

基于样本对元学习的小样本图像分类方法

李维刚,甘平,谢璐,李松涛

(武汉科技大学冶金自动化与检测技术教育部工程研究中心,湖北武汉 430081)

摘要: 本文针对小样本图像分类问题,提出一种基于样本对的元学习(Pairwise-based Meta Learning, PML)方法. 利用传递迁移学习对预训练好的 Resnet50 模型进行微调,得到一个更适应小样本任务的特征编码器,将该特征编码器作为元学习模型的初始特征编码器来训练模型,进一步增强了元学习模型的泛化能力;同时,本文还基于支持集与查询集样本之间的相似性提出元损失函数(Meta Loss, ML),其考虑了特征空间中查询集所有样本的相互关系,以此来缩小正样本类内距离,增加正负样本类间距离,从而提高分类精度. 实验结果表明,本文的方法在 1-shot、5-shot 任务上分别达到了 77.65%、89.65% 的分类精度,较最新的元学习方法 Meta-baseline 分别提高 7.38%、5.65%.

关键词: 小样本图像; 传递迁移学习; 元学习; 元损失函数

中图分类号: TP391.4

文献标识码: A

文章编号: 0372-2112(2022)02-0295-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20210453

A Few-Shot Image Classification Method by Pairwise-Based Meta Learning

LI Wei-gang, GAN Ping, XIE Lu, LI Song-tao

(Engineering Research Center for Metallurgical Automation and Measurement Technology (Ministry of Education), Wuhan University of Science and Technology, Wuhan, Hubei 430081, China)

Abstract: In this paper, a pairwise-based meta learning (PML) method is proposed for few-shot image classification. Transitive transfer learning is used to fine tune the pre-trained Resnet50 model to get a feature encoder that is more suitable for few shot task. The feature encoder is used as the initial feature encoder of the meta-learning model to train the model, which further enhances the generalization ability of the meta-learning model. Based on the similarity between the support set and the query set samples, a meta loss (ML) function is proposed, which considers the relationship between all the samples of the query set in the feature space, so as to reduce the within-class distance of positive samples and increase the between-class distance of positive and negative samples, thus improving the classification accuracy. The experimental results show that the classification accuracy of the methods in this paper is 77.65% and 89.65% on 1-shot and 5-shot tasks, respectively, and it is 7.38% and 5.65% higher than the latest meta-learning method, Meta-baseline.

Key words: few-shot image; transitive transfer learning; meta learning; meta loss function

1 引言

依靠大数据的监督学习模型极其依赖大量人工标注的标签样本. 在很多领域内, 由于缺乏足够的标签样本训练, 模型容易过拟合, 在测试时分类精度不理想. 简单的数据增强和正则化技术并不能使问题得到完全解决^[1]. 目前, 迁移学习与元学习成为解决这类小样本问题的有效方法, 它们都是利用先验知识在小样本任务中快速地掌握新的技能.

迁移学习^[2]运用已存在的知识对不同但相关领域

问题进行求解. 当目标域标签样本缺乏时, 只要源域和目标域相关, 迁移学习就能利用从源域中学习的知识帮助目标域模型进行训练, 实现已学习知识在相关领域间的复用和迁移. Pan 等^[3]将迁移学习方法分为基于样本、基于特征、基于关系以及基于模型四种. 其中, 基于特征的迁移是迁移学习领域中最热门的方向, 其主要思想是寻找“好”的特征表示来最小化域间差异, 但此方法在源域和目标域差异过大时效果不理想.

元学习^[4]是解决小样本问题的另一个重要途径, 它

将学过的知识再利用,让模型快速地学会新任务(Task)^[5].元学习方法分为基于优化、基于生成式模型、基于记忆单元以及基于度量四种.在分类问题中,基于度量的元学习方法^[1,6]拥有较高的性能表现.该方法在某一特征空间直接将特征对比度量来执行小样本分类任务,但该类方法对训练集样本数量要求较高,且性能对模型结构敏感度高.同时,元学习方法通常存在分类精度较低的问题.

对此,本文针对迁移学习、元学习目前困境提出基于样本对元学习(Pairwise-based Meta Learning, PML)的小样本图像分类方法.其利用传递迁移学习^[7]来解决源域与目标域差异过大的问题;同时依据Sun^[8]与Chen^[9]等的观点,搭建先“迁移学习”,再“元学习”的模型来改善性能;最后,针对元学习特殊的训练范式,提出了元损失函数(Meta Loss, ML),该损失函数利用样本对三种相似性来考虑特征空间中其他样本的影响,以此来扩大正负样本距离,提升PML模型的性能.

由于钢材的显微组织类型繁多,纹理复杂多变,人

工标注极其困难,难以构建大规模训练数据集,因此,仅有Lubbers^[10]、DeCost^[11]与Azimi^[12]等少数人进行了相关研究.然而,这些方法泛化能力过弱,面对训练类别以外的新型钢材时,性能表现较差.针对此问题,本文构建了钢材显微组织小样本图像数据集并进行实验来验证PML模型的有效性,结果表明,PML方法具有较强的泛化能力,分类精度较佳.同时,本文将ML损失推广到其它元学习方法中,并在公开数据集mini-ImageNet^[13]、tiered-ImageNet^[14]上进行实验.结果表明,ML能改善元学习方法的性能,验证了ML损失具有一定通用性.

2 小样本图像分类方法

PML方法如图1所示,包含迁移学习模型与元学习模型两个模块.迁移学习模型利用传递迁移学习获得特征编码器 f_θ ,将其作为元学习模型的初始特征编码器.元学习模型采用余弦相似度度量支持集和查询集样本相似度,并利用ML损失优化 f_θ 参数,提高模型分类精度.具体阐述如下.

