

基于双阶段元学习的小样本中医舌色域自适应分类方法

卓力* 张雷 贾童瑶 李晓光 张辉

(北京工业大学计算智能与智能系统北京重点实验室 北京 100124)

(北京工业大学信息学部 北京 100124)

摘要: 舌色是中医(TCM)望诊最关注的诊察特征之一。在实际应用中,通过一台设备采集到的舌象数据训练得到的舌色分类模型应用于另一台设备时,由于舌象数据分布特性不一致,分类性能往往急剧下降。为此,该文提出一种基于双阶段元学习的小样本中医舌色域自适应分类方法。首先,设计了一种双阶段元学习训练策略,从源域有标注样本中提取域不变特征,并利用目标域的少量有标注数据对网络模型进行微调,使得模型可以快速适应目标域的新样本特性,提高舌色分类模型的泛化能力并克服过拟合。接下来,提出了一种渐进高质量伪标签生成方法,利用训练好的模型对目标域的未标注样本进行预测,从中挑选出置信度高的预测结果作为伪标签,逐步生成高质量的伪标签。最后,利用这些高质量的伪标签,结合目标域的有标注数据对模型进行训练,得到舌色分类模型。考虑到伪标签中含有噪声问题,采用了对比正则化函数,可以有效抑制噪声样本在训练过程中产生的负面影响,提升目标域舌色分类准确率。在两个自建中医舌色分类数据集上的实验结果表明,在目标域仅提供20张有标注样本的情况下,舌色分类准确率达到91.3%,与目标域有监督的分类性能仅差2.05%。

关键词: 中医舌色分类; 小样本; 域自适应; 双阶段元学习

中图分类号: TN911.73; TP391

文献标识码: A

文章编号: 1009-5896(2024)03-0986-09

DOI: [10.11999/JEIT230249](https://doi.org/10.11999/JEIT230249)

Few Shot Domain Adaptation Tongue Color Classification in Traditional Chinese Medicine via Two-stage Meta-learning

ZHUO Li ZHANG Lei JIA Tongyao LI Xiaoguang ZHANG Hui

(Beijing Key Laboratory of Computational Intelligence and Intelligent Systems, Beijing University of Technology, Beijing 100124, China)

(Signal and Information Processing Laboratory, Beijing University of Technology, Beijing 100124, China)

Abstract: Tongue color is one of the most concerning diagnostic features of tongue diagnosis in Traditional Chinese Medicine (TCM). In practical applications, the performance of the model trained from the tongue data acquired by one device is dramatically degraded when applied to other devices due to the data distribution discrepancy. Therefore, in this paper, a few shot domain adaptation tongue color classification method with two-stage meta-learning is proposed. Firstly, a two-stage meta-learning training strategy is proposed to extract domain invariant features from labeled samples in the source domain, and then, the meta-trained network model is fine-tuned using a few labeled data in the target domain, so that the model can quickly adapt to the new sample characteristics in the target domain, improving the generalization ability of the tongue color classification model and avoid overfitting problem. Next, a progressive pseudo label generation strategy is proposed, which uses the meta-trained model to predict the unlabeled samples in the target domain. The prediction results with high confidence are selected and treated as pseudo labels. So high-quality pseudo labels can be gradually generated. Finally, these high-quality pseudo labels are used to train the model, together with the labeled data in the target domain. The tongue color classification model can be obtained. Considering the noisy pseudo labels, the contrast regularization function is adopted, which can effectively suppress the negative

收稿日期: 2023-04-11; 改回日期: 2023-09-07; 网络出版: 2023-09-12

*通信作者: 卓力 zhuoli@bjut.edu.cn

基金项目: 国家自然科学基金(61871006), 国家中医药管理局中医药创新团队及人才支持计划(ZYYCXTD-C-202210)

Foundation Items: The National Natural Science Foundation of China (61871006), Innovation Team and Talents Cultivation Program of National Administration of Traditional Chinese Medicine (ZYYCXTD-C-202210)

impact of noisy samples in the training process and improve the tongue color classification accuracy in the target domain. The experimental results on two self-established TCM tongue color classification datasets show that the classification accuracy of tongue color in the target domain reaches 91.3% when only 20 labeled samples are given in the target domain, which is only 2.05% lower than that of the supervised classification model in the target domain.

Key words: Tongue color classification in Traditional Chinese Medicine(TCM); Few shot; Domain adaptation; Two-stage meta-learning

1 引言

舌诊是中医(Traditional Chinese Medicine, TCM)望诊的主要内容之一,是辨证施治的重要依据。舌象的变化可真实地反映人体脏腑的虚实、气血的盛衰、病位的深浅、病邪的性质以及预后的好坏。舌诊主要通过观察患者的舌苔、舌色等诊察特征来进行诊断。舌诊涉及的诊察特征有30多种,其中,舌色是最直接也是最常用的诊察特征之一。舌色即为舌尖和舌两侧的颜色,一般分为淡红色、红色、暗红色、紫色。舌色分类可以看作模式识别问题,普遍采用机器学习的手段加以解决。

近年来,深度学习逐渐被应用于舌诊客观化研究中,大大提高了舌象分析处理的准确率。但是现有的这些研究工作还无法获得令人满意的分类结果,主要原因在于^[1]:

(1)深度神经网络模型结构复杂,需要大量的有标注样本对其进行训练,才能获得理想的性能。然而舌象样本数据的采集、标注费时费力,有标注的数据匮乏,严重限制了分类性能的提升;

(2)通过一台设备采集到的舌象数据训练得到的模型应用于另一台设备时,由于光照条件、采集设备等发生了变化,导致舌象数据分布特性不一致,分类性能急剧下降,更有甚者会导致模型的失效,阻碍了模型的实际推广应用。

