

融合轻卷积网络 and 全迁移学习的递阶式舌象点刺识别方法

李俊贤¹ 朱明峰^{1*}

LI Junxian ZHU Mingfeng

摘要

鉴于现有舌象点刺识别方法准确性的不足,以及传统 CNN 需先训练再识别的不便,文章提出一种更加精准易用的舌象点刺识别方法。对传统 CNN 进行了精简设计,采用一种轻量化 CNN,在保证识别率基础上,可更加快速地完成训练优化;并引入全迁移学习方法,采用一种递阶式方法,实现舌象点刺的精准识别;识别后的最佳模型可供后续借鉴和利用,可大幅减少后续训练的时间消耗,从而提高识别效率。经实践检验,改进后的方法较改进前的方法准确性更高,精确率、Dice 系数以及 mIoU 系数可达 100%,错分类误差为零,且改进后的方法的效率较原先大幅提升,相较于其他算法的耗时 1 000 ms 以上,下降到了 15 ms。该方法在精度、效率和可用性方面较过去有显著提升。

关键词

轻量化;卷积网络;迁移学习;舌象点刺识别

doi: 10.3969/j.issn.1672-9528.2025.11.004

0 引言

舌诊是传统中医的重要诊断方法之一,因受医师主观因素及环境的影响,其准确性目前缺乏统一的度量标准。舌诊客观化旨在通过计算机客观地观测指标,对中医舌象进行定性、定量、定位的检测和分析。近年来,不少研究者借助数码成像设备采集舌象,利用计算机图像分析技术,实现对舌象的精确描述和量化分析,从而实现舌诊客观化。通过舌诊客观化,能够减少医生主观因素对舌诊结果的影响,提高舌诊的准确性。同时,将现代信息技术和人工智能方法融合,并将其应用于舌诊研究,可促进中医现代诊疗技术的发展。

1 研究背景

舌诊是中医望诊的主要内容,而点刺舌是舌诊中的一种典型症型。点刺的数量、密度以及分布位置在点刺舌象分析中有着至关重要的作用。基于此原因,点刺舌象的识别与检测是舌诊客观化的一个重要组成部分。目前已有的舌象点刺识别方法主要包括基于颜色与辅助光源的检测方法、基于传统函数以及统计学习的检测方法以及基于深度学习的检测方法。

在基于颜色与辅助光源的检测方法中,许家伦等人^[1]通过 RGB 三原色以及灰度均值差值来对点刺和淤点进行识别,

取得了较好的效果。张楠等人^[2]提出在 HSI 空间内基于阈值分割方法,实现对舌象点刺的识别。王学民等人^[3]采用了基于辅助光源的舌象点刺识别方法,并实现了点刺的计数和部位的判别。

在基于传统函数以及统计学习的检测方法中,黄勃等人^[4]采用了 Gabor 小波的方法对点刺舌象进行分类识别。何苗等人^[5]在该方法的基础上,使用了一种特征加权的方法,该方法会使纹理分类的效果大幅提高。卢谢吉^[6]提出了使用改进后的分水岭分割算法来进行瘀斑的检测,并使用 Top-hat 变换方法以及灰度直方图的阈值选取方法对淤点进行检测。王昇等人^[7]采用了 SimpleBlobDetector 算法来提取图像中的点刺特征向量,并使用支持向量机以及 K 均值聚类得到聚类结果,从而提取出点刺和淤点。

在基于深度学习的检测方法中,彭成东等人^[8]提出了基于多尺度卷积神经网络的舌象点刺识别模型,使用多尺度 CNN 模型对点刺舌象进行了识别。罗思言等人^[9]提出将深度学习中的卷积神经网络与传统的点刺检测算法相结合,使用了深度学习模型 Fast-RCNN,解决了传统算法设计过于复杂的问题。

综上所述,现有的舌象点刺识别和检测方法已经在一定程度上取得了不错的效果,但其准确性、效率和易用性仍有可提升的空间。另外,现有方法大部分停留在小样本集上。随着信息技术的日新月异,相较于传统方法,目前兴起的机器学习和深度学习技术可以显著提升舌象点刺识别和检测的精度和易用性。

1. 江西中医药大学计算机学院 江西南昌 330004

[基金项目] 江西省教育厅科学技术研究项目 (GJJ190672);

江西省中医药管理局科技计划项目 (2022B988)

