

# 基于半监督多维度对比学习的噪声标签图像分类<sup>①</sup>



朱定局<sup>1</sup>, 叶展昊<sup>1</sup>, 何珂仪<sup>2</sup>

<sup>1</sup>(华南师范大学 人工智能学院, 佛山 528225)

<sup>2</sup>(华南师范大学 经济与管理学院, 广州 510006)

通信作者: 朱定局, E-mail: zhudingju@m.scnu.edu.cn

**摘要:** 基于深度学习的人工智能诊断模型严重依赖于高质量的详尽注释数据进行算法训练, 但受到噪声标签信息的影响. 为了增强模型的鲁棒性并防止有噪声的标签记忆, 本文提出了一种基于多维度对比学习的噪声标签图像分类方法, 该方法可以有效地融合多维度对比学习和半监督学习来对抗标签噪声. 具体来说, 提出的方法由 3 个精心设计的组件组成: 以混合增强图像为输入, 设计了具有动量更新机制的混合特征嵌入模块来挖掘抽象的分布式特征表示. 同时, 通过使用多维度对比学习模块, 结合实例对比学习和类间对比学习, 从不同维度对特征空间中的特征进行调整. 此外, 还利用噪声鲁棒损失函数来确保具有正确标签的样本在学习过程中占主导地位. 在 CIFAR-10 和 CIFAR-100 数据集上进行的实验表明, 我们的方法取得了比现有方法更好的结果.

**关键词:** 噪声标签; 对比学习; 半监督学习; 分类问题; 深度学习

引用格式: 朱定局, 叶展昊, 何珂仪. 基于半监督多维度对比学习的噪声标签图像分类. 计算机系统应用, 2025, 34(5): 151-158. <http://www.c-s-a.org.cn/1003-3254/9836.html>

## Noise Label Image Classification Based on Semi-supervised Multi-dimensional Contrastive Learning

ZHU Ding-Ju<sup>1</sup>, YE Zhan-Hao<sup>1</sup>, HE Ke-Yi<sup>2</sup>

<sup>1</sup>(School of Artificial Intelligence, South China Normal University, Foshan 528225, China)

<sup>2</sup>(School of Economics & Management, South China Normal University, Guangzhou 510006, China)

**Abstract:** Deep learning-based artificial intelligence diagnostic models rely heavily on high-quality and exhaustively annotated data for algorithm training, but they are affected by noise label information. To enhance the robustness of the model and prevent memorization of noise labels, this study proposes a noise label image classification method based on multi-dimensional contrastive learning. This method can effectively integrate multi-dimensional contrastive learning and semi-supervised learning to combat label noise. Specifically, the proposed method consists of three carefully designed components. A mixed feature embedding module with a momentum update mechanism is designed to extract abstract distributed feature representations using mixed augmented images as input. Simultaneously, the study adjusts the features in the feature space from different dimensions by employing a multi-dimensional contrastive learning module, which combines instance contrastive learning and inter-class contrastive learning. Additionally, a noise-robust loss function is utilized to ensure that samples with correct labels dominate the learning process. Experiments conducted on CIFAR-10 and CIFAR-100 datasets demonstrate that the proposed method achieves better results than existing methods.

**Key words:** noise label; contrastive learning; self-supervised learning; classification problem; deep learning

① 基金项目: 广东特支计划

收稿时间: 2024-10-17; 修改时间: 2024-10-30; 采用时间: 2024-11-28; csa 在线出版时间: 2025-02-26

CNKI 网络首发时间: 2025-02-27

## 1 引言

深度神经网络<sup>[1,2]</sup>作为一种引领人工智能领域前沿的技术,在各种任务中取得了显著的进展。然而,这种进展的实现严重依赖于拥有大规模高质量人工标注标签的数据集。但是现实世界中获得准确标注的过程却异常昂贵且耗费时间。这一问题引发了一个看似矛盾的困境:尽管大规模数据集是推动深度学习的引擎,但获取准确标签的难题却成为其发展的瓶颈。为填补这一鸿沟,基于网络搜索和用户标签的自动数据标注方法应运而生,不可避免地也引入了标签噪声<sup>[3,4]</sup>。在监督学习的框架下,标签噪声的存在严重威胁了模型的泛化性能和鲁棒性,从而对所得到的学习表示和分类边界的正确性造成了不可忽视的影响<sup>[5,6]</sup>。