针对上述问题,本文结合元学习、伪标签生成和有噪样本学习,提出一种中医舌色域自适应分类方法,以提高舌色分类模型的性能和泛化能力。主要的创新点包括:(1)提出一种基于双阶段元学习的训练策略。利用图像分类数据集MiniImageNet对模型进行第1阶段的元学习训练,使模型学习到通用性的特征。利用源域舌色数据集对模型进行第2阶段的元学习训练,使得模型可以快速适应舌色数据的特性;(2)提出一种渐进高质量伪标签生成方法。基于目标域少量有标注样本对预训练模型进行微调,利用微调后的模型对目标域大量无标注样本进行预测,生成伪标签,通过设置伪标签置信度阈值结合模型集成策略,判断生成的伪标签质量,从中筛选出高质量的伪标签,和目标域的少量

有标注数据一同用于模型训练,渐进提升伪标签的准确度;(3)利用目标域少量标注样本和大量伪标签样本训练分类网络,针对生成的伪标签中含有噪声问题,采用了对比正则化函数,有效抑制噪声样本在训练过程中产生的负面影响,提升目标域舌色分类准确率。

在自建的2个中医舌色分类数据集上的实验结果表明,本文提出的中医舌色分类方法能基于目标域少量有标注样本,显著提升目标域舌色分类的准确率。在目标域每类仅给出5张有标注样本的情况下,目标域舌色分类准确率达到91.3%,与目标域有监督分类性能仅差2.05%。

2 相关工作

近年来,以深度学习为代表的人工智能迅猛发展,为传统中医的创新提供了重要的契机。学者将深度学习应用于中医舌色分类中,取得了重要的研究进展。下面对相关领域的研究进展进行介绍。

2.1 基于深度学习的中医舌色分类

深度学习可以从大量的有标注样本中自动学习到表达能力强、通用性好的特征。学者将深度学习应用于中医舌色分类中,大幅提升了分类准确率。文献[2]对舌图像进行预处理,使用修改后的CaffeNet网络对舌图像进行分类。文献[3]结合图像预处理和深度学习,在舌图像数据集中验证了自搭建的卷积神经网络(Convolutional Neural Network, CNN)的分类性能。文献[4]将舌图像分割为舌质区域和舌苔区域,使用稀疏编码表示舌图像的特征向量,对重建特征向量的残差进行计算来确定舌色类别。文献[5]提出了一种新颖的置信学习辅助知识蒸馏框架用于解决舌象噪声标签问题,教师网络一方面可以执行置信学习来识别、清理和纠正有噪的标签,另一方面可以学习知识,指导学生网络训练。文献[6]针对舌象标签噪声问题,提出了一种两阶段数据清洗方法,对噪声样本进行识别和清洗,同时设计了一种基于通道注意力机制的轻型CNN,有效提升了舌色分类准确率。

上述基于深度学习的中医舌色分类方法均取得

了远超过传统方法的分类性能。但是前提假设是训练数据和测试数据来自同一个域,具有相同的样本分布。但是在实际应用中,这一假设往往难以成立,由于训练集和测试集往往存在域差异,导致分类性能严重下降,模型的泛化能力仍有待于进一步提升。

2.2 域自适应学习

域自适应学习是迁移学习的特例,旨在学习一个鲁棒的网络模型,使得在源域训练好的模型在目标域上也能获得良好的性能,是一种可以有效提升模型泛化能力的学习范式。

域自适应方法主要可以分为无监督域自适应和半监督域自适应。无监督域自适应指的是目标域数据样本均未标注,可以进一步划分为浅层和深层方法。浅层域自适应方法^[7-10]主要利用基于实例和基于特征的技术来对齐域分布,对齐分布的一种方法是最小化域之间距离。域自适应中最常用的距离度量包括最大平均差异(Maximum Mean Discrepancy, MMD)^[11]、相关比对(CORrelation ALignment, CORAL)^[12]、KL散度(Kullback-Leibler Divergence, KLD)^[13]和对比域差异(Contrastive Domain Discrepancy, CDD)^[14]等。深层域自适应方法^[15,16]通常使用自编码器或对抗网络来减小域间距离。文献^[17]提出了深度传输网络(Deep Transfer Network, DTN),该网络同时匹配域间边缘分布和条件分布,可以有效缩小域间距离。

半监督域自适应指的是目标域数据样本仅有少量进行了标注。文献^[18]提出了最小最大熵(Mini-Max Entropy, MME)方法,通过最大化熵更新编码器,以保持特征的域不变性。文献^[19]利用增强的类别对齐模块计算源域的每个样本与目标域有标签样本中心的距离,利用一致性学习模块把无标注数据经过弱增强后得到数据的伪标签作为强增强数据的真实标签。最后通过两个模块的联合学习减少域间和域内差异。文献^[20]提出了跨域自适应聚类(Cross-Domain Adaptive Clustering, CDAC),对高置信度伪标签设计了对抗自适应聚类损失,拉近类内距离的同时拉大类间距离。文献^[21]通过修正无标签样本的概率分布和置信度域值来提高伪标签的质量。

元学习也被称为“学习如何学习”,其本质是通过构建大量的元训练和元测试任务,使得网络可以不断适应每个具体任务的学习,从而具备抽象的学习能力,仅通过少量的训练样本就可以实现新任务的高效学习。元学习主要分为基于度量的元学习、基于模型的元学习和基于优化的元学习等,代

表性方法包括一般神经注意力机制元学习(Simple Neural Attentive Meta-Learner, SNAML)^[22]、模型不可知元学习(Model-Agnostic Meta-Learning, MAML)^[23]等。