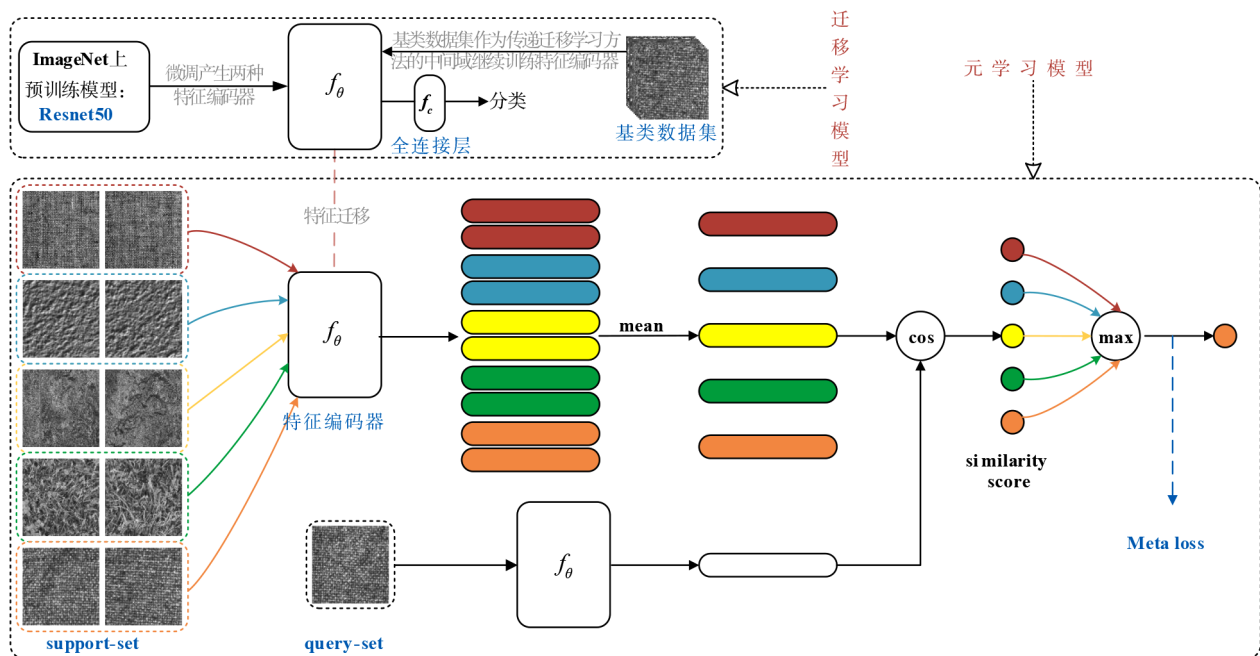


图1 PML方法示意图

2.1 迁移学习模型

构建迁移学习模型是为了获得一个特征编码器 f_θ ,该特征编码器需对新类数据集 \mathbb{N} (标签样本少)有泛化能力,且不会出现负迁移现象(指在源域上学习到的知识,对目标域上的学习产生负面作用).为了获得该特征编码器,本文参考传递迁移学习方法设计该模型,传递迁移学习原理如下所述:

传统迁移学习要求领域间足够相似,而当领域间

不相似时,传递迁移学习可利用处于领域间的若干领域,将知识传递式迁移.其训练范式如图2所示,通过将源域 D_s 的特征信息先传递给中间域 D_i ,中间域 D_i 再传递给目标域 D_t ,帮助预测函数 $f_t(x)$ 更好的执行任务 T_t .其中 D_s 与 D_i 具有微弱的相关性, D_s 与 D_i 、 D_i 与 D_t 有一定相关性,且 $D_s \neq D_i \neq D_t$.

本文使用交叉熵损失在与 \mathbb{N} 有一定相关性的基类数据集 \mathbb{B} (中间域)上训练两类初始网络,将删除 f_c 层后

得到的 f_θ 作为元学习模型的初始特征编码器. 其中, 两类初始网络分别为图3中 path2 路径(Resnet50^[15])与图3中丢弃 stage 5 模块的 path1 路径. 第二类初始网络较第一类初始网络参数量更少, 输出维度由 2048 维降至 1024 维, 训练速度更快, 但在某些任务中会损失一定分类精度.




图2 传递迁移学习训练范式

2.2 元学习模型

元学习与传统深度学习训练范式不同, 其分为元训练(Meta-training)与元测试(Meta-testing)两个阶段. 在元训练阶段从基类数据集 \mathbb{B} 抽取任务(每个任务随机选取不同类别的数据), 在这些任务中训练模型. 在元测试阶段, 仅提供少量标签样本, 即可对新类数据集

\mathbb{N} 进行分类.

具体来说, 每个任务随机抽取 \mathbb{B} 中 N 个类别各 K 个样本, 将其作为支持集. 再从这 N 个类别剩余数据中抽取 M 个样本作为查询集. 模型从支持集 $N \times K$ 个样本中学习, 以此来识别查询集 $N \times M$ 个样本的类别, 这种任务被称为 N -way K -shot 任务.