近年来,学术界和工业界开始密切关注如何有效解决噪声标签的问题,以进一步提升深度学习技术的性能和可靠性。虽然已有的方法虽然取得了一定的进展,但仍然面临一系列的挑战。(1) 区分噪声标签和干净标签:如果模型无法准确地地区分噪声标签和干净标签,那么噪声标签可能会被错误地用于训练,导致模型学到错误的知识,影响模型的泛化性能和鲁棒性。所以需要开发有效的噪声标签检测算法用来辅助区分噪声标签和干净标签。(2) 降低噪声标签带来的分布偏移:分布偏移可能导致模型在真实场景中的表现不佳,甚至在一些未知领域中失效。通过降低分布偏移,可以提高模型的泛化性能,并使其更好地适应实际应用场景。(3) 解决噪声标签带来的分类边界破坏:噪声标签可能导致模型学到过于复杂或者不稳定的决策边界,降低了模型的鲁棒性。通过解决这个问题,可以提高模型在面对噪声标签时的性能,并增加模型对输入数据的稳健性。

最初,先前的研究<sup>[7,8]</sup>表明修改有噪声数据的损失函数可以使神经网络接近贝叶斯最优分类器,从而在干净数据上获得更好的性能<sup>[9,10]</sup>。在此理论基础上,Zhang等<sup>[9]</sup>提出了广义交叉熵损失,它结合了平均绝对误差和分类交叉熵损失的优点,收敛速度更快,泛化能力更高。Amid等<sup>[11]</sup>通过引入基于Tsallis散度的两个温度进一步扩大了GCE损失,从而提高了对标签噪声的鲁棒性。受Kullback-Leibler散度的对称性质的启发,Wang等<sup>[12]</sup>提出了一种噪声鲁棒对称交叉熵损失,利用对应的反向交叉熵损失来解决困难类学习和噪声标签

过拟合的问题。

转移矩阵估计已经被证明是一种有效的技术来减轻噪声标签的不利影响,它涉及利用学习到的转移概率来修改每个例子的影响。例如,Hendrycks等<sup>[13]</sup>直接使用了汇总噪声下一个类被翻转到另一个类的概率的矩阵。Cheng等<sup>[14]</sup>引入了流形嵌入方法,纳入平滑假设,目的是保持特征空间中实例之间的邻接关系与过渡矩阵空间中的邻接关系一致。为了解决训练数据中实例依赖的噪声问题,Yang等<sup>[15]</sup>提出利用从提取的示例中估计出的Bayes最优转移矩阵作为实例依赖的噪声转移矩阵。然而,这些方法的泛化性能高度依赖于估计转移矩阵和先验知识的准确性<sup>[16]</sup>。

与上述有监督学习方法相比,半监督学习最近被认为是解决有噪声标签问题的一种有效技术<sup>[17-19]</sup>。变换后的标签可以逐步规范有噪声标签的记忆效果,这给记忆带来了很大的好处。例如,Nguyen等<sup>[20]</sup>提出了一种自相似的半监督学习框架,该框架通过结合基于置信度的阈值来逐步从噪声数据中过滤出错误标记的示例,从而改变了从噪声标签中学习的问题。Li等<sup>[21]</sup>提出了DivideMix,这是一个噪声鲁棒框架,利用高斯混合模型基于半监督原则动态选择样本。同样,Zhou等<sup>[22]</sup>提出了两阶段学习策略之间的平滑过渡和相互作用,两阶段学习策略动态选择具有监督训练的干净训练样本和基于半监督学习的重新标记的噪声样本。如上所述,现实世界数据中存在的噪声可能是复杂而多样的,从随机的标签翻转到系统的错误标记。因此,为了设计一种有效的半监督学习方法,对噪声特性的详细理解仍然值得探索。

通过优化正样本和负样本之间的距离或相似性度量,对比学习的能力已经得到证实,有助于以无监督学习方式学习鲁棒性和判别性表征<sup>[23]</sup>。有监督对比学习作为对比学习的一种变体,通过强化标记数据提供的监督约束,在提高学习表征的可分性方面具有更强的判别能力<sup>[24]</sup>。最近,许多研究都提出充分利用对比学习来对抗标签噪声<sup>[25,26]</sup>。例如,Ortego等<sup>[26]</sup>提出了一种多目标插值训练方法MOIT,该方法联合利用对比学习和半监督学习来提高对标签噪声的分类性能。Li等<sup>[25]</sup>提出了Sel-CL,这是一种选择性监督的对比学习机制,通过引入自信对的概念并使用新的检测策略,提高了过滤噪声标签的能力。

针对上述研究内容,目前对于噪声标签问题的研

究还存在以下两个挑战: 1) 半监督学习技术的主要限制是它们假设噪声标签的分布类似于干净标签的分布. 不可避免地, 数据集中各种类型和水平的噪声的存在可以对半监督学习方法的性能构成重大挑战. 2) 此外, 在有噪声标签的情况下, 有监督对比学习技术的性能也受到监督信息质量的限制. 标签噪声会在实例之间的相似性关系中引入不一致, 导致不正确的配对和失真的表示.