2 方法

本方法基于轻量化 CNN 与迁移学习 (light-weight convolutional neural network & transfer learning, LWCNN&TL), 实现对舌象点刺的识别, 具体流程为:

- (1) 收集舌象;
- (2) 采用 CollectorXPro 软件提取和标注舌点图像;
- (3) 将样本分为两份, 其中 80% 为训练集, 20% 为测试集;
- (4) 借助轻量化 CNN 与迁移学习对训练集做训练;
- (5) 采用训练后的模型对测试集做测试以及对新样本做识别。

2.1 数据采集与标注

本文所使用的原始舌象来源于网络, 经过分类标注后舌点图大小为 16×16 , 舌点图库样本总数为 100 张, 训练集和测试集分别如图 1 和图 2 所示。

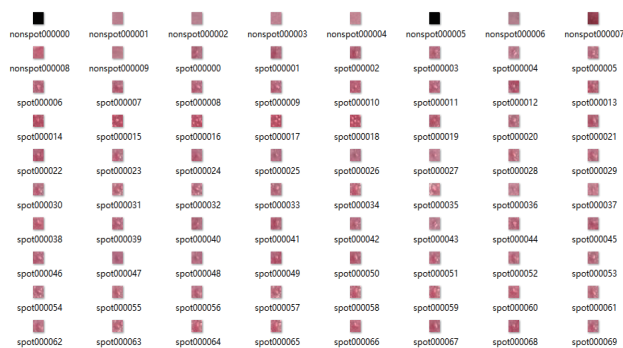


图 1 训练集



图 2 测试集

2.2 轻量化 CNN

卷积神经网络 (convolutional neural networks, CNN) 是一种广泛应用于图像识别、语音识别、自然语言处理等领域的深度学习模型。轻量化 CNN 的核心在于通过优化网络结构, 减少参数数量来降低计算量, 同时保持较高的识别精度。针对舌点原图尺寸较小的特点, 通过对卷积层、激活层及池化层的适当精简, 从而达到提高效率的目的。

本文所设计的轻量化 CNN 将 RGB3 通道 16×16 的图像, 通过 3 组步长为 1, 权值为 w 的卷积核, 激活函数采用 ReLU, 即 $f(x) = \max(0, x)$ 。经过卷积后得到单通道 3 组 12×12 特征图, 通过步长为 2 的 2×2 池化得到 6×6 特征图, 最后全连接层采用 sigmoid 激活函数得到两个分类结点。该方法如图 3 所示。




图 3 轻量化 CNN 原理

2.3 迁移学习算法

迁移学习是一种机器学习方法, 其核心在于通过共享知识和经验, 从已解决的任务中获得的特征、表示或模型, 来加速或改善新任务的学习过程。迁移学习可以通过将源域的知识和经验迁移到目标域中, 来提高模型的鲁棒性; 同时也可以提升模型的性能, 使预训练的模型在新任务上获得更好的性能。基于此原理, 本文在轻量化 CNN 的基础上又设计了全维真迁移算法来增强舌象点刺识别的实际效果。本文所设计的全维真迁移算法如图 4 所示。

算法 1 全维真迁移算法

输入: 学习标记 (TransferLearningTag), 首次学习标记 (bIsFirstTraining), 当前模型 (CurModel), 最优模型 (BestModel)
输出: 当前模型 (CurModel), 最优模型 (BestModel)

```

1.  if TransferLearningTag==TRUE
2.      if bIsFirstTraining==TRUE
3.          预训练 CurModel;
4.          保存训练模型 CurModel 至 BestModel;
5.          以 CurModel 为模型初始参数进行训练;
6.          if 新模型 CurModel 优于保存的模型 BestModel
7.              更新模型, 即将 CurModel 保存至 BestModel;
8.          end if
9.          bIsFirstTraining=FALSE;
10.     else
11.         恢复训练模型 BestModel 作为 CurModel 的初始参数;
12.         训练模型 CurModel;
13.         if 新模型 CurModel 优于保存的模型 BestModel
14.             更新模型, 即将 CurModel 保存至 BestModel;
15.         end if
16.     end if
17. else // 迁移学习 tag 未选中
18.     全新训练模型 CurModel;
19. end if
    
```