从 \mathbb{B} 中抽取大量 N -way K -shot 任务. 利用式(1)计算每个任务中支持集第 i 类样本 x^i 的特征向量均值 β_i , 作为该类质心. 让查询集中样本 x 分别与 N 个类质心计算式(2), 得出相似度得分 p_i 的集合 p , 预测样本 x 为相似度得分最高的类别, 并通过最小化损失函数来优化 f_θ 参数. 其中, 式(2)中 $\langle \cdot, \cdot \rangle$ 表示两个向量的内积, β_i 也可视为新 f_c 层的预测权重.

$$\beta_i = \frac{1}{K} \sum_{j=1}^K f_\theta(x_j^i) \quad (1)$$

$$p_i = \frac{\langle f_\theta(x), \beta_i \rangle}{\|f_\theta(x)\| \|\beta_i\|} \quad (2)$$

元测试即图4中 Meta-testing 过程, 其在新类数据集 \mathbb{N} 上执行与元训练过程相似的步骤. 本文中迁移学习模型利用元测试方法进行评估.

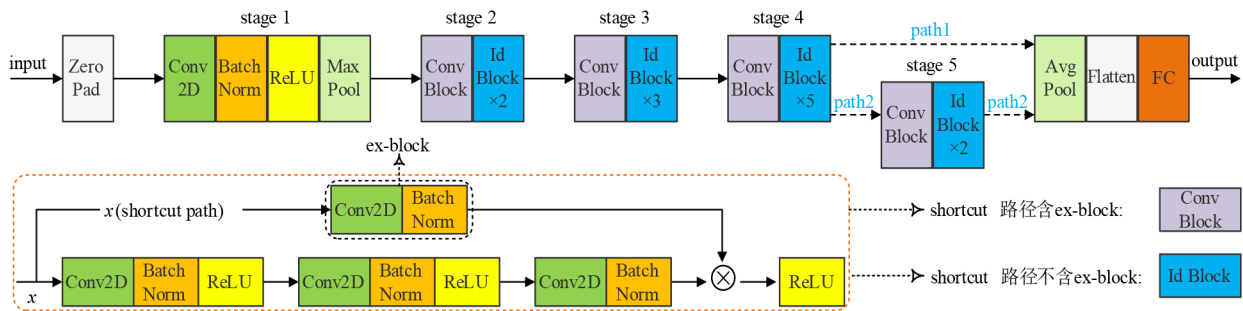


图3 初始网络

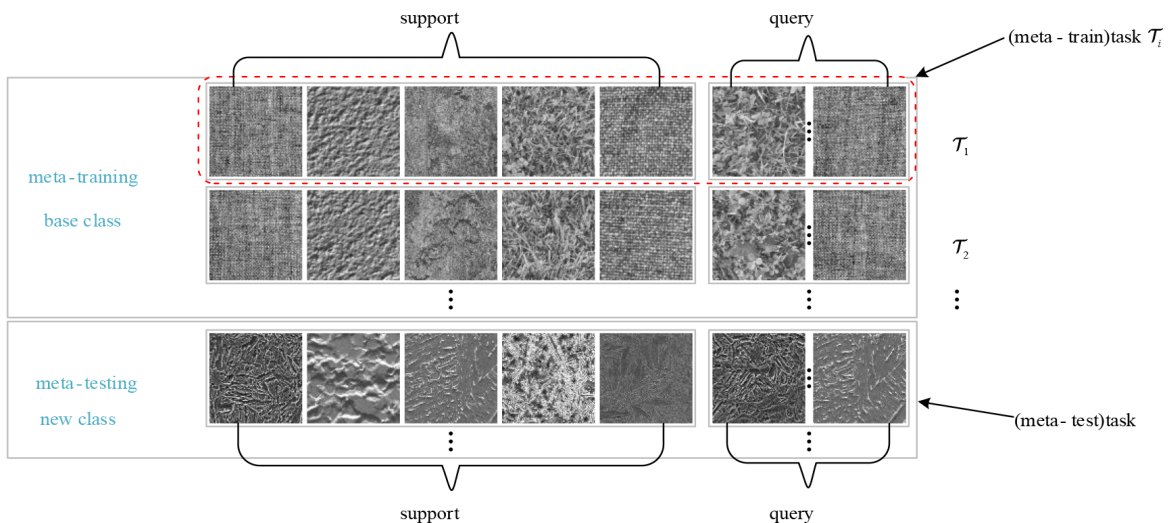


图4 5-way 1-shot元学习范式

3 元损失函数

目前,元学习大多采用交叉熵损失,其只片面考虑查询集中单个样本与支持集样本的关系,并未考虑其它样本对该样本的影响.对此,本文基于多相似性损失(Multi-Similarity Loss, MS Loss)^[16],提出了能考虑查询集所有样本关系的元损失函数ML.详细介绍如下.

3.1 多相似性损失函数

将所有样本的特征向量依次设为锚点并与其余样本两两配对,可以构造多个样本对,利用样本对的余弦相似度来度量样本对中两个样本的距离.余弦相似度越大,即两个样本越相似,特征向量距离越近.如式(3)所示,余弦相似度即计算样本对中两个样本特征向量 x_i, x_k 的内积,式(2)中相似度得分 p 是余弦相似度在元学习范式中的应用.

$$S_{ik} = \langle x_i, x_k \rangle = \frac{x_i \cdot x_k}{\|x_i\| \|x_k\|} \quad (3)$$

目前,大多数度量方法都是利用样本对的自相似性来进行样本对加权,相似性可分为自相似性S、正相对相似性P与负相对相似性N三种.Wang等^[16]在Cars-196数据集上进行实验,证明了三种相似性均有正增益,详细实验结果见表1.其中,自相对性S对实验结果影响最大.