元学习有助于提升分类模型的泛化能力和知识迁移复用的能力,是一种实现域自适应的有效手段。因此,本文设计了双阶段元学习域自适应策略,来提升舌色分类模型的泛化能力。

3 基于双阶段元学习的小样本中医舌色域自适应分类方法

本文提出方法的整体框架如图1所示。主要包括双阶段元学习、渐进高质量伪标签生成和有噪声样本的模型训练等3个步骤。下面介绍每个步骤的具体实现细节。

3.1 双阶段元学习

双阶段元学习整体流程如图1所示。第1阶段,利用公共数据集MiniImageNet对分类模型进行元学习训练,从大规模数据集中学习到分类任务的通用知识;第2阶段,利用源域的有标注舌象样本数据和目标域的少量有标注数据对分类模型进行元学习训练,使其快速适应目标域新舌象数据样本的特性。

本文选用ResNet18作为主干网络,采用基于度量的元学习方法进行训练。遵照元学习训练过程,将数据划分为元训练集和元测试集,又将每个数据集进一步划分为支持集和查询集。

元训练阶段。训练集可以表示为 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$,其中 N 是训练集 D 的类别数, x 是训练样本, y 是对应的标签。将训练集 D 划分成多个 K -way C -shot的元任务,其中 K -way C -shot代表从训练集 D 中随机选取 K 个类别、且每个类别包含 C 个样本,将划分后的元任务分为支持集和查询集,利用支持集中样本计算出各类的质心,通过拉近查询集中样本与对应类质心的距离,计算损失函数更新模型参数。

元测试阶段。使用支持集中样本更新各类的质心,通过计算查询集中样本与各类质心的距离进行类别预测。

采用双阶段元学习策略,可以克服舌象样本数据量不足的问题,避免训练过程中出现过拟合。接下来,将利用训练好的模型对目标域的大量无标记样本进行预测,渐进生成高质量的伪标签。

3.2 渐进高质量伪标签生成

渐进伪标签生成过程如图2所示。首先,利用双阶段元学习训练后的模型对目标域大量的未标注样本进行预测,将预测结果作为伪标签。很显然,

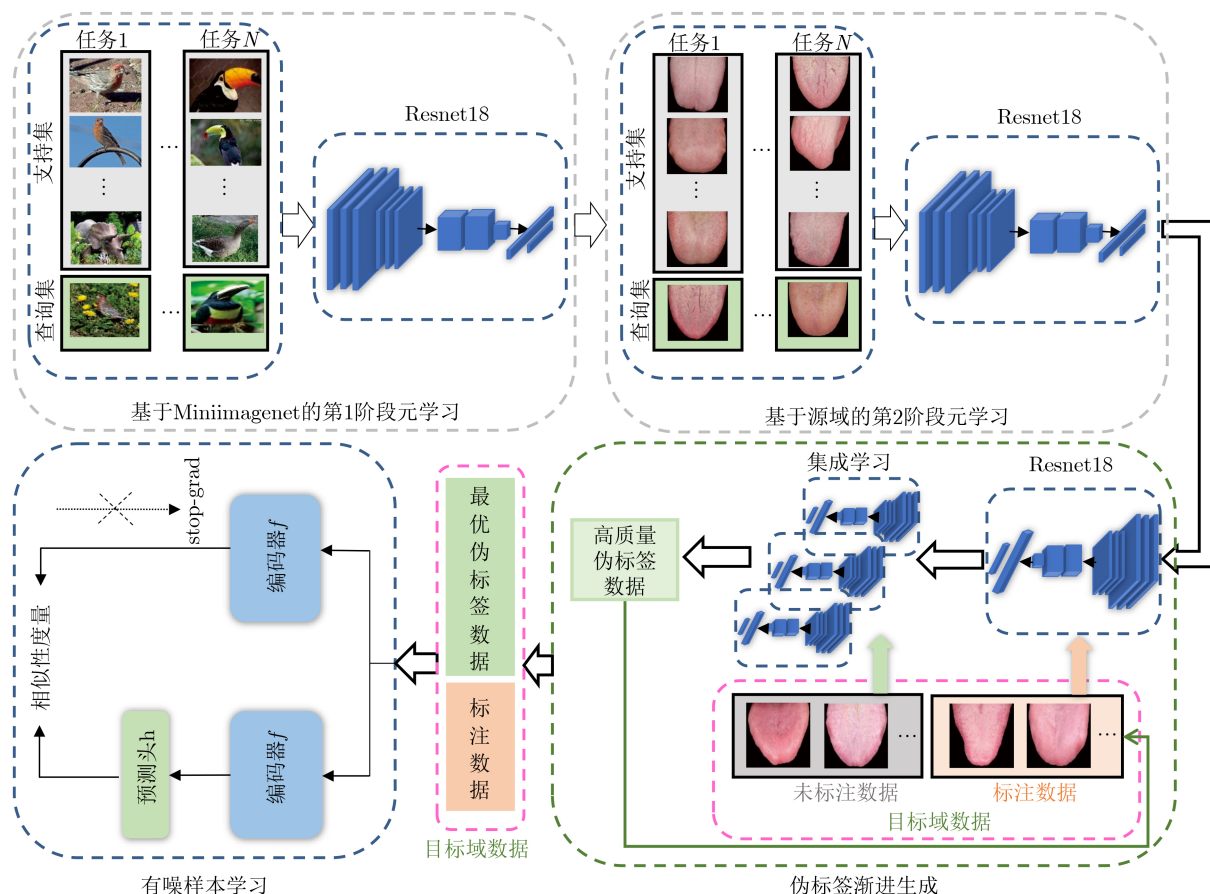


图1 双阶段元学习的中医舌色域自适应分类整体框图

伪标签中不可避免地会出现错误，这些噪声标签会对后续的模型训练造成严重的负面影响，误差会不断累积，导致模型的性能比较差。

为此，本文提出一种渐进的伪标签生成方法，提升伪标签的质量。基本思路是对模型预测结果的置信度进行判别，同时结合模型集成策略，判断伪标签的质量。伪标签质量判别过程如下：

