法的舌象颜色分析[J]. 中西医结合学报, 2009, 7(5): 422-427.
Xu JT, Zhang ZF, Yan ZJ, et al. Analysis of tongue color under natural daylight based on chromatic aberration correction[J]. Journal of Chinese Integrative Medicine, 2009, 7(5): 422-427.
- [4] 秦忠. 关于中医诊断客观化研究的思考[J]. 贵阳中医学院学报, 2010, 32(3): 3-4.
Qin Z. Thoughts on objectification of TCM diagnosis[J]. Journal of Guiyang College of Traditional Chinese Medicine, 2010, 32(3): 3-4.
- [5] Wang YL, Shi XM, Li L, et al. The impact of artificial intelligence on traditional Chinese medicine[J]. AM J Chin Med, 2021, 49(6): 1297-1314.
- [6] Guo Y, Ren X, Chen YX, et al. Artificial intelligence meets Chinese medicine[J]. Chin J Integr Med, 2019, 25(9): 648-653.
- [7] Feng CW, Zhou SY, Qu YY, et al. Overview of artificial intelligence applications in chinese medicine therapy[J]. Evid Based Complement Alternat Med, 2021. Doi: 10.1155/2021/6678958.
- [8] 杨佳欣,韩东,董新明,等. 基于形态特征提取的中医齿痕舌客观化研究[J/OL]. 激光与光电子学进展, 2022, 59(11): 355-363.
Yang JX, Han D, Dong XM, et al. Research on objectification of Chinese medicine tooth mark tongue based on morphological feature

- extraction[J/OL]. *Laser & Optoelectronics Progress*, 2022, 59(11): 355-363.
- [9] 李宗润, 李炜弘, 井洪. 基于多种机器视觉技术的舌体分割模型研究[J]. *时珍国医国药*, 2021, 32(7): 1768-1771.
- Li ZR, Li WH, Jin Q. Tongue segmentation model based on multiple machine vision techniques [J]. *Lishizhen Medicine and Materia Medica Research*, 2021, 32(7): 1768-1771.
- [10] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//MICCAI. Springer, Cham, 2010: 234-241.
- [11] Chen LC, Zhu YK, George P, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//ECCV, 2018: 801-818.
- [12] Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis[J]. *Med Image Anal*, 2017, 42: 60-88.
- [13] 王昇, 刘开华, 王丽婷. 舌诊图像点刺和瘀点的识别与提取[J]. *计算机工程与科学*, 2017, 39(6): 1126-1132.
- Wang S, Liu KH, Wang LT. Tongue spot and petechiae recognition and extraction in tongue diagnosis images[J]. *Computer Engineering & Science*, 2017, 39(6): 1126-1132.
- [14] Shevade SK, Keerthi SS, Bhattacharyya C, et al. Improvements to the SMO algorithm for SVM regression[J]. *IEEE Trans Neural Netw*, 2000, 11(5): 1188-1193.
- [15] 王学民, 王瑞云, 郭丹, 等. 基于辅助光源的舌象点刺识别方法研究[J]. *传感技术学报*, 2016, 29(10): 1553-1559.
- Wang XM, Wang RY, Guo D, et al. Rresearch about tongue-prickled recognition method based on auxiliary light source [J]. *Chinese Journal of Sensors and Actuators*, 2016, 29(10): 1553-1559.
- [16] 何苗, 王宽全, 刘春雨. 基于Gabor小波和特征加权的红刺舌象分类[J]. *现代生物医学进展*, 2007, 7(11): 1714-1717.
- He M, Wang KQ, Liu CY. Red-prickled tongue image classification based on gabor wavelet and weighted features[J]. *Progress in Modern Biomedicine*, 2007, 7(11): 1714-1717.
- [17] Ando T, Fumio H. Operator log-convex functions and operator means [J]. *Math Ann*, 2011, 11(3): 611-630.
- [18] 崔振超. 计算机舌诊中舌体分割与纹理分类研究[D]. 哈尔滨: 哈尔滨工业大学, 2015: 52-55.
- Cui ZC. Tongue body segmentation and texture classification in computerized tongue diagnosis [D]. Harbin: Harbin Institute of Technology, 2015: 52-55.
- [19] Bryan C, Antonio T, Kevin P, et al. LabelMe: a database and web-based tool for image annotation[J]. *Int J Comput Vis*, 2008: 157-173.
- [20] Keys R. Cubic convolution interpolation for digital image processing [J]. *IEEE Trans Acoust*, 1981, 29(6): 1153-1160.
- [21] Tabassum K, Hijab M, Damodaram A. Location dependent query processing issues, challenges and applications [C]//Computer and Network Technology Second International Conference, 2010: 239-243.
- [22] Girshick R. Fast R-CNN [C]//IEEE International Conference on Computer Vision. IEEE, 2015: 1440-1448.
- [23] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]// Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2016: 770-778.
- [24] Theeuwes J. Stimulus-driven capture and attentional set: selective search for color and visual abrupt onsets [J]. *J Exp Psychol Hum Percept Perform*, 1994, 20(4): 799-806.
- [25] Lin TY, Maire M, Belongie S, et al. Microsoft COCO: common objects in context [C]// European Conference on Computer Vision, 2014: 740-755.