图5 三种样本对相似性示意图

Wang等^[16]将基于样本对的损失函数 \mathcal{L} 描述成通用对加权(GPW)框架,利用该框架将 \mathcal{L} 转换为式(4)中计算逐对(pair-wise)相似性的加权:

$$\mathcal{L}(S, y) = \sum_{i=1}^m \left(\sum_{y_j \neq y_i} \omega_{ij} S_{ij} - \sum_{y_j = y_i} \omega_{ij} S_{ij} \right) \quad (4)$$

其中, m 为样本总数, S_{ij} 为样本对 $\{x_i, x_j\}$ 的余弦相似度, y 为样本标签, ω_{ij} 为样本对 $\{x_i, x_j\}$ 的权重.Wang等人在式(4)的基础上,结合上述样本对三种相似性提出了MS损失.计算如式(5)所示:

$$\mathcal{L}_{MS} = \frac{1}{m} \sum_{i=1}^m \left\{ \frac{1}{\alpha} \log \left[1 + \sum_{k \in \mathcal{P}} e^{-\alpha(S_{ik} - \lambda)} \right] + \frac{1}{\beta} \log \left[1 + \sum_{k \in \mathcal{N}} e^{\beta(S_{ik} - \lambda)} \right] \right\} \quad (5)$$

其中, \mathcal{P} 和 \mathcal{N} 分别表示正、负样本集合, α, β 为超参数.

表1 三种相似性在图像检索任务上的性能表现
(数据来源于文献[16])

Recall	S/%	N/%	P/%	SN1/%	SN2/%	SP/%	NP/%	SNP/%
1	71.9	69.7	67.0	70.4	73.2	74.6	72.2	77.3
2	80.0	79.3	77.4	79.5	81.5	83.8	81.7	85.3
4	86.4	86.2	84.7	86.2	87.6	89.7	88.0	90.5
8	91.0	91.0	90.0	91.1	92.6	94.1	92.4	94.2

自相似性S即计算样本对 $\{x_i, x_k\}$ 本身的余弦相似度,它确保在特征空间中正类比负类样本距离锚点更近.我们把余弦相似度较大的负对(不同类别样本对)和余弦相似度较小的正对(同类样本对)称为困难样本对,其信息量更大,更值得模型去学习.如图5中情况1,负对 $\{\text{anchor}, \text{neg1}\}$ 相较于其余负对有更大的余弦相似度,该对即为困难负对.

显然,相似性S只片面描述了样本对自身的相似性,没有考虑到特征空间中其余样本的影响.相对相似性结合其他样本与锚点之间的关系解决了这种局限性.图5以负样本neg1为例,结合情况1、2可知负相对相似性随着其他负对的余弦相似度增加而降低;结合情况2、3可知正相对相似性随着正对的接近而降低.正样本相对相似性与之类似.

公式前半部分控制正样本的紧密程度,对余弦相似度 $< \lambda$ 的正样本进行惩罚;公式后半部分同理.

3.2 基于多相似性的元损失函数

为了更适应元学习训练范式,本文以MS损失为基础提出了元损失函数ML,详见式(6).元损失函数是通过图6所示的样本对挖掘和加权两个迭代步骤来实现的.对比式(5),式(6)中 \mathcal{L}_{ML} 只以支持集样本的质心作为锚点,并增加了两个超参数 $\mu(\mu \neq 1)$ 和 $\eta(\eta \neq \lambda)$,具体说明如下:

$$\mathcal{L}_{ML} = \frac{1}{N} \sum_{a=1}^N \left\{ \frac{1}{\alpha} \log \left[\mu + \sum_{k \in \mathcal{P}} e^{-\alpha(S_{ak} - \eta)} \right] + \frac{1}{\beta} \log \left[\mu + \sum_{k \in \mathcal{N}} e^{\beta(S_{ak} - \lambda)} \right] \right\} \quad (6)$$

3.2.1 改进的样本对挖掘方案

训练所有样本对耗时过长;而随机采样会被冗余样本对淹没,导致收敛速度慢,模型退化.对此,MS损

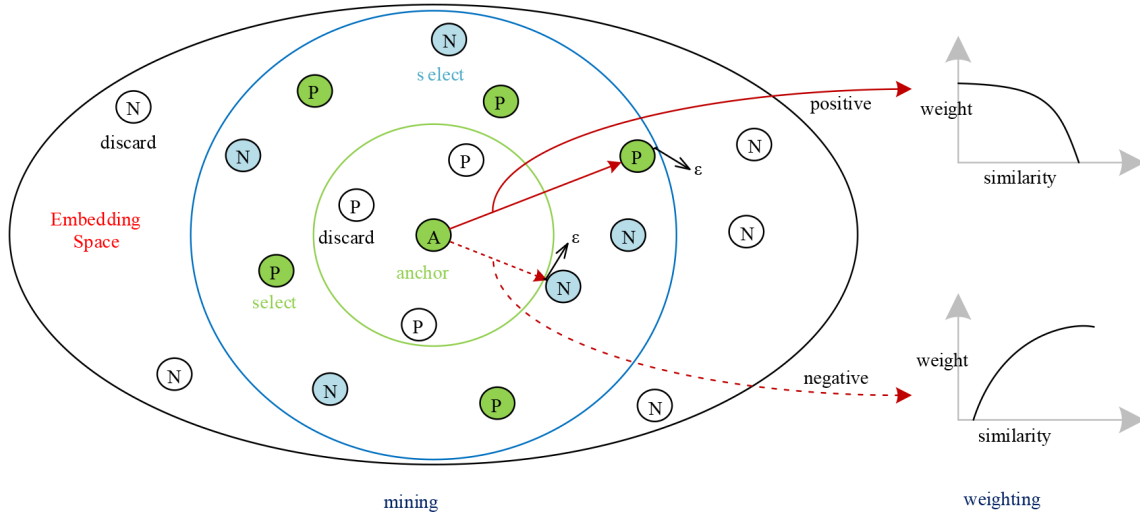


图6 对挖掘和对加权示意图

失通过挖掘困难样本对改善了上述问题。

但在元训练任务中,MS损失是不可行的,这是因为图4中元学习范式希望查询集样本以支持集样本为基准进行分类;而MS损失会存在支持集样本以查询集(此时作锚点)样本为基准进行分类。