假设 $p(y = k|q)$ 表示模型输出的类别预测概率，当 $p(y = k|q)$ 大于阈值 th ，且多个模型的预测结果一致时，将其认定为高质量伪标签；否则判定为低质量伪标签加以丢弃。将高质量伪标签样本数据与已有的少量的有标注数据一同用于模型训练，提升模型对未标注数据的预测准确性。利用训练好的模型对剩余的未标注数据进行预测和伪标签质量判别，重复以上步骤，直到所有的未标注数据均赋予了伪标签。

本文采用了Resnet18, SACA-Resnet18, E-CA2-ResNet18^[5]3个异质网络结构进行模型集成学习。其中SACA-Resnet18在Resnet18中加入了空间注意力和通道注意力机制，这是考虑到中医舌诊的习惯，采用空间注意力机制引导网络重点关注舌尖和舌两侧区域，采用通道注意力机制提升舌色分类

特征的区分性和表达能力。E-CA2-ResNet18指的是Resnet18中加入通道注意力机制并结合是否激活(ACtivate Or Not, ACON)函数。集成学习采用投票法，融合多个模型的预测结果，筛选出高质量的伪标签。

3.3 损失函数

在生成的伪标签中不可避免地会存在错误，直接使用噪声伪标签进行模型训练会导致误差传递，使得模型在训练过程中难以收敛。为此，本文采用鲁棒的对称交叉熵(Symmetric Cross Entropy, SCE)损失函数^[24]和对比正则化(Contrastive Regularization, CTR)函数^[25]对网络进行优化训练，抑制噪声样本对分类性能的影响。

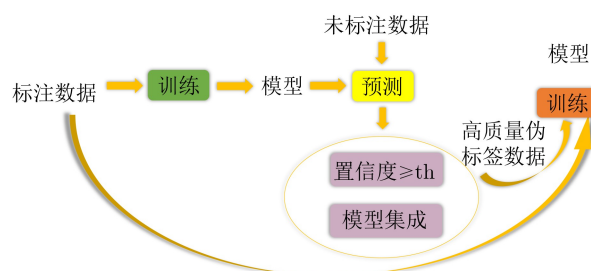


图2 渐进高质量伪标签生成过程

总损失函数如式(1)所示

$$L = L_{\text{sce}} + \alpha \tilde{L}_{\text{ctr}} \quad (1)$$

其中, L_{sce} 代表SCE损失函数, \tilde{L}_{ctr} 代表CTR函数, α 用于控制正则化的强度。

CTR函数假设两张来自同类的干净样本所携的关于正确标签的信息是相关的, 而所携带的关于错误标签的信息是无关系的, 保证了模型不会欠拟合正确标签。同时, 携带较少的与错误标签相关的信息, 也在一定程度上保证模型不会过拟合噪声样本。表达式如式(2)所示

$$\tilde{L}_{\text{ctr}}(x_i, x_j) = (\ln(1 - \langle \tilde{q}_i, \tilde{z}_j \rangle) + \ln(1 - \langle \tilde{q}_j, \tilde{z}_i \rangle)) \cdot \mathbf{1}\{\mathbf{p}_i^T \mathbf{p}_j \geq \tau\} \quad (2)$$

SCE是一种鲁棒的损失函数, 可以在一定程度上缓解模型对噪声样本的过拟合问题。其表达式为

$$L_{\text{sce}} = \gamma L_{\text{ce}} + \beta L_{\text{rce}} \quad (3)$$

其中, γ, β 是两个超参数, L_{ce} 是交叉熵损失, 如式(4)所示

$$L_{\text{ce}} = - \sum_{k=1}^K q(k|x) \log_2 p(k|x) \quad (4)$$

L_{rce} 是反向交叉熵损失, 如式(5)所示

$$L_{\text{rce}} = - \sum_{k=1}^K p(k|x) \log_2 q(k|x) \quad (5)$$

4 实验结果与分析

为了验证所提方法的有效性, 本文进行了实验。下面详细介绍实验结果, 并对其进行分析。

4.1 数据集和性能评价

数据集。实验中采用了2个自建的中医学舌象分类数据集SIPL-A, SIPL-B。数据集中的样本分别利用2台自研的SIPL型中医舌象仪进行采集, 并对舌体进行了分割。所有样本均由具有多年临床诊断经验的中医医师手工标注。两个自建数据集的类别和样本数量如表1所示, 部分示例舌图像如图3所示。可以看出, 由于2台设备在光照条件、采集设备等

方面存在差异, 两个数据集中的样本存在明显的颜色差异。

将MiniImageNet数据集作为第1阶段元学习数据集, SIPL-A数据集作为第2阶段元学习的源域数据集, SIPL-B数据集作为目标域数据集。源域训练集使用全部标注数据, 目标域训练集随机选取了20张有标注数据, 即4个类别、每类5幅图像, 其余数据均视为无标注数据。

数据扩充。由于自建数据集SIPL-A, SIPL-B的有标注样本量较少, 本文采用数据扩充的方式扩大训练样本规模, 具体包括垂直翻转、水平翻转、随机裁剪和其他几何变换方式等。