在这样的背景下, 我们的研究旨在探究将半监督学习与对比学习相结合的潜在优势, 以更加有效地应对噪声标签所带来的挑战, 提出了一个基于多维度对比学习和半监督学习的噪声标签分类方法. 本文的主要创新点总结如下: 1) 本文提出了一个新的噪声标签学习框架, 该框架结合了多维度对比学习和半监督学习, 为在标签噪声存在的情况下实现鲁棒的特征表示提供了一个有前途的解决方案. 2) 我们提出了多维度对比学习方法, 通过结合实例对比学习和类间对比学习来缓解混合特征域之间的语义差异. 3) 引入了一个鲁棒的对比损失, 确保在对比学习损失中始终由正确的样本对主导损失, 减少错误的样本对产生的梯度更

新, 为模型框架提供更进一步的鲁棒性.

## 2 基于多维度对比学习和半监督学习的方法

### 2.1 概述

为了能够减少或消除噪声标签对模型和分类器产生的影响, 增强模型学习判别特征的能力和分类边界的鲁棒性, 本文提出了一种鲁棒的对比学习和半监督结合的方法, 该方法同时受益于半监督学习和对比学习, 用于对抗噪声标签并提高模型的稳定性和鲁棒性. 本文总体方法框架如图1所示. 在框架中主要包括3个方面: 1) 通过建立具有动量更新机制的多分支架构, 可以有效地从不同数据增强级别的增强图像中捕获抽象的特征表示. 2) 通过使用多维度对比学习模块, 结合实例对比学习和类间对比学习, 从不同维度对特征空间中的特征进行调整, 并且通过改进的损失函数, 进一步削弱错误的样本对在梯度回传中产生的损失和梯度更新. 3) 基于初始分类器提供的置信度得分, 引入灵活的伪标签替换策略, 以有效地选择置信度样本并生成伪标签, 从而实现更准确地监督信号重构. 在这一节中, 我们将会对3个重要方面分别进行全面的解释.

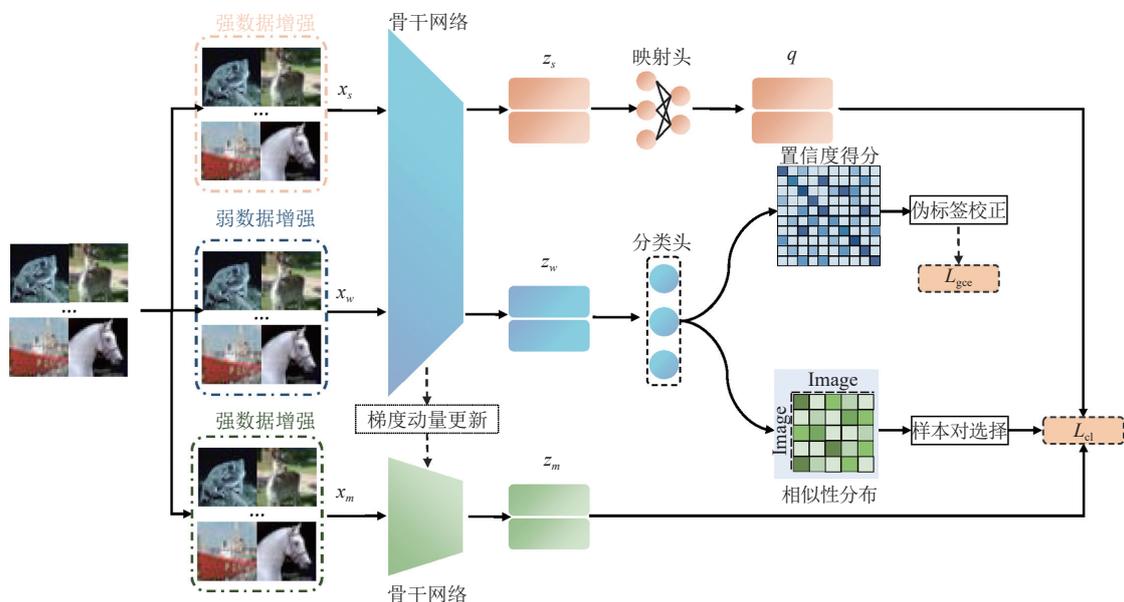


图1 网络框架图

### 2.2 数据增强

数据增强是一项重要的技术, 已经在各种机器学习和深度学习任务中得到广泛应用. 无论在有监督学习还是半监督学习中, 数据增强都有着重要的作用. 它

可以对原始数据进行扩充, 从而生成更加多样性的训练样本, 也可以帮助模型学习到数据本身的特征, 从而提高任务的性能和模型的泛化能力. 使用数据增强提供了显著的好处: 它通过在更广泛的增强样本上进行

训练来提高泛化,这有助于模型更好地泛化到未见过的数据并减少过拟合.它增强了鲁棒性,使模型更能抵抗噪声和对抗性示例,因为它适应了连续的数据变化.它作为一种正则化形式,平滑模型的决策边界,防止它对任何单个训练样本做出过于绝对的预测.