2.4 训练集与测试集

在机器学习中训练集与测试集的选取是较为重要的基础步骤，直接影响到模型的性能评估和泛化能力。因此，在选取上，训练集和测试集应该是相对独立的。并且其都具有代表性，能够反映整体数据集的特征。同时，训练集和测试集的大小需要合理安排，以便于模型能够学习到足够的信息，同时能够准确地评估模型性能。

总之，本文所采取的方法为随机划分方法，又称留出法，即随机选取 80% 的数据做训练集，将剩余的 20% 作为测试集。从而，该方法可以保证模型有足够的样本学习特征，同时可以对测试集做精准的评价。

3 结果

3.1 精度与效率评估

为了评估本文算法的性能，本次实验采用精确率（Precision）、Dice 系数（Dice Coefficient）、mIoU（mean intersection over union）系数以及错分类误差（miss classification error, ME）进行评价^[10]。精确率、Dice 系数、mIoU 和错分类误差的计算公式分别为：

$$\text{精确率} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{Dice 系数} = \frac{2TP}{2TP + FP + FN} \quad (2)$$

$$\text{IoU} = \frac{TP}{TP + FP + FN} \quad (3)$$

$$\text{错分类误差} = \frac{FP + FN}{TP + TN + FP + FN} \quad (4)$$

这些参数通过模型预测结果与人工标记的标签进行对比以判别结果，TP（true positive）为人工标注的舌点图被识别为舌点的数量；FP（false positive）为人工标注的舌点图未被正确识别的数量；TN（true negative）为人工标注的背景图被识别为背景的数量；FN（false negative）为人工标注的背景图被识别为舌点的数量。


本文使用的实验环境如下：处理器为 Intel Core i7-8750H，机带 RAM 为 32.0 GB，系统为 64 位 Windows10 操作系统，1 TB 的固态硬盘。

3.2 实验结果


为了验证本文算法的有效性，实验中将本文的算法、基于空间注意力机制的 CNN 算法（SM&CNN）、RCNN 算法以及 LWCNN 算法在经过分类标注的舌点样本数据集上进行测试。采用 4 个评估指标：精确率（Precision）、

Dice 系数、mIoU 以及错分类误差，来评价识别效果。其中精确率、Dice 系数、mIoU 越高效果越好，错分类误差越低效果越好。

传统 LWCNN 的训练方式为单步训练，即每次训练都从头开始，其误差演进如图 5（a）所示。本文将全迁移学习引入 LWCNN 的训练优化，训练过程为递阶式，即训练分成多步，每次训练都基于先前得到的最佳模型，其误差演进如图 5（b）和图 5（c）所示。这样最佳模型得以自动保留，可大幅降低后续训练的耗时，从而提高后续训练的精度和效率，同时也使方法更加简便易用。误差演进曲线越接近下方边线，说明模型越准确。误差演进曲线越长，则迭代次数越多，耗时越长。如图 5 所示，LWCNN&TL 训练过程包含 2 步，第 1 步过程较长，第 2 步误差迅速收敛至 0。



(a) LWCNN 训练误差单步演进曲线



(b) LWCNN&TL 第 1 步训练误差演进曲线



(c) LWCNN&TL 第 2 步训练误差演进曲线

图 5 两种模型误差演进

图 5 为 LWCNN 以及 LWCNN&TL 两种模型的误差演进曲线，从图中的演算曲线以及运行结果可以清晰地看到，LWCNN 方法在训练过程中的曲线呈现收敛的趋势，但在模型最后收敛时存在一定的误差耗时。LWCNN&TL 方法采用递阶式训练，将训练分为两步，可以清晰地看出 LWCNN&TL 方法的后续演算曲线几乎不存在耗时。

表 1 是上述 4 种算法的精度平均值，表中的结果是测算 10 次的平均值。从表 1 可以看出本文算法的精确率、Dice 系数以及 mIoU 系数皆为 100%，错分类误差为 0。从实验结果分析，相较于其他算法，本文算法取得了最优的结果。

表 1 模型运行精度对比

方法	单位: %			
	Precision	Dice	mIoU	ME
RCNN	79.00	88.24	78.95	21.05
SM&CNN	85.00	90.91	83.33	15.00
LWCNN	90.00	93.75	88.24	10.00
LWCNN&TL	100.00	100.00	100.00	0

表 2 是上述 4 种算法的运行时间对比,耗时上采用 ms 为单位,表中的结果也是测算 10 次的平均值。从结果分析,相较于其他算法,本文算法的训练耗时最低,仅为 15.4 ms。

