

基于混合采样策略与 Fixmatch 的图像分类方法

白罡旭¹, 杨海峰¹, 蔡江辉^{1,2}, 王玉鹏¹

(1. 太原科技大学 计算机科学与技术学院, 山西 太原 030024;

2. 中北大学, 山西 太原 030051)

摘要: RUC (Unsupervised Image Clustering with Robust Learning) 是一种为改善聚类性能而提出的图像分类方法, 但是由于它的协同训练仅适用于双视图数据集, 并且没有考虑到数据之间相似性对其伪标签采样策略的影响, 此外其使用的 Mixmatch 只是单纯地进行 k 次随机增强求均值却没有考虑到强增强与弱增强的联系。为了解决这些问题, 该文提出了 HFC (classification method based on Hybrid sampling strategy and Fixmatch)。首先, 设计了一种置信度与距离的伪标签采样策略, 联合两种策略以提高筛选到正确标签的概率; 其次, 使用 Tri-training 取代 Co-training, 即通过两个分类器指导第三个分类器进行训练, 使得模型不再受限双视图数据集; 最后, 采用目前较好的 Fixmatch 的数据增强方法取代 RUC 中 Mixmatch 随机增强, 以突出强增强与弱增强的联合作用。HFC 在 CIFAR-10、CIFAR-100 和 STL-10 数据集上进行实验, 取得了较好的结果, 验证了该方法的有效性。

关键词: 半监督学习; 聚类; 采样策略; 图像分类; 数据增强

中图分类号: TP181

文献标识码: A

文章编号: 1673-629X(2023)11-0072-06

doi: 10.3969/j.issn.1673-629X.2023.11.011

An Image Classification Method Based on Hybrid Sampling Strategy and Fixmatch

BAI Gang-xu¹, YANG Hai-feng¹, CAI Jiang-hui^{1,2}, WANG Yu-peng¹

(1. School of Computer Science and Technology, Taiyuan University of Science and Technology,

Taiyuan 030024, China;

2. North University of China, Taiyuan 030051, China)

Abstract: RUC is an image classification method proposed to improve clustering performance, but its cooperative training is only applicable to two-view data sets. Moreover, the influence of the similarity between the data on the pseudo-label sampling strategy was not taken into account. In addition, the Mixmatch used simply carried out k sub-random enhancement to find the mean value without considering the relationship between strong enhancement and weak enhancement. To solve these problems, we propose an HFC (classification method based on Hybrid sampling strategy and Fixmatch). Firstly, a pseudo-label sampling strategy with confidence and distance is designed, and the two strategies are combined to improve the probability of filtering to the correct label. Secondly, the Tri-training is used instead of Co-training, that is, the third classifier is guided by two classifiers for training, so that the model is no longer limited by the two-view dataset. Finally, we replace the random Mixmatch augmentation in RUC with the Fixmatch data augmentation method to highlight the combined effect of strong enhancement and weak enhancement. Experiments with HFC on CIFAR-10, CIFAR-100 and STL-10 datasets have obtained good results, which verify the effectiveness of the proposed method.

Key words: semi-supervised learning; clustering; sampling strategy; image classification; data augmentation

0 引言

聚类是一种单纯地按照相似性规则^[1]自然划分的无监督分析方法。传统的聚类分析方法无法有效利用正确标签中的有效信息^[2], 而且存在对预测结果过

度自信的问题。

针对这些问题, 提出了很多改进方法, 较为经典的是基于深度学习的算法, 它们首先用深层神经网络结构对原始数据进行特征学习^[3], 然后对学习到的特征

收稿日期: 2022-12-29

修回日期: 2023-05-05

基金项目: 国家自然科学基金项目 (U1931209)

作者简介: 白罡旭 (1997-), 男, 硕士研究生, 研究方向为数据挖掘与图像处理; 通讯作者: 杨海峰 (1980-), 男, 博士, 教授, 博导, 研究方向为人工智能、数据挖掘。