本文所提出的框架使用 Mixup、空间翻转和颜色空间变化的数据增强技术,其中 Mixup 数据增强技术是从每个小批中随机选择两个训练样本,通过在所选样本间进行线性插值来创建混合增强样本. Mixup 的原理可以定义为:

$$\tilde{x}_i = \lambda x_i + (1 - \lambda)x_j \quad (1)$$

其中,  $\tilde{x}_i$  是经过 Mixup 数据增强后的增强样本,其中  $x_i$  和  $x_j$  是从同一个 mini-batch 中随机抽取的训练样本,  $\lambda$  是一个用于控制混合比例的超参数,它的范围是  $\lambda \in [0, 1]$ . 如图 1 所示,对于输入图像  $x$  通过数据增强得到 3 张图像  $x_s$ 、 $x_m$  和  $x_w$ ,其中  $x_s$  和  $x_m$  是经过 Mixup、空间翻转和颜色空间变化数据增强后得到的强数据增强的图像,  $x_w$  则没有经过 Mixup 数据增强,只使用空间翻转和颜色空间变化的数据增强技术得到的弱数据增强图像.

### 2.3 多维度对比学习

为了减少标签噪声引起的标签分布偏移,构建了多维度对比学习模块,通过结合实例对比学习和类间对比学习来缓解混合特征域之间的语义差异.对比学习通过强制模型区分相似和不相似的样本,对比学习可以更有效地捕获底层数据分布.这使得提取的特征更具辨别性和泛化性,这对模型后续将特征用于分类起到了至关重要的作用.这种技术鼓励模型对相同输入的扰动版本产生稳定的预测.

我们所提出的框架使用 PreAct ResNet-18 作为骨干网络进行特征提取.图像  $x_s$ 、 $x_m$  和  $x_w$  经过骨干网络提取特征后得到特征  $z_s$ 、 $z_m$  和  $z_w$ .为了能够对图像的表达能力更强,即用于实例间对比学习的特征  $z_s$  和  $z_m$  尽可能的相似,通过加入映射头得到一个新的特征  $q$ .映射头将 128 维度的特征  $z_s$  先经过一个线性层变为 512 维度的,再对当前 mini-batch 内进行批量标准化操作,得到一个经过正则化的特征,再经过一个线性层将 512 维度的特征转换为 128 维度的特征  $q$ .因此特征  $z_s$  和  $q$  有着相同的空间大小和维度,但  $q$  有着更加判别性的特征.

整个框架由 3 条分支组成,包括两个骨干网络,其中一个骨干网络的权重更新是通过另一个骨干网络动量更新.动量更新机制可以定义为:

$$\theta_{f_2} = m\theta_{f_2} + (1 - m)\theta_{f_1} \quad (2)$$

其中,  $\theta$  表示的是骨干网络的网络权重,  $m \in [0, 1]$  是用于控制每次动量更新变化大小的权重.

在得到特征后就需要选择可靠的正样本对用于计算对比学习的损失.特征  $z_w$  经过分类器得到图像的分类置信度  $p$ ,我们可以计算两个图像的相似度分布情况,于是就可以在不知噪声率的情况下得到一个 mini-batch 中的可靠正样本对集合,具体公式如下:

$$G = \{(i, j) | p_i \cdot p_j \geq \gamma\} \quad (3)$$

其中,  $\gamma$  是一个相似度匹配阈值,用于控制可靠正样本对的数量.得到正样本对集合后,正样本对  $(i, j)$  的损失计算公式如下:

$$L_{icl} = \sum \log(1 - (q_i \cdot z_m)) \parallel \{(i, j) \in G\} \quad (4)$$

通过设计该损失函数能够避免错误的样本对所产生的负面影响.

类间对比学习策略是在最大边际聚类的原则基础上精心设计的<sup>[27]</sup>,为了最大限度地减少对标签的依赖,以促进模型的预测输出与语义标签的边际分布对齐.它侧重于对齐同一类中实例的特征表示,同时增加模型对于预测结果的自信程度.并且设计了一个类内损失,使属于同一类的实例在潜在嵌入空间中更接近,从而有助于为每个特定类形成更紧凑和定义良好的聚类.类内损失表示为:

$$L_{ccl} = \sum_{c=1}^C \left( \frac{P^c}{\|\sum P\|_1} \times \log \frac{P^c}{\|\sum P\|_1} \right) + \delta \quad (5)$$

其中,  $C$  是数据集的类别数量,  $\delta$  是防止损失函数为负值的正则项,为了鼓励类间特征的稀疏性,我们使用 L1 归一化来去除不相关或者稀疏的特征,从而强调每个类特征中最具有区分的特征.

