



# 计算机科学

COMPUTER SCIENCE

## 基于最大影响力集合的主动学习方法

李雅和, 谢志鹏

引用本文

李雅和, 谢志鹏. 基于最大影响力集合的主动学习方法[J]. 计算机科学, 2025, 52(1): 289-297.

LI Yahe, XIE Zhipeng. [Active Learning Based on Maximum Influence Set](#)[J]. Computer Science, 2025, 52(1): 289-297.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

**Similar articles recommended (Please use Firefox or IE to view the article)**

### [基于SE注意力多源域对抗网络的射频指纹识别](#)

RF Fingerprint Recognition Based on SE Attention Multi-source Domain Adversarial Network  
计算机科学, 2025, 52(1): 412-419. <https://doi.org/10.11896/jsjcx.231100076>

### [计算机视觉领域对抗样本检测综述](#)

Adversarial Sample Detection in Computer Vision:A Survey  
计算机科学, 2025, 52(1): 345-361. <https://doi.org/10.11896/jsjcx.240300080>

### [视觉富文档理解预训练综述](#)

Review of Pre-training Methods for Visually-rich Document Understanding  
计算机科学, 2025, 52(1): 259-276. <https://doi.org/10.11896/jsjcx.240300028>

### [基于细粒度代码表示和特征融合的即时软件缺陷预测方法](#)

Just-In-Time Software Defect Prediction Approach Based on Fine-grained Code Representation and Feature Fusion  
计算机科学, 2025, 52(1): 242-249. <https://doi.org/10.11896/jsjcx.240200046>

### [视觉Transformer\(ViT\)发展综述](#)

Survey of Vision Transformers(ViT)  
计算机科学, 2025, 52(1): 194-209. <https://doi.org/10.11896/jsjcx.240600135>

# 基于最大影响力集合的主动学习方法

李雅和 谢志鹏

复旦大学计算机科学技术学院 上海 200438

(yaheli21@m.fudan.edu.cn)

**摘要** 随着深度学习技术的不断进步,其已经在许多领域广泛应用。但深度模型的训练需要消耗大量标注数据,时间与资源成本高,如何利用尽可能少的标注数据达到最佳模型效果成为一个重要的研究课题。主动学习的提出正是为了解决这一问题,其旨在选择最有价值的样本进行标注并用于模型训练。传统的主动学习策略通常关注不确定性或多样性,旨在查询最困难或最具代表性的样本。然而,在主动学习问题中,这些方法通常没有考虑标注样本和无标注样本之间的交互作用。另一类主动学习方法则使用辅助网络进行样本选择,但这些方法通常会增加计算复杂度。在上述背景下,提出一种新的主动学习算法,旨在通过考虑不同样本之间的相互作用,综合衡量候选样本对其他样本的影响力与不确定性,来最大限度地提高模型的整体性能增益。所提算法首先根据样本隐含层表征之间的距离估计样本相互之间的影响力,进一步根据候选样本的影响力与无标注样本的不确定性估计该样本能够带来的潜在增益,并迭代地选择全局增益最大的样本进行标注。进一步在一系列不同领域的多种任务上将该方法与其他主动学习策略进行了比较,实验结果表明,该方法在所有任务中的表现均显著优于所有基线方法。进一步的量化分析实验也证明该方法在不确定性和多样性之间取得了良好的权衡,并探究了主动学习不同阶段应该注重的因素。