表示进行聚类,深层神经网络学习高级表示的能力^[4]使其成为无监督学习的良好选择。然而该方法也有一定的缺陷:训练早期容易将不确定的样本分入错误的类中,从而造成噪声累积降低性能。还有学者提出使用半监督模型来帮助聚类实现更好的性能,即使用聚类得出的预测结果作为伪标签,输入到半监督模型中进行再训练,达到矫正聚类预测错误的目的。该方法可以使用采样策略进一步提升筛选到正确标签的概率,尽可能避免噪声累积。然而这便引出了新的问题:如何为半监督模型提取到相对正确的标签和如何提升后续半监督模型的性能。添加半监督模型改进聚类有很多方法,其中比较好的是 RUC (Unsupervised Image Clustering with Robust Learning)^[5],它使用 Mixmatch^[6]半监督模型来改进聚类结果,并使用协同训练 Co-training^[7]来更好地训练模型。但是 RUC 也存在一些缺陷,例如:RUC 的采样策略没有考虑到数据之间相似性对其伪标签采样策略的影响;Co-training 是一类基于“分歧”的半监督学习方法,它必须使用冗余且独立双视图数据集^[8]。然而,在真实问题中充分使用冗余视图。这一要求往往很难得到满足,这使得模型适用范围受限。RUC 中的 Mixmatch 半监督模型只是单纯地进行 k 次随机增强求均值,却没有考虑到强增强与弱增强的联系,使得结果受平均值影响。

为了筛选到相对正确的标签,改进上述采样策略的问题,采用了基于置信度结合基于距离的方法,当符合两种策略时,才加入到伪标签中,大大降低了伪标签出错对后续训练的影响。针对 RUC 中 Co-training 适用范围受限的问题,该文采用 Tri-training^[9]的方法来解决。它使用两个分类器来指导第三个分类器进行训练,使得模型不再受限于 Co-training 的双视图数据集。相比于 RUC 中 Mixmatch 中随机增强混合求平均的方法,Fixmatch^[10]突出了强增强与弱增强的联合作用,即弱增强的预测值达到一定分数才能加入到伪标签中。

该文介绍了一种新的基于聚类结合半监督模型的方法 (HFC),该模型利用并处理现有聚类模型的结果,将其作为可能包含错误标签的噪声数据集,输入到半监督模型来更正聚类结果中的错误信息。模型包括:将聚类算法得出的伪标签集合通过基于置信度结合基于距离的采样方法分为两个不相交的有标签和无标签集合,输入到半监督模型中进行训练。HFC 模型以 Tri-training 为框架,Fixmatch 模型为基分类器。

1 相关工作

1.1 无监督聚类方法

无监督聚类是计算机视觉中的一项核心任务,目

的是在不使用任何标签的情况下识别每幅图像的类成员。

人们提出了各种无监督聚类方法。最初的方法使用主成分分析等方法提取特征,然后依次应用传统的基于距离或密度的聚类算法进行分类。例如,Jolliffe 等人^[11]使用主成分分析来提取低维特征,然后应用聚类来分配类别,并且描述了主成分分析的变体。DBscan^[12]是一种基于密度的算法。它能在噪声数据中发现任意形状和大小的簇。江等人^[13]使用稀疏子空间方法进行无监督学习。然而,由于缺乏对后续分配过程的了解,这些模型倾向于产生类间几乎没有分离的特征。

最近,人们提出了基于深度学习的算法。首先用深层神经网络结构对原始数据进行特征学习,然后对学习到的特征表示进行聚类,深层神经网络学习高级表示的能力使其成为无监督学习的良好选择。Hsu Chih-Chung 等人^[14]对从 CNN 网络中获得的特征进行聚类,并使用这些聚类结果作为伪标签来训练分类器。Bo Yang 等人^[15]使用深度神经网络同时学习特征表示和聚类分配,来处理图像和文本数据集。

近期出现了将再培训过程充当前续添加模块,以改进现有的聚类方法,它们使用改进的标签进行后续模块的再培训。Gupta 等人^[16]表明,半监督再培训可以改善无监督聚类。他们创造了一种新的图聚类方法,其中数据样本是节点,并从集合模型中获取置信度。Sungkyu Park 等人^[5]采用 Mixmatch 与 Co-training 结合的方法,提升了聚类性能。相比之下,该文采用的 Fixmatch 结合 Tri-training 方法不受数据集双视角的限制,进一步提升了聚类性能。Tri-training 使用两个分类器来指导第三个分类器进行训练,使得模型不再受限于 Co-training 的双视图数据集。Fixmatch 则突出了强增强与弱增强的作用,比 Mixmatch 中随机增强混合求平均的方法有更好的性能。