### 2.4 半监督学习

我们在半监督学习中使用伪标签策略对噪声标签所带来的错误监督信号进行重新校准,并且实现在数据中找到正确标注的样本.通过关注预测结果的一致性,半监督学习减少了噪声标签的影响,因为模型对被输入的微小变化具有鲁棒性.通过设置置信度阈值,半

监督学习可以过滤掉低置信度的预测,从而减少噪声的传播.仅使用高置信度伪标签进行进一步训练,这有助于减轻噪声标签的影响.为了实现该目的,我们基于初始分类器提供的置信度得分对数据标签分类为干净数据集和噪声数据集:

$$R_c = \{x_i | p_i \cdot y_i \geq \sigma\} \quad (6)$$

$$R_n = \{x_i | p_i \cdot y_i < \sigma\} \quad (7)$$

其中,  $y_i$  是  $y_i$  的原始标签,  $\sigma$  是一个置信度分数阈值用于筛选出干净数据集  $R_c$  和噪声数据集  $R_n$ .

在得到了噪声数据集后,我们对噪声数据集中的标签进行重新标注,通过选择分类器得到的分类置信度  $p$  中预测概率最高的类别作为伪标签,起到重新校准监督信号的作用:

$$\hat{y}_i = \{\max(p_i) | x_i \in R_n\} \quad (8)$$

通过基于当前模型的预测将伪标签分配给有噪声标签,我们有效地扩展了干净标签的数据集.并提供了具有精确监督标签的额外训练样本.使用半监督学习的噪声稳健分类目标函数来稳定收敛并实现训练样本的更好表示,其定义为:

$$L_{gce} = \sum_{x_i \in R_c} (1 - (p_i \cdot y_i)^\mu) / \mu + \sum_{x_i \in R_n} (1 - (p_i \cdot \hat{y}_i)^\mu) / \mu \quad (9)$$

其中,  $\mu$  是一个超参数用于对损失进行归一化处理.

综上所述,将对半学习和半监督学习两个方法结合在一起,可以同时学习到更加判别性的特征和获得更加准确的监督信号,从而取得更好的性能表现.最终框架的损失函数定义如下:

$$L = \omega_1 (L_{icl} + L_{ccl}) + \omega_2 L_{gce} \quad (10)$$

其中,超参数  $\omega_1$  和  $\omega_2$  是平衡因子,用于调整两个损失在训练过程中的比重.

### 3 实验结果和分析

#### 3.1 数据集和实验设置

为了验证评估框架的性能,我们在 CIFAR-10 和 CIFAR-100 两个基准数据集上进行了图像分类任务,并且设置了不同的噪声率来验证模型在不同噪声率破坏下的性能表现.

CIFAR-10 数据集是 Tiny Images 数据集的一个子集,由 60000 张  $32 \times 32$  彩色图像组成.这些图像被标记为 10 个相互排斥的类别:飞机、汽车、鸟、猫、鹿、

狗、青蛙、马、船和卡车.每个类有 6000 个图像,每个类有 5000 个训练图像和 1000 个测试图像. CIFAR-100 数据集则包含了 100 个相互排斥的类,每个图像都带有一个精细标签,每个类包含 500 个训练图像和 100 个测试图像.遵循之前论文中使用的噪声模拟标准,噪声设置用具有预定义的百分比概率对真实标签进行随机替换为噪声标签,我们分别在噪声率 20%、50% 和 80% 下进行了实验.

#### 3.2 实验参数与评价指标

在我们的实验中,我们利用 PreAct ResNet-18<sup>[28]</sup> 作为我们模型的主干架构.训练过程包括 550 个周期,其中包括 150 个周期的热身阶段.使用随机梯度下降训练模型,动量为 0.9,权重衰减为  $10^{-4}$ ,批量为 256.为了优化学习过程,我们采用余弦退火策略调整学习速率.初始学习率设置为 0.02,并根据余弦退火逐渐降低.动量更新的超参数  $m$  设置为 0.99.相似度匹配阈值  $\gamma$  设置为 0.5.置信度分数阈值  $\sigma$  设置为 0.5.将超参数  $\mu$  设置为 0.8.损失函数的权值  $\omega_1$  和  $\omega_2$  分别设为 0.8 和 0.2.