性能评价指标。本文采用最常用的准确率来度量舌色分类性能, 具体定义为

$$\text{Acc} = (\text{TP} + \text{TN})/N \quad (6)$$

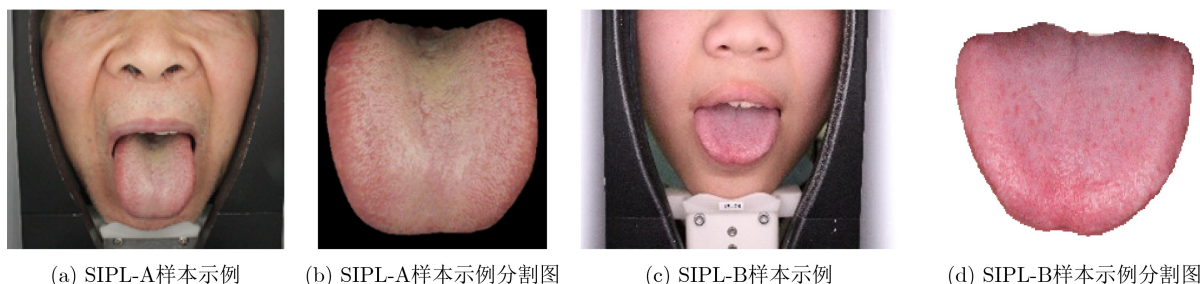
假设 C 表示舌色类别中的一类, 式(6)中TP表示类 C 中的样本被正确预测为类 C 的数量, TN表示不属于 C 类的其他类别样本被正确预测为对应类别的数量, N 表示测试集中样本的总数量。

4.2 参数设置

本文使用Pytorch开源架构进行网络模型的搭建、训练和测试。硬件配置基本参数为: Intel(R) core(tm)I5-7500 CPU@3.40 GHz, 16GB内存, Titan xp(Pascal)显卡。在元学习阶段, 模型训练采用Adam梯度下降算法, Bacth Size设置为100, 学习率设置为0.0003, 训练迭代周期为200次。此外, 在训练过程中学习率以固定步长衰减, 学习率每10个epochs减少为原来的gamma倍, 其中gamma设置为0.5。渐进伪标签生成过程中, 伪标签置信度阈值th设置为0.9。在有噪样本学习阶段, 采用Adam梯度下降算法进行优化, 学习率固定为0.003,

表1 两个自建数据集的样本类别和数量

数据集	类别和数量				总数
	淡红	红	暗红	暗紫	
SIPL-A	130	130	114	36	410
SIPL-B	200	190	110	35	535



(a) SIPL-A样本示例

(b) SIPL-A样本示例分割图

(c) SIPL-B样本示例

(d) SIPL-B样本示例分割图

图3 两个自建数据集集中的部分样本示例

Bacth Szie设置为32，迭代周期设置为400次，对比正则化损失系数 α 设置为50。

4.3 有监督舌色分类性能

本文首先在2个数据集上进行了实验，基于有标注样本数据，采用有监督学习方式对模型进行训练，得到的分类准确率如表2所示。其中网络模型为ResNet18，采用SCE损失函数进行监督。可以看出，采用有监督学习方式训练出来的分类模型，在SIPL-A,SIPL-B两个数据集上的分类精度分别达到了94.03%和93.35%。这些数据将作为基准数据，验证本文提出的域自适应舌色分类方法的性能。

4.4 不同训练策略对伪标签质量的影响

为了验证双阶段元学习策略对模型跨域性能的影响，本文将其与其他几种训练策略进行了对比，对比结果如表3所示。其中每种策略的具体实现方式如下：

策略1 直接使用源域数据集SIPL-A训练Resnet18，对目标域的测试集数据进行测试。

策略2 利用源域数据集SIPL-A对Resnet18进行预训练，再使用目标域20张有标注数据进行微调。

策略3 利用MiniImageNet数据集对Resnet18进行预训练，再使用目标域20张有标注数据进行微调。

策略4 单阶段元学习，即仅使用源域数据集对Resnet18模型进行元学习训练，然后利用目标域20张有标注数据进行微调。

策略5 提出双阶段元学习训练策略。

由表3可知，策略1未适用任何跨域训练策略，伪标签准确率仅为66.5%，这说明源域训练出的模型在目标域的性能急剧下降，模型泛化能力差。策略2相比策略1有10.3%的提升，说明使用目标域少量标注数据微调可以提升分类性能。使用SIPL-A数据集预训练相比MiniImageNet数据集进行预训练有2%的性能提升，说明利用相似任务数据集预

表2 采用有监督学习方法得到的两个数据集分类精度(%)

	淡红舌	红舌	暗红舌	暗紫舌	整体精度
SIPL-A	91.25	92.48	96.80	100.00	94.03
SIPL-B	93.90	93.19	95.65	85.71	93.35

表3 不同训练策略对伪标签准确率的影响(%)

训练策略	伪标签准确率
策略1	66.5
策略2	76.8
策略3	74.8
策略4	79.9
策略5	82.0

训练模型可取得更优的效果。策略4相比策略3性能提升了5.1%，验证了元学习训练策略在域自适应上的优势。与单阶段元学习相比，本文提出的双阶段元学习训练策略能将分类准确率提升2.1%。这是因为通过第1阶段大规模通用数据集上的元学习训练，使得模型能够学习到图像分类的通用知识。第2阶段模型通过源域的有标注样本进行元学习训练，能学习到关于舌色分类的元知识，并可以快速适应目标域的新数据特性，从而获得了最优的分类性能。

4.5 目标域有标注样本数量对伪标签质量的影响

接下来，将验证目标域有标注样本数量对伪标签质量的影响。目标域每个类别的有标注样本数量分别为1例、3例和5例，训练策略均采用双阶段元学习，得到的伪标签准确率对比结果如表4所示。