1.2 半监督学习算法

半监督学习是由自学习发展而来的,在之后的发展中逐渐出现了自学习^[17]、直推学习^[18]、生成式模型等学习方法。按照学习场景的不同,半监督学习划分为 4 类:半监督降维^[19]、半监督回归^[20]、半监督聚类^[21]、半监督分类^[22]。半监督分类可以分为:基于生成式的半监督学习、基于支持向量机的半监督学习、基于图的半监督学习和协同训练。

“Semi-supervised”由 Merz 等首次提出,揭开了半监督发展的序幕。Klein 等人^[23]首次提出了用于聚类的半监督距离度量学习方法。刘建伟等人^[24]对半监督分类和聚类等方法做了系统性总结。Wu Hao 等人

使用伪标签^[25]训练,使得无标注数据样本的熵变得更小,分类泛化性能更好。Harri Valpola 使用 student 模型^[26]的指数平均权重来更新 teacher 模型。该方法有两方面的优势:第一,在 student 和 teacher 模型之间的反馈过程会收敛的更快,准确率更高;第二,在大型数据集上扩展应用较好。Wang 等人^[27]采用了数据增强策略来实现邻域风险最小化,利用训练数据集的扰动来增强学习机的表现能力。但是一般的数据增强仅仅在同类间对数据进行处理,没有进行类间数据的融合操作。David Berthelot 等人提出的 Remixmatch^[28]替换了 Mixmatch 中的一致性正则化。对于给定的无标注样本,首先产生一个弱增强的数据,然后产生多个强增强的数据。弱增强产生的预测作为所有强增强数据的猜测标签。Kihyuk Sohn 等人提出的 Fixmatch 实际上是伪标签和一致性正则化的综合体。Fixmatch 利用弱数据增强图像生成伪标签,保留预测置信度更高的伪标签。然后,将经过强数据增强的图像传到模型中得到预测值,使用交叉熵损失,将预测值和伪标签进行比较。该算法集合了 Mixmatch 和 Remixmatch 等算法的优点并进一步简化,是目前较为优秀的半监督分类算法。

2 HFC 方法

HFC 模型的关键思想是使用基于置信度和基于距离的方法提取出模型认为正确的伪标签,并将其作为后续半监督模块的输入部分。如图 1 所示,该文首先使用聚类方法处理数据,使用基于置信度结合基于距离的采样策略将其分成两个不相交的集合:干净集

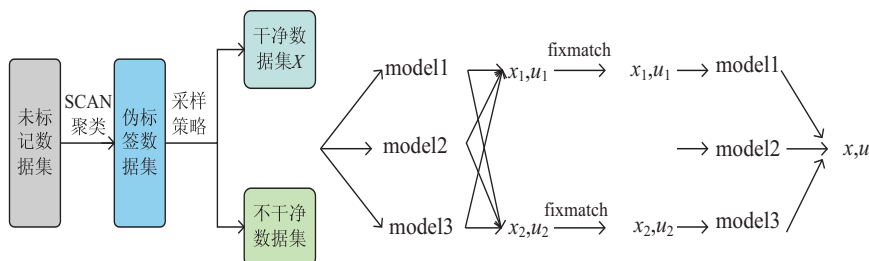


图 1 HFC 模型

2.2 基于置信度和距离的采样方法

置信度方法按照伪标签数据的置信度得分选择干净样本。给定一个训练样本 $(x, y \in D)$, $\max(y)$ 是其置信度,如果 $\max(y) > \tau_1$,认为伪标签 y 是可信的,并将其添加到干净集 X 中。否则,它被分配给 U 。阈值 τ_1 设置得非常高,以尽可能多地消除不确定样本。

聚类结果中离簇中心最近的点可信度较高,其伪标签是可信的。第一步找到簇心,标记为 K 。第二步设簇中任意一点到簇心 K 的距离为 d ,将所有 d 进行排序。第三步按照一定比例 p 将每个簇中 d 最小的数据加入到干净集 X 中,其余分到不干净集合 U 中(该