对此,本文受到LMNN^[17]、MS损失^[16]的启发,设计了一种如图6所示适用于元训练范式的挖掘方案。具体而言,本文的挖掘方案只将支持集样本设为锚点,锚点与查询集样本两两配对。然后利用正相对相似性P构造式(7)来挖掘信息量丰富的困难负对,构造式(8)来挖掘信息量丰富的困难正对,同时丢弃其余信息量少的样本对。

$$S_{ai}^- > \min_{S_{aP}^-} S_{aP}^- - \epsilon \quad (7)$$

$$S_{aj}^+ < \max_{S_{aN}^+} S_{aN}^+ + \epsilon \quad (8)$$

其中, S_{ai}^- 为挖掘的负样本对, S_{aj}^+ 为挖掘的正样本对, S_{aP}^- 、 S_{aN}^+ 分别为锚点 x_a 与所有正、负样本的余弦相似度集合, ϵ 是给定的阈值,挖掘流程如下:

输入: 一个任务内所有样本

- 1、利用式(1)求出特征空间中支持集 N 类样本的质心集合 x_a ;
- 2、 x_a 与特征空间中查询集所有样本两两配对,得到样本对集合 R ;
- 3、利用式(3)计算集合 R 中各个样本对的余弦相似度 S ;
- 4、找出正样本对集合 $\mathcal{P} \in R$ 中最小余弦相似度样本对 $\{a, \mathcal{P}\}_{\min}$;
- 5、找出负样本对集合 $\mathcal{N} \in R$ 中最大余弦相似度样本对 $\{a, \mathcal{N}\}_{\max}$;
- 6、负样本对 $\{x_a, x_i\}$ 的余弦相似度 S_{ai}^- 满足式(7)则保留该样本对;
- 7、正样本对 $\{x_a, x_j\}$ 的余弦相似度 S_{aj}^+ 满足式(8)则保留该样本对;
- 8、抛弃其余样本对;

输出: 已保留样本对的集合

3.2.2 改进的样本对加权策略

利用正相对相似性P可以粗略挖掘困难样本对,再结合相似性S和N,可以进一步对样本对加权。具体而言,给定负样本对 $\{x_a, x_i\}, i \in \mathcal{N}$, 式(9)为权重 ω_{ai}^- (式(6)中 S_{ai} 的偏导数), 其对余弦相似度 $> \lambda$ 的负样本进行惩罚; 正样本对 $\{x_a, x_j\}, j \in \mathcal{P}$ 的权重 ω_{aj}^+ 计算见式(10), 其对余弦相似度 $< \eta$ 的正样本进行惩罚。不同的惩罚阈值可以扩大正负样本差异,更易于区分。同时,针对最重要的自相似性S,引入 μ 来改变其在权重中占比。实验证明,此样本对加权策略在基类 \mathcal{B} 与新类 \mathcal{N} 上皆有增益。

$$\begin{aligned} \omega_{ai}^- &= \frac{1}{\mu e^{\beta(\lambda - S_{ai})} + \sum_{k \in \mathcal{N}'} e^{\beta(S_{ak} - S_{ai})}} \\ &= \frac{e^{\beta(S_{ai} - \lambda)}}{\mu + \sum_{k \in \mathcal{N}'} e^{\beta(S_{ak} - \lambda)}} \end{aligned} \quad (9)$$

$$\omega_{aj}^+ = \frac{1}{\mu e^{-\alpha(\eta - S_{aj})} + \sum_{k \in \mathcal{P}'} e^{-\alpha(S_{ak} - S_{aj})}} \quad (10)$$

图7中当1、2、3为负样本时,由式(9)可知负样本对 $\{A, 1\}$ 权重 ω_{ai}^- 大小为: Case 1 > Case 2 > Case 3。当1、2、3为正样本时,由式(10)可知正样本对 $\{A, 1\}$ 权重 ω_{aj}^+ 大小为: Case 3 > Case 2 > Case 1。




图7 样本对权重示意图

4 实验结果与分析

本文方法基于 Pytorch 实现. 图像大小为 224×224 , 采用 AdamW^[18] 优化算法, 学习率随代数线性衰减. 迁移学习训练批次为 100, 迭代 200 次, 初始学习率为 $1e-6$. 元学习模型执行 5-way 1-shot 和 5-shot 任务 (表 4 例外), 查询集大小 5×15 , 训练每代 300 个任务, 评估每代 100 个任务, 共 50 代. 初始学习率为 $1e-8$. 超参数 α, β 分别

为 2, 50.

4.1 数据集及评价指标介绍

本文从武汉科技大学耐火材料与冶金国家重点实验室获取钢材显微组织图像, 构建新类数据集 N , 将其应用于元测试过程, 以此来评估 PML 方法. N 由不同放大倍数下的单相和多相显微组织图像组成, 共计 10 个类别, 部分类别示意图如图 8 所示.