由表4可知，当目标域每类有标注样本数量分别为1, 3, 5例时，伪标签准确率分别达到了78.6%, 80.7%和82.0%，准确率随着有标注样本数量的增加而不断提升。因此，本文将目标域每类的有标注样本数量设置为5例，以降低模型训练对有标注数据的依赖，减轻人工标注压力，提高所提出方法的实用性。

4.6 不同元学习方法对伪标签质量的影响

为了验证不同元学习方法对伪标签质量的影响，本文将提出方法与代表性的元学习方法Matching networks^[26], Relation network^[27], SNAML^[22]和Online MAML^[28]进行了对比，表5列出了采用不同元学习方法得到的对比实验结果，取10次实验的平均分类准确率作为实验结果，主干网络均使用Resnet18。

从表5可以看出，对于所有的元学习方法，相比单阶段元学习，双阶段元学习生成的伪标签准确

表4 不同目标域有标注样本数量对伪标签准确率的影响(%)

目标域有标注样本	训练策略	伪标签准确率
1例	双阶段元学习	78.6
3例	双阶段元学习	80.7
5例	双阶段元学习	82.0

表5 不同元学习方法对伪标签准确率的影响(%)

元学习方法	单阶段元学习 伪标签准确率	双阶段元学习 伪标签准确率
Matching networks	77.2	78.5
Relation network	77.8	79.8
SNAML	78.5	81.2
Online MAML	79.5	81.7
本文方法	79.9	82.0

率均有一定的提升,说明双阶段元学习训练策略可以有效学习到域不变特征。本文采用的元学习方法可以取得最优的分类性能,相比于其他元学习方法,单阶段元学习和双阶段元学习生成的伪标签准确率均为最高。

4.7 伪标签质量对分类性能的影响

本节将验证伪标签质量对分类性能的影响。实验中,分别采用不同的方法生成无标注样本的伪标签,取10次实验结果的平均值作为伪标签准确率,结果如表6所示。其中,伪标签准确率是指对全部未标注数据预测的准确率。模型集成在伪标签预测中采用投票法。具体对比方法包括:

(1) 一次性伪标签生成+模型集成:指在全部生成伪标签过程中加入模型集成策略;

(2) 渐进伪标签生成+置信度阈值:指仅利用置信度阈值对标签质量进行判别,选取质量高的伪标签加入有标注数据微调模型,对未标注数据进行预测,渐进生成伪标签;

(3) 渐进伪标签生成+置信度阈值+模型集成:利用置信度阈值和模型集成两个条件对标签质量进行判别,并渐进生成伪标签。

实验中,置信度阈值均设为0.9。从表6可以看出,一次性生成所有未标注数据的伪标签,准确率仅为82%。加入模型集成策略能够略微提升准确率,但是效果十分有限。采用渐进生成伪标签的方式,结合置信度阈值进行筛选,可以生成201个伪标签,能够提高伪标签准确率。在此基础上进一步结合模型集成策略,可以筛选出146个高质量伪标签,将这些伪标签加入有标注数据对模型进行微调,能够进一步提升伪标签准确率,达到87.00%。

表7所示的是不同轮次生成的伪标签准确率。可以看出,进行两轮迭代即可得到高质量伪标签,再进行多轮实验,伪标签准确率提升有限。因此,本文通过两轮迭代,生成未标注数据的伪标签。

4.8 有噪样本对分类性能的影响

为了验证有噪伪标签对分类性能的影响,本文将提出的方法与代表性的5种有噪样本学习方法,包括GCE, PENCIL, SCE, Co-teaching, Co-teach-

表6 不同伪标签生成方法的结果对比

方法	伪标签数量	伪标签准确率 (%)
一次性伪标签生成	/	82.00
一次性伪标签生成+模型集成	/	83.96
渐进伪标签生成+置信度阈值	201	85.50
渐进伪标签生成+置信度阈值+模型集成	146	87.00

ing+等进行了对比。表8列出了采用不同有噪样本学习方法得到的对比实验结果,取10次实验的平均分类准确率作为实验结果,主干网络均使用Resnet18。表8中所有数据均是将目标域生成的伪标签和少量标注样本一起用于训练得到的结果。

从表8可以看出,直接利用生成的伪标签和少量的标注数据对模型进行训练,准确率仅为87.50%。这是因为伪标签中含有一定的噪声。而采用有噪样本学习方法,均可以不同程度地提升分类准确率。与其他有噪样本学习策略相比,本文方法能取得最优的分类性能,相比其他方法有0.5%~3%的提升。

4.9 与其他域自适应方法对比

为了验证本文提出跨域舌色分类方法的有效性,将其与现有的代表性域自适应方法最小最大熵(MiniMax Entropy, MME)^[18]、CDAC^[20]、Adama-tch^[26]等进行了对比。

由于目前还没有跨域舌色分类的相关研究工作,为了保证公平对比,将对比方法在与本文方法在相同设置下重新进行训练,结果如表9所示。从表9可以看出,本文提出的双阶段元学习域自适应方法取得最优的分类性能,达到了91.3%。相比于其他的域自适应方法,分类性能提升了2%以上,充分验证了本文方法的有效性。

4.10 消融实验

本文进行了消融实验,以验证所提算法中各个部分的有效性。基线方法以ResNet18作为主干网

表7 渐进高质量伪标签生成的轮次结果对比

方法	高质量伪标签	伪标签准确率 (%)
第1轮	146	87.00
第2轮	140	88.10
第3轮	145	88.19
第4轮	148	88.16

表8 不同有噪样本学习方法的分类结果对比(%)

方法	基于最优伪标签+少量标注的分类准确率
直接训练	87.50
GCE	90.01
PENCIL	87.76
SCE	90.25
Co-teaching	89.86
Co-teaching+	89.98
CTR	90.35
CTR+GCE	90.80
本文方法(CTR+SCE)	91.30