在本文中,我们采用准确率 (accuracy,  $Acc$ ) 来评估针对噪声标签分类问题的方法.对于本文涉及的多分类问题,我们使用以下 4 个指标来定义分类结果:  $TP$  (true positive): 实际属于该类别且被正确分类为该类别的实例数量.  $TN$  (true negative): 实际不属于该类别且被正确识别为非该类别的实例数量.  $FP$  (false positive): 实际不属于该类别但被错误分类为该类别的实例数量.  $FN$  (false negative): 实际属于该类别但被错误分类为其他类别的实例数量.基于这些指标,准确率的计算方法如下所示:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

#### 3.3 基线方法

为了验证我们框架方法的优越性,将本文方法和其他现有噪声标签分类问题方法分别在 CIFAR-10 和 CIFAR-100 上进行性能分析.

Mixup<sup>[29]</sup>: 论文提出了一个简单的数据处理方法,是第 1 篇使用 Mixup 想法的文章.

GCE<sup>[9]</sup>: 论文提出了一组理论基础的噪声鲁棒损失函数,可以看作是 MAE 和 CCE 的推广.所提出的损失函数可以很容易地应用于任何现有的深度神经网络结构和算法.

P-correction<sup>[30]</sup>: 模型利用反向传播来概率地更新

和纠正图像标签,而不是更新网络参数.并且不需要辅助的干净数据集或噪声的先验信息.

M-correction<sup>[31]</sup>:提出了一个  $\beta$  混合来估计这个概率,并通过依赖网络预测(所谓的自举损失)来纠正损失.还进一步调整了混合增强,以进一步推动我们的方法.

ELR<sup>[32]</sup>:方法利用半监督学习技术根据模型输出产生目标概率,并设计了一个正则化项,将模型引导到这些目标,隐式地防止错误标签的记忆.

MOIT<sup>[26]</sup>:进一步提出了一种新的标签噪声检测方法,通过对比学习获得的鲁棒特征表示来估计与原始标签不一致的每样本软标签,从而准确地识别噪声样本.这种检测允许将有噪声的样本作为未标记的样本,并以半监督的方式训练分类器,以防止噪声记忆并改善表征学习.

CTRR<sup>[33]</sup>:提出了一种新的对比正则化函数,用于防止标签噪声主导表征学习的过程.通过对正则化函数诱导的表征进行理论研究,我们发现学习到的表征保留了与真实标签相关的信息,并丢弃了与错误标签相关的信息.

Sel-CL<sup>[25]</sup>:核心思想是从嘈杂的对偶中选择自信对偶,使用自信对偶来学习鲁棒的隐含表示.需要注意的是,对于表示学习来说,直接识别自信对偶是比较困难的.

### 3.4 实验结果

其他现有方法的实验结果均来自原论文的实验结果,结果如表1所示.从实验结果中,我们可以观察到:1)我们提出的方法在大多数实验设置中始终优于基线方法.具体来说,与目前表现最好的方法相比,本文方法可以观察到分类准确率的显著提高,在 CIFAR-10 上平均提高 1.9%,在 CIFAR-100 上平均提高 3.0%.这一改进表明了本文方法在处理标签噪声和提高分类任务的整体性能方面的优越性和鲁棒性.2)需要注意的是,处理高水平的标签噪声是一项特别具有挑战性的任务,因为错误标签的存在会严重破坏分类模型的性能.然而,我们的方法证明了它能够在这些具有挑战性的场景中有效地实现实质性的性能提升.特别是当噪声水平为 80% 时,本文方法在 CIFAR-10 上的分类准确率提高了 4.6%,在 CIFAR-100 上的分类准确率提高了 6.3%.

总的来说,与目前现有的方法相比,在不同实验设

置下的性能改进可以作为我们方法有效性和优越性的有力证据.

表1 实验结果 (%)

Methods	CIFAR-10				CIFAR-100			
	20%	50%	80%	Mean	20%	50%	80%	Mean
CE	82.7	57.9	26.1	55.6	61.8	37.3	8.8	35.9
Mixup <sup>[29]</sup>	92.3	77.6	46.7	72.2	66.0	46.6	17.6	43.4
GCE <sup>[9]</sup>	90.0	89.3	73.9	84.4	68.1	53.3	22.1	47.8
P-correction <sup>[30]</sup>	92.0	88.7	76.5	85.7	68.1	56.4	20.7	48.4
M-correction <sup>[31]</sup>	93.8	91.9	86.6	90.7	73.4	65.4	47.6	62.1
ELR <sup>[32]</sup>	93.8	92.6	88.0	91.4	74.5	70.2	45.2	63.3
MOIT <sup>[26]</sup>	94.1	91.8	81.1	89.0	75.9	70.6	47.6	64.7
CTRR <sup>[33]</sup>	93.9	93.1	90.3	92.4	73.8	72.2	43.7	63.2
Sel-CL <sup>[25]</sup>	95.5	93.9	89.2	92.8	76.5	72.4	59.6	69.5
Ours	95.7	94.8	93.8	94.7	77.5	74.3	65.9	72.5

### 3.5 消融实验

在消融研究中,我们的目标是通过系统地分析改进模型配置的性能来分析我们提出的方法的性能.具体来说,我们将完整模型的结果与通过删除特定组件或修改模型体系结构的某些方面获得的结果进行比较.