**关键词:** 主动学习;深度学习;不确定性

**中图分类号** TP391

## Active Learning Based on Maximum Influence Set

LI Yahe and XIE Zhipeng

School of Computer Science, Fudan University, Shanghai 200438, China

**Abstract** With the continuous progress of deep learning, it has been widely applied in numerous fields. However, the training of deep models requires a large amount of labeled data, and the cost of time and resources is high. How to maximize the model performance with the least amount of labeled data has become an important research topic. Active learning aims to address this issue by selecting the most valuable samples for annotation and utilizing them for model training. Traditional active learning approaches usually concentrate on uncertainty or diversity, aiming to query the most difficult or representative samples. Nevertheless, these methods typically only take into account one-sided effects and overlook the interaction between labeled and unlabeled data in active learning scenarios. Another type of active learning method utilizes auxiliary networks for sample selection, but these methods usually result in higher computational complexity. This paper proposes a novel active learning approach designed to optimize the model's total performance gain by taking into account sample-to-sample interactions and comprehensively measuring local uncertainty and the influence of candidate samples on other samples. The method first estimates the influence of samples on each other based on the distance between the hidden layer representations of the samples, and further estimates the potential gain that the sample can bring based on the influence of candidate samples and the uncertainty of unlabeled samples. The sample with the highest global gain is iteratively chosen for annotation. On a series of tasks across several domains, the study further compares the proposed method with other active learning strategies. Experimental results demonstrate that the proposed method outperforms all competitors in all tasks. Further quantitative analysis experiments have also demonstrated that it balances uncertainty and diversity well, and explores the factors that should be emphasized at different stages of active learning.

**Keywords** Active learning, Deep learning, Uncertainty

## 1 引言

近年来,深度学习在许多领域取得了长足的进展,掀起了一股巨大的浪潮。然而,在绝大部分实际应用中,依赖于大量标注样本的监督学习仍然是深度学习的主要应用场景,并且

深度学习模型通常高度依赖于标注数据的质量。但在部分场景下,标注样本的时间成本与资源成本通常很高,或者未标注样本数量远大于标注样本数量。如何高效地从大量未标注数据中选择最有价值的样本进行标注成为一个亟需解决的重要问题。主动学习范式<sup>[1-2]</sup>正是为了解决这一问题而提出的,其

旨在利用特定的策略来识别大量未标注样本中最有价值的样本,高效地选择样本进行标注,从而使模型可以用尽可能少的标注样本数达到预期的效果。通常,主动学习框架是一个不断迭代的交互式过程,主要由5个核心部分组成:无标注数据池、选择策略、标注者、标注样本集和一个机器学习模型。在每次迭代中,主动学习框架使用选择策略从无标注数据池中筛选样本并将其加入到训练集中,重新训练模型。上述过程将会重复执行,直到训练的模型达到预期效果或者标注样本数达到设定的阈值。

早期的研究已经提出大量的主动学习策略,这些策略可以大致分为两类:基于不确定性的策略<sup>[1,3-4]</sup>和基于多样性的策略<sup>[5-7]</sup>。基于不确定性的策略主要考虑模型对样本输出预测结果的置信程度,而基于多样性的策略则注重样本空间的分布。然而,这两种策略都有缺点,无法实现总体的最优解。基于不确定性的方法可能会选择多个相似的冗余样本,而基于多样性的方法可能会忽略数据分布中不均匀的信息密度。原因在于这两种方法并没有直接考虑主动学习的根本目标,而是基于间接的启发式原则,所以它们在选择样本时会引入一些先验的偏差。

近年来,也有一些结合其他领域思想的主动学习策略被提出。例如 Gissin 等<sup>[8]</sup>将主动学习视为一个对抗问题,利用对抗网络来区分标注样本与未标注样本。Yoo 等<sup>[9]</sup>则通过一个辅助网络来预测无标注样本的损失,进而选择损失最大的样本。然而,这些方法的本质思想仍然是基于不确定性与多样性,并且需要训练额外的神经网络,因此具有更高的时间复杂度,这给它们的应用带来了不便。

针对这些问题,本文提出了一种基于最大影响力集合的主动学习方法(Active Learning Based on Maximum Influence Set, ALMIS),以期能够综合考虑样本的分布与样本的置信程度,选择能够最大程度地在整个无标注数据集上降低不确定性的样本集合。换言之,该策略希望在标注数据集更新前后最大限度地整体数据分布上提高模型性能。不同于以往基于不确定性或多样性的方法,ALMIS的核心目标是最大化样本分布上的整体潜在增益,该方法在不同标注样本规模下能够自适应注重不确定性或多样性。与此同时,本文方法在参数量上也优于基于辅助网络的主动学习策略,其不需要额外的网络结构,使得本文方法更易在实际问题中应用。