表 2 模型运行时间对比

方法	耗时 /ms
RCNN	1 282.4
SM&CNN	904.4
LWCNN	1 797.0
LWCNN&TL	15.4

4 总结

舌诊是中医望诊中的主要内容,它在中医的临床诊断中发挥了重要的作用。在中医临床,点刺舌象是舌诊中的一种典型的症型。点刺的数量、密度以及分布位置在点刺舌象分析中有着至关重要的作用。然而,传统的中医点刺舌象的识别,依赖医生肉眼的观察与经验,容易被个人的主观意识以及外部环境影响。中医舌诊客观化旨在建立客观统一的辨识标准。首先,舌诊的客观化可以减少主观偏差,量化舌象特征,有助于医生更准确地判断病情,提升了舌诊的准确性和可靠性。其次,在舌诊客观化中引入了机器学习技术,此举可以推动中医诊断技术的进步,也为中医的现代化发展开辟了新的思路。再次,客观化的舌诊结果,也为中医疗效评估提供了更为科学的依据。舌象点刺识别是舌诊客观化的重要组成之一,其主要内容为识别点刺舌象,为实现全面舌诊客观化铺平了道路。传统 CNN 算法在已有数据集上展现了不错的性能,但是在准确率和效率上还有待进一步提高。基于上述事实,本文设计实现了全维真迁移算法,该算法可进一步提高舌象点刺识别训练优化的性能。

从实验结果分析可知,改进后的方法 LWCNN&TL 的性能优于已有方法(RCNN、SM&CNN 和 LWCNN)。LWCNN&TL 的准确性优于其他 3 种方法,可达 100%。LWCNN&TL 的训练耗时最低,可低至 15.4 ms。

本文所做的主要贡献包括 2 点:首先,本文对传统 CNN 算法及结构进行轻量化改进,即 LWCNN,以适应点刺图尺

寸较小的特点;其次,设计了全维真迁移算法,并将其成功应用于 LWCNN 模型,可有效提高训练的精度,也可提升后续训练的效率,增强了方法的易用性。LWCNN 的主要优点在于使用了更小的模型,具有了更低的计算复杂度和更快的训练速度。在现有样本集的测试结果中,LWCNN 在性能表现上优于已有方法。而在实施了全迁移学习算法后,迁移学习可以利用已经训练好的模型提升基线性能,节省模型的训练时间。因此,改进后的方法可以在精度与效率上有着显著的提升。

参考文献:

[1] 许家佗,张志枫,孙炆,等.舌象图像分析中点刺与瘀点特征的识别[J].上海中医药大学学报,2004,18(4):38-40.

[2] 张楠,胡广芹,张新峰,等.中医舌象点刺识别研究[C]//世界中医药学会联合会中医诊疗仪器专业委员会成立大会暨第一届学术年会论文集.北京:世界中医药学会联合会,2015:342-346.

[3] 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.

[4] 黄勃,李乃民,刘春雨,等.基于 Gabor 小波的红刺舌象分类研究[C]//第一届全国中西医结合诊断学术会议论文选集.哈尔滨:中国中西医结合学会,2006.

[5] 何苗,王宽全,刘春雨.基于 Gabor 小波和特加权的红刺舌象分类[J].现代生物医学进展,2007,7(11):1714-1717.

[6] 卢谢吉.舌图像中瘀斑瘀点检测技术研究[D].哈尔滨:哈尔滨工业大学,2008.

[7] 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.

[8] 彭成东,汪莉,蒋冬梅,等.基于多尺度卷积神经网络的舌象点刺识别模型建立与验证(英文)[J].Digital Chinese medicine,2022,5(1):49-58.

[9] 罗思言,吴豆豆,刘茜玮,等.基于计算机视觉的点刺标注与检测[J].中国医学物理学杂志,2023,40(2):238-243.

[10] 钟振,杨朝阳.基于深度学习的中医舌象图像分割研究[J].江西中医药,2021,52(7):46-49.

【作者简介】

李俊贤(1999—),男,浙江温州人,硕士研究生,研究方向:舌诊客观化。

朱明峰(1980—),通信作者(email:8590143@qq.com),男,江西南昌人,硕士,副教授、硕导,研究方向:中医药人工智能。

(收稿日期:2025-06-07 修回日期:2025-11-17)