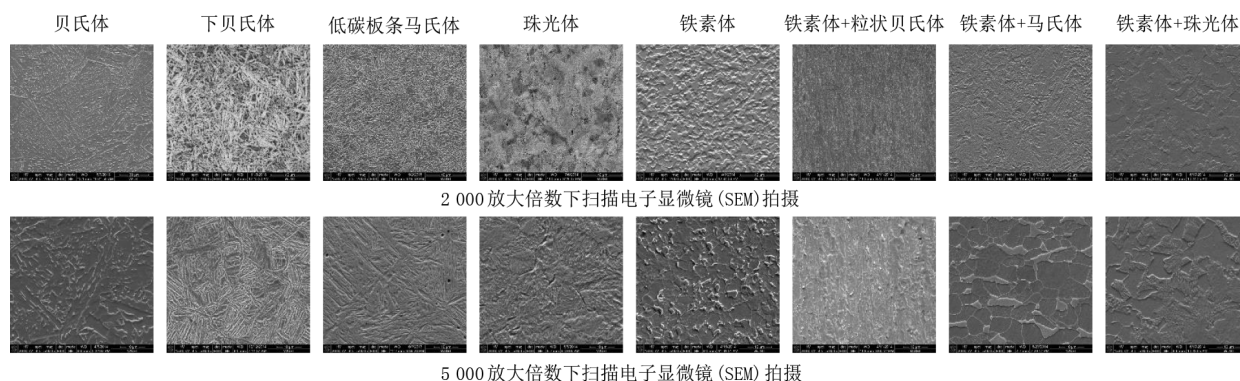


图 8 钢材显微组织示意图

同时, 本文选取与新类数据集 N 相似的公开数据集 Kylberg Texture Dataset 作为基类数据集 B . 该数据集

由 28 个类别组成, 与 N 一样, 都是由灰度纹理图像组成, 部分类别示意图如图 9 所示.




图 9 Kylberg Texture 数据集 B 部分类别示意图

另外, 本文还利用基准数据集 mini-ImageNet 与 tiered-ImageNet 来评估 ML 损失. 评价指标为 N 个样本平均精度 P 在 95% 置信水平下的置信区间 ($Z=1.96$), 置信区间半径 R_{interval} 如式 (11) 所示.

$$R_{\text{interval}} = Z \sqrt{\frac{P(1-P)}{N}} \quad (11)$$

4.2 多相似性损失函数的对比实验

为了验证 ML 中样本对挖掘方案与加权策略的重要性, 本文在相同实验设置下, 针对 ML 挖掘与加权方法进行相关研究, 其中, 超参数 ε 设置为 0.1.

首先使用本文加权策略, 将本文与 MS 损失的挖掘方案在 5-way 1-shot 和 5-shot 任务上实验. 如表 2 所示, 本文挖掘方案优于 MS 损失挖掘方案. 同时, 1-shot 与 5-shot 任务分别使用 2 048 维、1 024 维的特征编码器时分类精度更高. 根据 Zeiler 等^[19] 的研究, 推测其原因是因为该数据集纹理特征偏多, 当执行 1-shot 任务时, 支持集样本过少, 需要高层语义信息的辅助分类; 而当执行

5-shot 任务时, 较多的支持集样本提取的纹理信息足以区分样本, 无需高层语义信息. 此外, 本文的挖掘方案在 1-shot 任务上, 训练速度分别提升了 45%、33%.

接着, 本文将式 (6) 中超参数 μ 改为 1, 命为 ML- μ 损失; 将 η 改为 λ , 命为 ML- η 损失. 最后, 使用两种特征编码器, 以相同的实验设置, 在 5-way 1-shot 和 5-shot 任务中, 将交叉熵损失、MS 损失、使用本文挖掘方案的 MS 损失、ML- μ 损失、ML- η 损失与 ML 损失在 N 上进行评估, 实验结果见表 3.

由表 3 可知, (1) MS 损失效果不如交叉熵损失; (2) 综合②、③可知, 本文挖掘方案性能更佳; (3) 综合③、④、⑤可知, μ, η (实验优选值) 能提升分类精度, 证明了改变相似性 S 权重占比和以不同阈值对正负样本惩罚皆能提升性能; (4) 综合表 3 可知, ML 精度最佳, 同时输出 2 048 和 1 024 维的特征编码器分别适配 1-shot 与 5-shot 任务, 这与表 2 结果相同. 因此, 后续实验保持此特征编码器设置.

表 2 不同挖掘方法下样本平均精度(%)的置信区间及单个训练任务耗时的对比

Task	Weighting	Mining	Class B	Class N	Time/Train task	Weight File Size
1-shot 1 024 维	Our method	Our method	98.85±0.14	75.87±0.97	0.176 s	33 581 KB
		MS mining method	98.57±0.16	75.09±0.98	0.256 s	
1-shot 2 048 维	Our method	Our method	99.14±0.12	76.81±0.96	0.192 s	92 145 KB
		MS mining method	98.79±0.14	76.16±0.96	0.256 s	
5-shot 1 024 维	Our method	Our method	99.50±0.09	89.63±0.69	0.224 s	33 581 KB
		MS mining method	99.44±0.10	89.45±0.70	0.288 s	
5-shot 2 048 维	Our method	Our method	99.76±0.06	88.40±0.73	0.224 s	92 145 KB
		MS mining method	99.64±0.08	88.00±0.74	0.288 s	