(编辑:薛泽玲)

(上接237页)

【参考文献】

- [1] 樊立天, 凌庆庆, 王浩文, 等. 可靠性分析方法在医疗设备运维管理中的应用研究综述[J]. *中国医疗设备*, 2022, 37(7): 148-151.
- Fan LT, Ling QQ, Wang HW, et al. Review on the application of reliability analysis method in operation and maintenance management of medical equipment [J]. *China Medical Devices*, 2022, 37(7): 148-151.
- [2] Ahsanullah M, Kibria BM, Shakil M. Normal distribution[M]. Paris: Atlantis Press, 2014: 7-50.
- [3] Das K. A comparative study of exponential distribution vs Weibull distribution in machine reliability analysis in a CMS design [J]. *Comput Ind Eng*, 2008, 54(1): 12-33.
- [4] Hallinan AJ. A review of the Weibull distribution [J]. *J Qual Technol*, 1993, 25(2): 85-93.
- [5] Mathai AM. Order statistics from a logistic distribution and applications to survival and reliability analysis [J]. *IEEE Trans Reliab*, 2003, 52(2): 200-206.
- [6] Ramos PL, Louzada F, Ramos E, et al. The Fréchet distribution: estimation and application-an overview [J]. *J Stat Manag Syst*, 2020, 23(3): 549-578.
- [7] Taghipour S, Banjevic D, Jardine AK. Reliability analysis of maintenance data for complex medical devices [J]. *Qual Reliab Eng Int*, 2011, 27(1): 71-84.
- [8] de Assis EM, Lima GA, Prestes A, et al. $\$ q \$$ -weibull applied to brazilian hydropower equipment [J]. *IEEE Trans Reliab*, 2018, 68(1): 122-132.
- [9] Klutke GA, Kiessler PC, Wortman MA. A critical look at the bathtub curve [J]. *IEEE Trans Reliab*, 2003, 52(1): 125-129.
- [10] Xu Z, Saleh JH. Machine learning for reliability engineering and safety applications: review of current status and future opportunities [J]. *Reliab Eng Syst Safe*, 2021, 211: 107530.
- [11] Spahić L, Kurta E, Čordić S, et al. Machine learning techniques for performance prediction of medical devices: infant incubators [C]// International Conference on Medical and Biological Engineering. Springer, 2019: 483-490.
- [12] Badnjević A, Pokvić LG, Hasičić M, et al. Evidence-based clinical engineering: machine learning algorithms for prediction of defibrillator performance [J]. *Biomed Signal Proces*, 2019, 54: 101629.
- [13] Santhosh TV, Gopika V, Ghosh AK, et al. An approach for reliability prediction of instrumentation & control cables by artificial neural networks and Weibull theory for probabilistic safety assessment of NPPs [J]. *Reliab Eng Syst Safe*, 2018, 170: 31-44.
- [14] Jia X, Nadarajah S, Guo B. Inference on q-Weibull parameters [J]. *Stat Pap*, 2020, 61(2): 575-593.
- [15] Teimouri M, Gupta AK. On the three-parameter Weibull distribution shape parameter estimation [J]. *J Data Sci*, 2013, 11(3): 403-414.
- [16] Algamal ZY, Ali HT. Discrimination between the weibull and the inverse gaussian distributions [J]. *J Math-Uk*, 2017, 13(2): 74-83.
- [17] 范英, 王顺坤, 晋民杰. 多种数据状态下三参数 Weibull 分布的极大似然估计 [J]. *机械强度*, 2012, 34(1): 53-57.
- Fan Y, Wang SK, Jin MJ. Maximum likelihood estimation of three parameter Weibull distribution in wide range of data state [J]. *Journal of Mechanical Strength*, 2012, 34(1): 53-57.

(编辑:陈丽霞)