比较结果见表2.我们的比较结果表明,去除我们的框架中任何一个模块都会显著降低模型的性能.这一发现强调了模块在增强模型处理标签噪声和提高分类精度方面的关键作用.当图像增强模块 Mixup 被去除时,在 CIFAR-100 上平均降低了 3.4%,这就说明了图像增强能够通过输入图像进行模糊,从而增强模型学习特征的鲁棒性.当对比学习模块被去除时,模型对标签噪声的鲁棒性降低,并且难以有效地学习判别表示.这一分析重申了结合对比学习的必要性,以增强模型学习鲁棒性和判别性表征的能力,以进行噪声标签校正.当半监督学习模块被去除时,可以看到效果是降低最严重的,特别是在 CIFAR-100 数据集上 80% 噪声率的情况下,效果降低了 7.6%.上述观察结果强调了去除成分在减轻标签噪声的负面影响方面的重要性,并且它的缺失阻碍了模型有效处理噪声标签的能力.总的来说,这些消融研究为每个组件的单独贡献提供了有价值的见解,并强调了它们在方法中集成的重要性,最终提高了处理标签噪声挑战的性能.

表2 消融实验结果 (%)

Methods	CIFAR-10				CIFAR-100			
	20%	50%	80%	Mean	20%	50%	80%	Mean
w/o Mixup	94.8	93.1	91.3	93.1	73.5	72.2	61.7	69.1
w/o CL	93.1	91.5	89.2	91.2	72.6	69.5	57.5	66.5
w/o SSL	93.7	90.7	89.5	91.3	72.3	68.4	54.1	64.9
Ours	95.7	94.8	93.8	94.7	77.5	74.3	65.9	72.5

## 4 结论与展望

我们提出了一个新的对比学习框架,该框架有效地结合了半监督学习和多维度对比学习方法,用于在困难的噪声标签环境下学习特征。为了处理噪声标签和噪声对,我们提出了两种选择策略,包括伪标签提升和置信度对选择。这些策略有效地重新校准监督信号,并过滤错误的正样本。在基准数据集上的大量实验验证了我们的方法优于基线。此外我们的方法还存在很多需要改进的地方,接下来我们将会继续对框架进行改进,包括尝试不同的对比学习框架,设计新的半监督学习方法和设计更加鲁棒的损失函数,并且在现实数据集上进行实验,从而增强框架的可靠性和性能表现。

### 参考文献

- 1 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 770–778.
- 2 Huang G, Liu Z, Van Der Maaten L, *et al.* Densely connected convolutional networks. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 4700–4708.
- 3 Li YC, Yang JC, Song YL, *et al.* Learning from noisy labels with distillation. Proceedings of the 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017. 1910–1918.
- 4 Yan JX, Luo L, Deng C, *et al.* Adaptive hierarchical similarity metric learning with noisy labels. IEEE Transactions on Image Processing, 2023, 32: 1245–1256. [doi: [10.1109/TIP.2023.3242148](https://doi.org/10.1109/TIP.2023.3242148)]
- 5 Xia XB, Liu TL, Han B, *et al.* Robust early-learning: Hindering the memorization of noisy labels. Proceedings of the 9th International Conference on Learning Representations. OpenReview.net, 2021.
- 6 Yao JC, Wang JJ, Tsang IW, *et al.* Deep learning from noisy image labels with quality embedding. IEEE Transactions on Image Processing, 2019, 28(4): 1909–1922. [doi: [10.1109/TIP.2018.2877939](https://doi.org/10.1109/TIP.2018.2877939)]
- 7 Lee S, Lee H, Yoon S. Adversarial vertex Mixup: Toward better adversarially robust generalization. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 272–281.
- 8 Feng L, Shu SL, Lin ZY, *et al.* Can cross entropy loss be robust to label noise? Proceedings of the 29th International Conference on International Joint Conferences on Artificial Intelligence. Yokohama: ijcai.org, 2021. 305.
- 9 Zhang ZL, Sabuncu MR. Generalized cross entropy loss for training deep neural networks with noisy labels. Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal: Curran Associates Inc., 2018. 8792–8802.
- 10 Algan G, Ulusoy I. MetalabelNet: Learning to generate soft-labels from noisy-labels. IEEE Transactions on Image Processing, 2022, 31: 4352–4362. [doi: [10.1109/TIP.2022.3183841](https://doi.org/10.1109/TIP.2022.3183841)]
- 11 Amid E, Warmuth MK, Srinivasan S. Two-temperature logistic regression based on the tsallis divergence. Proceedings of the 22nd International Conference on Artificial Intelligence and Statistics. Naha: PMLR, 2019. 2388–2396.
- 12 Wang YS, Ma XJ, Chen ZY, *et al.* Symmetric cross entropy for robust learning with noisy labels. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 322–330.
- 13 Hendrycks D, Mazeika M, Wilson D, *et al.* Using trusted data to train deep networks on labels corrupted by severe noise. Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal: Curran Associates Inc., 2018. 10477–10486.
- 14 Cheng D, Liu TL, Ning YX, *et al.* Instance-dependent label-noise learning with manifold-regularized transition matrix estimation. Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022. 16630–16639.
- 15 Yang S, Yang EK, Han B, *et al.* Estimating instance-dependent Bayes-label transition matrix using a deep neural network. Proceedings of the 39th International Conference on Machine Learning. Baltimore: PMLR, 2022. 25302–25312.
- 16 Song H, Kim M, Park D, *et al.* Learning from noisy labels with deep neural networks: A survey. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(11): 8135–8153. [doi: [10.1109/TNNLS.2022.3152527](https://doi.org/10.1109/TNNLS.2022.3152527)]
- 17 Tran M, Wagner SJ, Boxberg M, *et al.* S5CL: Unifying fully-supervised, self-supervised, and semi-supervised learning through hierarchical contrastive learning. Proceedings of the 25th International Conference on Medical Image Computing and Computer Assisted Intervention. Singapore: Springer, 2022. 99–108.
- 18 Baram S, Nguyen CM, Kassim A, *et al.* Consistency-based