络，依次加入双阶段元学习、渐进高质量伪标签生成和有噪样本学习部分，舌色分类准确率对比结果如表10所示。从实验结果中可以看出，采用基线方法分类准确率仅为76.8%。加入双阶段元学习后，分类结果提升了5.5%，达到了82.3%，这说明双阶段元学习可以显著提升跨域舌色分类性能。结合渐进高质量伪标签生成策略，目标域舌色分类精度进一步提升了5.2%。在此基础上进行有噪样本学习，分类准确率又提升了3.8%，达到了91.3%。与目标域采用所有标注样本进行有监督学习相比，分类性能仅差2.05%。

表9 不同域自适应方法的结果对比(%)

方法	分类准确率
MME	82.6
CDAC	83.8
Adamatch	89.1
本文方法	91.3

表10 消融实验(%)

ResNet18	双阶段元学习	渐进高质量伪标签生成	CTRR+SCE	分类准确率
√				76.8
√	√			82.3
√	√	√		87.5
√	√	√	√	91.3

5 结论

本文针对中医舌色分类模型跨域鲁棒性差的问题，提出了一种基于双阶段元学习的小样本中医舌色域自适应分类方法，以提高舌色分类模型的泛化性。通过实验，可以得到如下结论：

(1) 双阶段元学习训练策略可以从大规模数据集中学习到通用的分类知识，将这些知识迁移到舌色分类数据集上，可以有效提升了舌色分类性能；

(2) 一次生成伪标签会导致其中出现大量的不准确标签，导致分类性能不高。而渐进伪标签生成可以有效提升伪标签的质量，提升分类准确率；

(3) 由于伪标签中不可避免地含有噪声，采用具有噪声样本抑制特性的损失函数对模型进行训练可以大大提升分类性能。在自建的两个中医舌色分类数据集上的实验结果表明，本文提出的舌色分类方法在目标域仅给20张有标注样本情况下，目标域舌色分类准确率达到91.3%，与目标域有监督分类性能仅差2.05%，可以满足实际应用的需求，对于中医舌象仪的推广应用具有重要意义。

参考文献

- [1] 孙亮亮. 有噪声标注下的中医舌色分类研究[D]. [硕士学位论文], 北京工业大学, 2022.
SUN Liangliang. Research on the classification of TCM tongue color under noisy labeling[D]. [Master dissertation], Beijing University of Technology, 2022.
- [2] HOU Jun, SU Hongyi, YAN Bo, *et al.* Classification of tongue color based on CNN[C]. 2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA), Beijing, China, 2017: 725–729. doi: [10.1109/ICBDA.2017.8078731](https://doi.org/10.1109/ICBDA.2017.8078731).
- [3] FU Shengyu, ZHENG Hong, YANG Zijiang, *et al.* Computerized tongue coating nature diagnosis using convolutional neural network[C]. 2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA), Beijing, China, 2017: 730–734. doi: [10.1109/ICBDA.2017.8078732](https://doi.org/10.1109/ICBDA.2017.8078732).
- [4] QU Panling, ZHANG Hui, ZHUO Li, *et al.* Automatic analysis of tongue substance color and coating color using sparse representation-based classifier[C]. 2016 International Conference on Progress in Informatics and Computing (PIC), Shanghai, China, 2016: 289–294. doi: [10.1109/PIC.2016.7949512](https://doi.org/10.1109/PIC.2016.7949512).
- [5] LI Yanping, ZHUO Li, SUN Lianglian, *et al.* Tongue color classification in TCM with noisy labels via confident-learning-assisted knowledge distillation[J]. *Chinese Journal of Electronics*, 2023, 32(1): 140–150. doi: [10.23919/cje.2022.00.040](https://doi.org/10.23919/cje.2022.00.040).
- [6] 卓力, 孙亮亮, 张辉, 等. 有噪声标注情况下的中医舌色分类方法[J]. *电子与信息学报*, 2022, 44(1): 89–98. doi: [10.11999/JEIT210935](https://doi.org/10.11999/JEIT210935).
ZHUO Li, SUN Liangliang, ZHANG Hui, *et al.* TCM tongue color classification method under noisy labeling[J]. *Journal of Electronics & Information Technology*, 2022, 44(1): 89–98. doi: [10.11999/JEIT210935](https://doi.org/10.11999/JEIT210935).
- [7] GRETTON A, SMOLA A, HUANG Jiayuan, *et al.* Covariate shift by kernel mean matching[M]. QUIÑONERO-CANDELA J, SUGIYAMA M, SCHWAIGHOFER A, *et al.* Dataset Shift in Machine Learning. Cambridge: The MIT Press, 2008: 131–160. doi: [10.7551/mitpress/9780262170055.003.0008](https://doi.org/10.7551/mitpress/9780262170055.003.0008).
- [8] GOPALAN R, LI Ruonan, and CHELLAPPA R. Domain adaptation for object recognition: An unsupervised approach[C]. 2011 International Conference on Computer Vision, Barcelona, Spain, 2011: 999–1006. doi: [10.1109/ICCV.2011.6126344](https://doi.org/10.1109/ICCV.2011.6126344).
- [9] PAN S J, TSANG I W, KWOK J T, *et al.* Domain adaptation via transfer component analysis[J]. *IEEE Transactions on Neural Networks*, 2011, 22(2): 199–210. doi: [10.1109/TNN.2010.2091281](https://doi.org/10.1109/TNN.2010.2091281).
- [10] JHUO I H, LIU Dong, LEE D T, *et al.* Robust visual