X 和不干净集 U 。然后,以 Fixmatch 半监督的方法训练分类器,处理有标签数据和无标签数据。同时使用 Tri-training 指导半监督,以更好地提升准确率,扩大模型适用范围。下面将详细描述该模型,算法 1 为 HFC 的算法框架。

算法 1: HFC 算法框架

输入: 伪标签为 D 的训练集, 三个网络 $f_{\theta}(1), f_{\theta}(2), f_{\theta}(3)$, 阈值 τ_1 , 阈值 τ_2 , $X \cup U = D$

```

for  $k \in \{1, 2, 3\}$  do           // 训练三个网络
 $ls = \frac{1}{B} \sum_{b=1}^B H(pb, (xb))$ 
for  $b \in \{1, 2, \dots, B\}$  do
 $\mu b = A(\mu b)$                 // 强增强操作
 $qb = pm(y | \alpha(\varphi b); \theta)$  // 弱增强操作
end
 $\tilde{x}^{(k)} = \{(xb, Pb); b \in \{1, 2, \dots, B\}\}$ 
 $\tilde{u}^{(k)} = \{(\mu b, qb); b \in \{1, 2, \dots, B\}\}$ 
 $(\tilde{x}_1^{(k)}, \tilde{u}_1^{(k)}) = \text{Fixmatch}(\tilde{x}^{(k)}, \tilde{u}^{(k)})$ 
 $lu = \frac{1}{\mu_B} \sum_{b=1}^{\mu_B} \{\max(qb) > \tau\} H(\arg\max(qb), \mu b)$ 
 $L = ls + \lambda u * lu$            // 计算总体损失函数
end

```

2.1 干净数据集的收集方法

如图 1, HFC 首先使用聚类方法对初始数据进行聚类,得到伪标签数据集。然后使用基于置信度结合基于距离的采样策略将伪标签数据集划分为两个不相交的有标签和无标签集合,即 $D = X \cup U$ 。认为 X 是干净的,其伪标签是适度可信的。 U 是不干净集合,因其为标签不可信,所以将其去除。

比例 p 取决于所需有标签数据的数量占总样本数量的比例和所在簇占总样本数量的比例)。

将两种方法的干净集取交集,即当样本同时满足基于置信度和基于最近邻的方法时,才将样本加入到最终的干净样本中,剩余的去除伪标签后加到不干净集合中。

2.3 Fixmatch 半监督模块

Fixmatch 是谷歌提出的半监督模型,其核心思想是将输入数据集进行强增强和弱增强,利用它们各自的优点来迭代模型。该文使用 Fixmatch 为主要半监督模型来更正聚类结果中的错误标记。弱增强包括翻

转、对称,强增强包括裁剪等。首先是有标签的监督训练,使用有标签的图片训练初始模型。然后把没有标签的图片进行弱增强,使用模型给出预测。对于每张没有标签的图片,当模型的预测结果得分高于一定的阈值 τ_2 (τ_2 尽可能大来过滤掉不好的结果,避免对后续训练产生影响)时,将预测结果作为伪标签。接下来,将经过强增强的图像传到模型中,得到种类的预测值,并将其输出与伪标签进行比较以计算交叉熵损失。最后,将两种损失组合起来进行模型的更新。

Fixmatch 的损失函数由两部分组成:有标签的图片用有监督的损失 l_s ,没有标签的图片用无监督的损失 l_u ,两个损失都是标准的交叉熵损失。有监督的损失函数如公式(1)所示。

$$l_s = \frac{1}{\mu_b} \sum_{b=1}^B H(pb, pm(y | \alpha(xb))) \quad (1)$$

对于无标签图片的处理:首先得到伪标签,如果伪标签的得分大于一定的阈值 (τ_2 , 文中的阈值取 0.95),那么,就用该伪标签和强烈数据增强获得的特征计算交叉熵损失,如公式(2)所示。

$$l_u = \frac{1}{\mu_b} (\max(qb) \geq \tau_2) H(qb, pm(y | A(\mu b))) \quad (2)$$