- semi-supervised evidential active learning for diagnostic radiograph classification. Proceedings of the 25th International Conference on Medical Image Computing and Computer Assisted Intervention. Singapore: Springer, 2022. 675–685.
- 19 Jiang MR, Yang HZ, Li XX, *et al.* Dynamic bank learning for semi-supervised federated image diagnosis with class imbalance. Proceedings of the 25th International Conference on Medical Image Computing and Computer Assisted Intervention. Singapore: Springer, 2022. 196–206.
- 20 Nguyen DT, Mummadi CK, Ngo TPN, *et al.* SELF: Learning to filter noisy labels with self-ensembling. Proceedings of the 8th International Conference on Learning Representations. Addis Ababa: OpenReview.net, 2020.
- 21 Li JN, Socher R, Hoi SCH. DivideMix: Learning with noisy labels as semi-supervised learning. Proceedings of the 8th International Conference on Learning Representations. Addis Ababa: OpenReview.net, 2020.
- 22 Zhou TY, Wang SJ, Bilmes JA. Robust curriculum learning: From clean label detection to noisy label self-correction. Proceedings of the 9th International Conference on Learning Representations. OpenReview.net, 2021.
- 23 Chen T, Kornblith S, Norouzi M, *et al.* A simple framework for contrastive learning of visual representations. Proceedings of the 37th International Conference on Machine Learning. PMLR, 2020. 149.
- 24 Khosla P, Teterwak P, Wang C, *et al.* Supervised contrastive learning. Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2020. 1567.
- 25 Li SK, Xia XB, Ge SM, *et al.* Selective-supervised contrastive learning with noisy labels. Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022. 316–325.
- 26 Ortego D, Arazo E, Albert P, *et al.* Multi-objective interpolation training for robustness to label noise. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 6606–6615.
- 27 Huang JB, Gong SG, Zhu XT. Deep semantic clustering by partition confidence maximisation. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 8849–8858.
- 28 He KM, Zhang XY, Ren SQ, *et al.* Identity mappings in deep residual networks. Proceedings of the 14th European Conference on Computer Vision. Amsterdam: Springer, 2016. 630–645.
- 29 Zhang HY, Cissé M, Dauphin YN, *et al.* Mixup: Beyond empirical risk minimization. Proceedings of the 6th International Conference on Learning Representations. Vancouver: OpenReview.net, 2018.
- 30 Yi K, Wu JX. Probabilistic end-to-end noise correction for learning with noisy labels. Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 7017–7025.
- 31 Arazo E, Ortego D, Albert P, *et al.* Unsupervised label noise modeling and loss correction. Proceedings of the 36th International Conference on Machine Learning. Long Beach: PMLR, 2019. 312–321.
- 32 Liu S, Niles-Weed J, Razavian N, *et al.* Early-learning regularization prevents memorization of noisy labels. Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2020. 1707.
- 33 Yi L, Liu S, She Q, *et al.* On learning contrastive representations for learning with noisy labels. Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022. 16682–16691.

(校对责编: 张重毅)