- domain adaptation with low-rank reconstruction[C]. 2012 IEEE Conference on Computer Vision and Pattern Recognition, Providence, USA, 2012: 2168–2175. doi: [10.1109/CVPR.2012.6247924](https://doi.org/10.1109/CVPR.2012.6247924).
- [11] GRETTON A, BORGWARDT K M, RASCH M, *et al.* A kernel method for the two-sample-problem[C]. The 19th International Conference on Neural Information Processing Systems, Vancouver, Canada, 2006: 513–520.
- [12] SUN Baochen, FENG Jianshi, and SAENKO K. Correlation alignment for unsupervised domain adaptation[M]. CSURKA G. Domain Adaptation in Computer Vision Applications. Cham: Springer, 2017: 153–171. doi: [10.1007/978-3-319-58347-1_8](https://doi.org/10.1007/978-3-319-58347-1_8).
- [13] KULLBACK S and LEIBLER R A. On information and sufficiency[J]. *The Annals of Mathematical Statistics*, 1951, 22(1): 79–86. doi: [10.1214/aoms/1177729694](https://doi.org/10.1214/aoms/1177729694).
- [14] KANG Guoliang, JIANG Lu, YANG Yi, *et al.* Contrastive adaptation network for unsupervised domain adaptation[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Los Angeles, USA, 2019: 4888–4897. doi: [10.1109/CVPR.2019.00503](https://doi.org/10.1109/CVPR.2019.00503).
- [15] GLOROT X, BORDES A, and BENGIO Y. Domain adaptation for large-scale sentiment classification: A deep learning approach[C]. The 28th International Conference on International Conference on Machine Learning, Bellevue, USA, 2011: 513–520.
- [16] GANIN Y and LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]. The 32nd International Conference on International Conference on Machine Learning, Lille, France, 2015: 1180–1189.
- [17] ZHANG Xu, YU F X, CHANG S F, *et al.* Deep transfer network: Unsupervised domain adaptation[EB/OL]. <https://arxiv.org/abs/1503.00591>, 2015.
- [18] SAITO K, KIM D, SCLAROFF S, *et al.* Semi-supervised domain adaptation via minimax entropy[C]. 2019 IEEE/CVF International Conference on Computer Vision, Seoul, South Korea, 2019: 8049–8057. doi: [10.1109/ICCV.2019.00814](https://doi.org/10.1109/ICCV.2019.00814).
- [19] PÉREZ-CARRASCO M, PROTOPAPAS P, and CABRERA-VIVES G. Con²DA: Simplifying semi-supervised domain adaptation by learning consistent and contrastive feature representations[C]. 35th Conference on Neural Information Processing Systems (NeurIPS 2021), Sydney, Australia, 2021: 1558–1569. doi: [10.48550/arXiv.2204.01558](https://doi.org/10.48550/arXiv.2204.01558)
- [20] LI Jichang, LI Guanbin, SHI Yemin, *et al.* Cross-domain adaptive clustering for semi-supervised domain adaptation[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, USA, 2021: 2505–2514. doi: [10.1109/CVPR46437.2021.00253](https://doi.org/10.1109/CVPR46437.2021.00253).
- [21] BERTHELOT D, ROELOFS R, SOHN K, *et al.* AdaMatch: A unified approach to semi-supervised learning and domain adaptation[C]. The Tenth International Conference on Learning Representations, 2022: 4732–4782.
- [22] MISHRA N, ROHANINEJAD M, CHEN Xi, *et al.* A Simple neural attentive meta-learner[C]. 6th International Conference on Learning Representations, Vancouver, Canada, 2018: 3141–3158.
- [23] XU Zhixiong, CHEN Xiliang, TANG Wei, *et al.* Meta weight learning via model-agnostic meta-learning[J]. *Neurocomputing*, 2021, 432: 124–132. doi: [10.1016/j.neucom.2020.08.034](https://doi.org/10.1016/j.neucom.2020.08.034).
- [24] WANG Yisen, MA Xingjun, CHEN Zaiyi, *et al.* Symmetric cross entropy for robust learning with noisy labels[C]. 2019 IEEE/CVF International Conference on Computer Vision, Seoul, South Korea, 2019: 322–330. doi: [10.1109/ICCV.2019.00041](https://doi.org/10.1109/ICCV.2019.00041).
- [25] YI Li, LIU Sheng, SHE Qi, *et al.* On learning contrastive representations for learning with noisy labels[C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, USA, 2022: 16661–16670. doi: [10.1109/CVPR52688.2022.01618](https://doi.org/10.1109/CVPR52688.2022.01618).
- [26] VINYALS O, BLUNDELL C, LILLICRAP T, *et al.* Matching networks for one shot learning[C]. The 30th International Conference on Neural Information Processing Systems, Barcelona, Spain, 2016: 3637–3645. doi: [10.48550/arXiv.1606.04080](https://doi.org/10.48550/arXiv.1606.04080)
- [27] SUNG F, YANG Yongxin, ZHANG Li, *et al.* Learning to compare: Relation network for few-shot learning[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 1199–1208. doi: [10.1109/CVPR.2018.00131](https://doi.org/10.1109/CVPR.2018.00131).
- [28] FINN C, RAJESWARAN A, KAKADE S, *et al.* Online meta-learning[C]. The 36th International Conference on Machine Learning, Long Beach, USA, 2019: 1920–1930.
- 卓 力: 女, 教授, 博士生导师, 研究方向为医学影像处理、机器视觉和多媒体通信。
- 张 雷: 男, 硕士生, 研究方向为人工智能系统设计与集成。
- 贾童瑶: 女, 博士生, 研究方向为图像增强。
- 李晓光: 男, 副教授, 硕士生导师, 研究方向为医学影像处理和超分辨率图像复原。
- 张 辉: 男, 副教授, 硕士生导师, 研究方向为机器视觉和嵌入式系统。

责任编辑: 余 蓉