最后,Fixmatch 的损失函数为: $l_s + l_u$ 。

2.4 Tri-training

Tri-training 是对 Co-training(协同训练)的一种改进,它也是一种基于分歧的方法。Tri-training 首先对有标签数据集进行可重复取样(bootstrap sampling)以获得 3 个有标签训练集,然后从每个训练集产生 1 个分类器。给定 3 个分类器进行训练,如果 2 个分类器对同一个无标签数据的预测相同,则该数据就被认为具有较高的置信度,因此对其标记后将其加入第 3 个分类器的有标签训练集。在对未知数据进行预测时,Tri-training 算法不再像以往算法那样挑选 1 个分类器来使用,而是使用集成学习中经常用到的投票法来将 3 个分类器组成一个集合来实现对未知数据的预测。

3 实验结果与分析

为了评估模型的性能,在 4 个中小型数据集上(其中 CIFAR-10、CIFAR-100 来源于 the 80 million tiny images 数据集,STL-10 来源于 ImageNet)测试了其性能,并与其他方法进行了对比。在后续的消融实验中,分别去除了 3 个模块,来证明各个模块的作用。

3.1 实验环境

Intel(R) Xeon(R) W-10855M CPU @ 2.80 GHz 工作站。40 * Intel(R) Xeon(R) Gold 5218R CPU @

2.10 GHz 服务器。

置信度策略中 τ_1 为 0.99,Fixmatch 中 τ_2 为 0.95,前置的聚类模型为 SCAN^[29],是现有聚类中准确率较高的一种。

3.2 数据集选择及预处理

为了验证该模型在小型和大型数据集上的性能,使用了 CIFAR-10、CIFAR-100、STL-10 和 ImageNet 数据集。详细介绍如表 1 所示。CIFAR-10 是一个用于识别普适物体的小型数据集。它包含 60 000 幅 32×32 像素的图像,分为 10 个类,每个类有 6 000 个图像。CIFAR-100 数据集和 CIFAR-10 类似,分为 100 个类,每个类包含 600 个图像(为了与 RUC 对比,选择其中 20 个类)。STL-10 分为 10 类,包含 100 000 个未标记图像和 13 000 个 96×96 像素的标记图像。ImageNet 是一个计算机视觉数据集,该文使用它的子集 ILSVRC2012,该数据集拥有 1 000 个分类,每个分类约有 1 000 张图片。实验进行了 200 个 epoch 的训练。

为了使 HFC 模型可以更好地对抗噪声,更具鲁棒性,该文采用标签平滑的方法。标签平滑通过添加均匀噪声来规定标签,从而改进预测中的校准。给定带标签的样品及其相应标签 ($x, y \in X$),将均匀噪声注入所有类中。

表 1 数据集介绍

数据集	训练集/张	测试集/张
CIFAR-10	50 000	10 000
CIFAR-100	10 000	2 000
STL-10	100 000	13 000
ImageNet-50	62 500	2 500

3.3 评价指标

3.3.1 鲁棒性

如图 2 所示,使用 BIM 对抗攻击方法在 STL-10 上进行了实验,实验结果表明 HFC 的提升更进一步。RUC 通过 Mixmatch 结合 Co-training 和标签平滑操作来提高鲁棒性。与之相比,HFC 模型中 Fixmatch 在训练之初,就选择了高置信度样本作为伪标签数据,并且




图 2 BIM 攻击下准确率随扰动系数 ϵ 的变化

通过 Tri-training 分别训练,互相指导,进一步降低了噪声影响。

3.3.2 迭代速度

如图 3 所示,文中模型在 STL-10 上经历 40 次迭代时准确率已经快速上升,证明模型在中小数据集上迭代较少次数也有较高性能,且很快就趋于收敛。在较大数据集上模型受聚类输出的错误数据影响很小,能很快根据后续训练进行自我矫正,达到收敛。




图 3 各模型在 STL-10 上的迭代次数与准确率

3.4 结果分析

3.4.1 SCAN 与 HFC 结果

表 2 显示了文中模型与初始聚类算法 SCAN 在四个数据集上的结果。通过比较,文中模型在 CIFAR-10 数据集实验中比 SCAN 提升了 2 个百分点,正确率从 88.3% 提升到 90.3%。在 CIFAR-100 中比 SCAN 高出了 8 个百分点。在 STL-10 和 ImageNet 上分别提升了 5.9 个百分点和 1.5 个百分点。相比于 SCAN,HFC 过滤出不干净的样本,同时通过标签平滑和协同训练来辅助,以减少不干净标签中的错误信息产生的累积效应。结果证明了文中模型对现有聚类方法 SCAN 具有改进效果。