表 3 不同损失函数在新类 N 上样本平均精度(%)的置信区间对比

Index	Loss	Setup	1-shot/1 024 维	1-shot/2 048 维	5-shot/1 024 维	5-shot/2 048 维
①	Cross entropy Loss		75.85±0.97	75.99±0.97	89.56±0.69	87.17±0.76
②	MS weighting+ MS mining	$\lambda=0.5$	74.97±0.98	75.97±0.97	89.43±0.70	87.93±0.74
③	MS weighting+Our mining	$\lambda=0.5$	75.51±0.97	76.69±0.96	89.60±0.69	88.21±0.73
④	ML- μ Loss	$\eta=0.9, \lambda=0.5$	75.60±0.97	76.72±0.96	89.61±0.69	88.32±0.73
⑤	ML- η Loss	$\mu=0.75, \lambda=0.5$	75.59±0.97	76.75±0.96	89.61±0.69	88.23±0.73
⑥	ML(our)	$\mu=0.75, \eta=0.9, \lambda=0.5$	75.87±0.97	76.81±0.96	89.63±0.69	88.40±0.72

4.3 迁移学习模型对元学习模型的作用

Sun^[8]和Chen^[9]等认为迁移学习能提高元学习模型性能. 本文基于此观点将迁移学习获得的特征编码器作为元学习模型的初始特征编码器. 为证实此观点, 本文以相同实验设置将图 3 中在 ImageNet 上预训练的初始网络(Pre-training model)、图 1 中元学习模型(Meta model)、未在 ImageNet 上预训练的 PML 方法(PML-P)、未用基类数据集微调的 PML 方法(PML-F)、迁移学习模型(Transfer model)以及本文的 PML 方法, 按元测试方法在新类 N 上评估. 结果如图 10 所示.

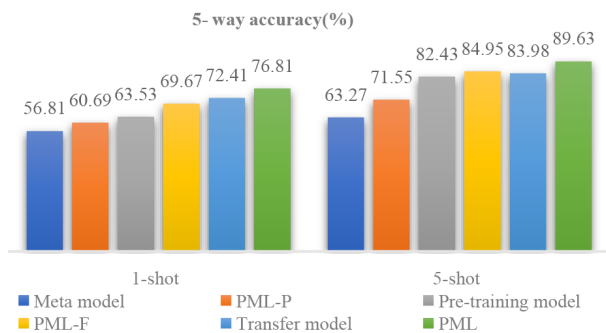


图 10 不同模型在新类样本上的平均精度 (%)

对比图 10 中 PML-P、PML-F、PML 与 Meta model, 可以看出 Meta model 精度最低, 证明了迁移学习能优化元学习模型性能; Pre-training model 与 Transfer model、PML-F 与 PML 两组对比验证了传递迁移学习的有效性. 为了进一步展示 PML 较强的泛化性, 本文从基类 B 中抽取大量 2-way 5-shot 任务并训练, 按元测试方法在新类 N 上评估, 结果见表 4. 综合图 10、表 4 可知, 迁移

学习模型一个潜在的重要能力是提高元学习模型的可转移性. PML 方法正是利用此能力来提高模型的泛化性.

表 4 不同模型下 2 类样本平均精度(%)的置信区间

Model	Transfer model		PML	
	1-shot	5-shot	1-shot	5-shot
Class N	88.57±1.14	95.17±0.77	92.27±0.96	96.97±0.61

4.4 困难样本对的选取对精度影响的探究

式(7)、(8)中超参数 ϵ 约束 ML 挖掘困难样本对的范围. 为了探寻 ϵ 对精度的影响, 本文以相同的实验设置对 ϵ 取值进行实验, 具体结果见图 11, 其中 ϵ 取 0.5 时即挖掘所有样本对, 不丢弃任何样本对.




图 11 新类数据集 N 上不同超参数 ϵ 取值下的分类精度

由图 11 可知, ML 挖掘的样本对过少时, 会丢失部分困难样本对, 模型无法充分学习, 性能下降; 而当 ML 挖掘的样本对过多时, 样本对是高度冗余的, 学习冗余样本对会导致模型退化, 性能下降.

同时, 本文将 ML 推广到 Chen^[9]等提出的 Meta-

由表 6、7 可知,在 mini-ImageNet 数据集上,Meta-Baseline 模型加 ML 损失在 1-shot、5-shot 任务上分类精度分别达到 64.10%、80.48%,较其他方法拥有更优异的性能表现. 在 tiered-ImageNet 数据集上也拥有较优的精度. 这表明,本文提出的 ML 损失能改善元学习性能,具有一定的通用性.

5 结论

针对现实中很多领域难以获得大量标签样本的问题,本文融合迁移学习、元学习,设计了一种小样本学习图像分类方法,较于最新的方法有着巨大的优势. 此方法主要由下述三个方面构成:

(1) 基于传递迁移学习方法,利用与目标域相似的中间域去训练初始分类网络,以此来避免负迁移现象的产生,提高网络泛化能力;

(2) 基于迁移学习与元学习在泛化能力上的差异,将元学习模型在迁移学习模型的基础上继续训练,进一步提高元学习模型泛化能力.

(3) 利用样本对三种相似性,提出适用于元学习的元损失函数. 其同时考虑了特征空间中查询集所有样本的关系,借此扩大不同类样本特征向量的差异,缩小同类样本特征向量的距离. 并将这种能力泛化到新类数据集上,从而提高元学习模型性能.

此外,ML 损失面对不同的数据集其最优表现选取的挖掘范围不同,这表明需要继续研究一种样本对自适应挖掘方案,加强 ML 损失的稳定性.

参考文献

- [1] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona, Spain: MIT Press, 2016: 3630-3638.
- [2] 季鼎承, 蒋亦樟, 王士同. 基于域与样例平衡的多源迁移学习方法[J]. 电子学报, 2019, 47(3): 692-699.
JI Ding-cheng, JIANG Yi-zhang, WANG Shi-tong. Multi-source transfer learning method by balancing both the domains and instances[J]. Acta Electronica Sinica, 2019, 47(3): 692-699. (in Chinese)
- [3] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge & Data Engineering, 2010, 22(10): 1345-1359.
- [4] 李凡长, 刘洋, 吴鹏翔, 等. 元学习研究综述[J]. 计算机学报, 2021, 44(2): 422-446.
LI Fan-chang, LIU Yang, WU Peng-xiang, et al. A survey on recent advances in meta-learning[J]. Chinese Journal of Computers, 2021, 44(2): 422-446. (in Chinese)
- [5] LAKE B, SALAKHUTDINOV R, GROSS J, et al. One shot learning of simple visual concepts[C]//Proceedings of the Annual Meeting of the Cognitive Science Society. California: eScholarship, 2011: 33(33).
- [6] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]//Proceedings of the International Conference on Neural Information Processing Systems. Massachusetts, USA: MIT Press, 2017: 4077-4087.
- [7] TAN B, SONG Y, ZHONG E, et al. Transitive transfer learning[C]//Proceedings of the 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, NY, USA: ACM, 2015: 1155-1164.
- [8] SUN Q, LIU Y, CHUA T S, et al. Meta-transfer learning for few-shot learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA: IEEE, 2019: 403-412.
- [9] CHEN Y, WANG X, LIU Z, et al. A new meta-baseline for few-shot learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE, 2020: 04390.
- [10] LUBBERS N, LOOKMAN T, BARROS K. Inferring low-dimensional microstructure representations using convolutional neural networks[J]. Physical Review E, 2017, 96(5): 052111.
- [11] DECOST B L, FRANCIS T, HOLM E A. Exploring the microstructure manifold: Image texture representations applied to ultrahigh carbon steel microstructures[J]. Acta Materialia, 2017, 133: 30-40.
- [12] AZIMI S M, BRITZ D, ENGSTLER M, et al. Advanced steel microstructural classification by deep learning methods[J]. Scientific Reports, 2018, 8(1): 2128.
- [13] LEE K, MAJI S, RAVICHANDRAN A, SOATTO S. Meta-learning with differentiable convex optimization[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA: IEEE, 2019: 10657-10665.
- [14] REN M, TRIANTAFILLOU E, RAVI S, et al. Meta-learning for semi-supervised few-shot classification[C]//Proceedings of the International Conference on Learning Representations. <https://openreview.net>, 2018: 1803.00676.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [16] WANG X, HAN X, HUANG W, et al. Multi-similarity

- loss with general pair weighting for deep metric learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA: IEEE, 2019: 5022-5030.
- [17] WEINBERGER K Q, SAUL L K. Distance metric learning for large margin nearest neighbor classification[J]. Journal of Machine Learning Research, 2009, 10(2): 207-244.
- [18] LOSHCHILOV I, HUTTER F. Decoupled weight decay regularization[C]//Proceedings of the European International Conference on Learning Representations(ICLR). <https://openreview.net>, 2017: 1711.05101.
- [19] ZEILERM D, TAYLOR G W, FERGUS R. Adaptive deconvolutional networks for mid and high level feature learning[C]//Proceedings of the International Conference on Computer Vision. Barcelona, Spain: IEEE, 2011: 2018-2025.
- [20] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//Proceedings of the International Conference on Machine Learning. New York, USA: ACM, 2017: 1126-1135.
- [21] SUNG F, YANG Y, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 1199-1208.
- [22] GHIASI G, LIN TY, LE Q V. Dropblock: A regularization method for convolutional networks[C]//Proceedings of the Advances in Neural Information Processing Systems(NIPS). Massachusetts, USA: MIT Press, 2018: 10727-10737.
- [23] LIU Y, SCHIELE B, SUN Q. An ensemble of epoch-wise empirical Bayes for few-shot learning[C]//Proceedings of the European Conference on Computer Vision. Berlin: Springer, Cham, 2020: 404-421.
- [24] CHEN Z, GE J, ZHAN H, et al. Pareto self-supervised training for few-shot learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, TN, USA: IEEE, 2021: 13663-13672.
- [25] QIAO S, LIU C, SHEN W, et al. Few-shot image recognition by predicting parameters from activations[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 7229-7238.
- [26] RUSU A A, RAO D, SYGNOWSKI J, et al. Meta-learning with latent embedding optimization[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA: IEEE, 2019: 1807. 05960.
- [27] CHEN WY, LIU YC, KIRA Z, et al. A closer look at few-shot classification[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA: IEEE, 2019: 1904. 04232.
- [28] MISHRA N, ROHANINEJAD M, et al. A simple neural attentive meta-learner[C]//Proceedings of the 6th International Conference on Learning Representations. <https://openreview.net>, 2018: 1707.03141.
- [29] MUNKHDALAI T, YUAN X, MEHRI S, et al. Rapid adaptation with conditionally shifted neurons[C]//Proceedings of the International Conference on Machine Learning. Stockholm, Sweden: PMLR, 2018: 3664-3673.
- [30] ORESHKIN B, L'OPEZ P R, LACOSTE A. Tadam: Task dependent adaptive metric for improved few-shot learning[C]//Proceedings of the Advances in Neural Information Processing Systems. USA Massachusetts: MIT Press, 2018: 721-731.

作者简介



李维刚 男,1977年生,湖北通城人. 博士、教授、博导,主要研究方向为人工智能与机器学习算法.



甘平(通讯作者) 男,1995年生,湖北武汉人. 硕士,主要研究方向为小样本学习、GAN. E-mail: 383615194@qq.com