表 2 模型在各数据集上的准确率 %

Dataset/acc	SCAN	SCAN+HFC
ImageNet-50	75.6	77.1
CIFAR-10	88.3	90.3
CIFAR-100	50.6	58.6
STL-10	81.9	87.8

表 3 对比实验及准确率 %

模型	CIFAR-10	CIFAR-100	STL-10
SCAN+gupta	87.3	51.7	84.1
SCAN+dividemix	86.4	50.2	80.2
SCAN+RUC	89.1	57.5	86.3
SCAN+UDA	88.9	53.4	85.4
SCAN+HFC	90.3	58.6	87.8

3.4.2 对比实验

为了进行公平比较,将现有的算法(如 RUC 和 DivideMix)或之前提出的另一个附加模块(如 Gupta)与 SCAN 相结合。如表 3 所示,一些模型在添加后续模块后显示出更差的结果,分析可能的原因是未改善噪声影响。当初始聚类相当准确时,Gupta 带来的改进效果十分有限。相比之下,文中模型结合了标签平滑操作与协同训练,使得最终结果更好,更具鲁棒性。

UDA 的成功,得益于对特定任务使用特定目标的数据增强算法。但是其结果表现一般,可能是受到 SCAN 预测错误数据的影响比较大。相比之下,文中模型则具有较好的稳定性。

RUC 在各方面都做了改进,但是仍受限于 Co-training 限制的双视角数据集,该文采用了 Tri-training 框架避免了此问题,而且采用投票机制使用两个模型训练第三个模型,比 Co-training 双模型的互相训练更具可信度,减少了噪声的影响。通过引入准确率更高的半监督模型 Fixmatch 代替 Mixmatch 来进一步处理聚类得到的结果,可以使分类精确度得到进一步提升。

3.5 消融实验

为了确定各个模块对整体模型的影响,进行了消融实验。首先是采样策略中基于距离方法的消融,接着是 Tri-training 训练的消融,实验结果如表 4 所示。其中缺失了基于距离的采样策略,准确率降低了 0.9 个百分点,这说明只有两种策略一起筛选有标签数据集时,才能降低错误标记对后续训练的影响。缺失 Tri-training,模型的准确率由 90.1% 下降到 87.2%,没有其他 2 个分类器对第 3 个分类器的指导,效果大打折扣。以上结果证明每个部分都不可或缺,它们在一起才能达到较好的效果。

表 4 模型在 CIFAR-10 上的消融实验 %

Setup	Last Acc	Best Acc
HFC	90.1	90.5
w/o 基于距离	89.2	89.5
w/o Tri-training	87.2	87.4

4 结束语

为了解决无监督聚类方法出现预测错误和过度自信的问题,提出了一种新的基于置信度和基于距离的采样策略和 Tri-training 结合 Fixmatch 的模型。加入该模型可以矫正聚类的某些错误分类,从而产生更精确的聚类结果。但是模型也有自身局限性:时间复杂度不尽如人意、精确度也有待提升。未来打算将模型进行轻量化,并且进一步改善采样策略和提升半监督模型性能。

参考文献:

- [1] AL-JABER K, OBAFEMI-AJAYI T, OLBRICHT G, et al. Computational learning approaches to data analytics in bio-medical applications[M]. New York: Academic Press, 2019: 1-291.
- [2] 伍育红. 聚类算法综述[J]. 计算机科学, 2015, 42(6A): 491-499.
- [3] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. Neural Networks, 2015, 61: 85-117.
- [4] ALMABDY S, ELREFAEI L. Deep convolutional neural network-based approaches for face recognition[J]. Applied Sciences, 2019, 9(20): 43-97.
- [5] PARK S, HAN S, KIM S, et al. Improving unsupervised image clustering with robust learning[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle: IEEE, 2021: 12278-12287.
- [6] BERTHELOT D, CARLINI N, GOODFELLOW I, et al. Mixmatch: a holistic approach to semi-supervised learning[J]. Advances in Neural Information Processing Systems, 2019, 32: 1905-1935.
- [7] 马 蕾, 汪西莉. 基于支持向量机协同训练的半监督回归[J]. 计算机工程与应用, 2011, 47(3): 177-180.
- [8] DARNSTÄDT M, SIMON H U, SZÖRÉNYI B. Supervised learning and co-training[J]. Theoretical Computer Science, 2014, 519: 68-87.
- [9] ZHOU Z H, LI M. Tri-training: exploiting unlabeled data using three classifiers[J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(11): 1529-1541.
- [10] SOHN K, BERTHELOT D, CARLINI N, et al. Fixmatch: simplifying semi-supervised learning with consistency and confidence[J]. Advances in Neural Information Processing Systems, 2020, 33: 596-608.
- [11] JOLLIFFE I T, CADIMA J. Principal component analysis: a review and recent developments[J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2016, 374(2065): 20150202.
- [12] KHAN K, REHMAN S U, AZIZ K, et al. DBSCAN: past, present and future[C]//The fifth international conference on the applications of digital information and web technologies (ICADIWT 2014). Chennai: IEEE, 2014: 232-238.
- [13] 王卫卫, 李小平, 冯象初, 等. 稀疏子空间聚类综述[J]. 自动化学报, 2015, 41(8): 1373-1384.
- [14] HSU C C, LIN C W. Cnn-based joint clustering and representation learning with feature drift compensation for large-scale image data[J]. IEEE Transactions on Multimedia, 2017, 20(2): 421-429.
- [15] YANG B, FU X, SIDIROPOULOS N D, et al. Towards k-means-friendly spaces: simultaneous deep learning and clustering[C]//International conference on machine learning. New York: PMLR, 2017: 3861-3870.
- [16] GUPTA D, RAMJEE R, KWATRA N, et al. Unsupervised clustering using pseudo-semi-supervised learning[C]//International conference on learning representations. Millennium Hall: Open Review. net, 2020: 121-138.
- [17] 苏 赋, 吕 沁, 罗仁泽. 基于深度学习的图像分类研究综述[J]. 电信科学, 2019, 35(11): 58-74.
- [18] 张 新, 何 苯, 罗铁坚, 等. 基于聚类的直推式学习的性能分析[J]. 软件学报, 2014, 25(12): 27-45.
- [19] 陈诗国, 张道强. 半监督降维方法的实验比较[J]. 软件学报, 2011, 22(1): 28-43.
- [20] REN Y, HU K, DAI X, et al. Semi-supervised deep embedded clustering[J]. Neurocomputing, 2019, 325: 121-130.
- [21] 陆 宇, 赵凌云, 白斌雯, 等. 基于改进的半监督聚类的不平衡分类算法[J]. 计算机应用, 2022, 42(12): 3750-3755.
- [22] 莫建文, 贾 鹏. 基于梯形网络和改进三训练法的半监督分类[J]. 自动化学报, 2022, 48(8): 2088-2096.
- [23] KLEIN D, KAMVAR S D, MANNING C D. From instance-level constraints to space-level constraints: Making the most of prior knowledge in data clustering[C]//Twenty-first international conference on machine learning (ICML). Sydney: COLT and ILP, 2002: 307-314.
- [24] 刘建伟, 刘 媛, 罗雄麟. 半监督学习方法[J]. 计算机学报, 2015, 38(8): 1592-1617.
- [25] WU H, PRASAD S. Semi-supervised deep learning using pseudo labels for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2017, 27(3): 1259-1270.
- [26] TARVAINEN A, VALPOLA H. Mean teachers are better role models: weight-averaged consistency targets improve semi-supervised deep learning results[J]. Advances in Neural Information Processing Systems, 2017, 30: 1195-1204.
- [27] WU D, XIA S T, WANG Y. Adversarial weight perturbation helps robust generalization[J]. Advances in Neural Information Processing Systems, 2020, 33: 2958-2969.
- [28] BERTHELOT D, CARLINI N, CUBUK E D, et al. Re-mixmatch: semi-supervised learning with distribution alignment and augmentation anchoring. [C]//International conference on learning representations. Millennium Hall: Open Review. net, 2020: 221-240.
- [29] VAN GANSBEKE W, VANDENHENDE S, GEORGIOULIS S, et al. Scan: learning to classify images without labels [C]//Computer vision - ECCV 2020: 16th European conference. Glasgow: Springer, 2020: 268-285.