为了证明 ALMIS 的有效性和优越性,本文在来自不同领域的多个数据集上,将其与一系列基于不确定性、多样性或两者兼有的基线方法进行了比较,并进一步进行了分析实验,以探索每种方法的优缺点以及主动学习策略在不同阶段的注重要素。本文的主要贡献如下:

1)提出了一种新的主动学习算法 ALMIS,旨在通过估计模型在整体数据分布上潜在的不确定性降低程度来选择最具影响力的样本。本文方法通过样本对之间的距离信息与样本不确定性来综合判断样本的影响力。

2)在不同领域的多项任务上进行实验,验证了 ALMIS 的性能。结果表明,与所有基线方法相比,ALMIS 的表现均更好,证明了其有效性。

3)从不同的角度出发,分析了各种主动学习方法的侧

重点,通过定量实验分析探究了主动学习策略在不同阶段有效与否的关键因素。

本文第2章主要介绍主动学习的相关工作;第3章详细描述 ALMIS 算法,并给出算法的框架与流程;第4章描述实验设置与实验数据集;第5章报告实验结果;最后总结全文并展望未来。

## 2 相关工作

### 2.1 基于不确定性的主动学习方法

基于模型对样本的不确定性采样是最常用的主动学习策略。该框架下主动学习策略的目标是寻找对于当前模型来说最不确定的样本。对于分类模型这样的概率模型,通常可以将模型预测概率分布的信息熵作为样本不确定性的度量。此外,其他方法也考虑使用最大预测概率和第二大预测概率之间的差值<sup>[10]</sup>,或者简单地选择最不置信的样本(Least Confidence, LC)<sup>[5]</sup>,即真实类别,来预测概率最低的样本。此外, Margatina 等<sup>[11]</sup>提出对比主动学习(Contrastive Active Learning, CAL),选择近邻预测概率分布之间的 KL 散度(Kullback-Leibler Divergence)最大的样本,这也是一种局部不确定性度量方式。

近年来,为了引入贝叶斯推断,有研究将模型参数的不确定性纳入考虑。Houlsby 等<sup>[12]</sup>提出了基于分歧的贝叶斯主动学习(Bayesian Active Learning by Disagreement, BALD),这是一种选择模型预测结果和模型参数之间互信息最大的样本的方法。为了将 BALD 应用于深度神经网络, Gal 等<sup>[4]</sup>使用蒙特卡罗(Monte Carlo)采样与丢弃法(Dropout)作为对网络参数的采样<sup>[13]</sup>,通过多次前向传播在深度神经网络上估算最小置信度、预测概率分布的信息熵和 BALD,这对于在深度学习场景中应用这些主动学习策略至关重要。为了进一步验证此类主动学习方法对其他领域问题的适用性, Siddhant 等<sup>[14]</sup>在大量自然语言处理任务上应用上述方法并验证了它们的效果。随着预训练语言模型(如 BERT<sup>[15]</sup>)的流行,部分工作也将主动学习应用于语言模型<sup>[16-18]</sup>,获得了显著效果。然而,由于多次前向传播产生了高计算成本,基于贝叶斯推断的方法应用于大型深度模型的效率非常低。

此外,也有研究将不确定性采样策略应用于非概率模型,如决策树分类器<sup>[1]</sup>和最近邻分类器<sup>[19-20]</sup>。

### 2.2 基于多样性的主动学习方法

与不确定性采样相比,基于多样性的主动学习策略更加注重选择样本的多样性和全面性,其目标是从无标注数据中获得最具代表性的样本。多样性采样策略期望被选择的样本能够最大程度地代表大量类似样本,以减少信息冗余。例如, Nguyen 等<sup>[5]</sup>使用聚类算法来确保采样的多样性和分布均衡性。Sener 等<sup>[6]</sup>提出一种采样核心集(Core Set)的主动学习方法,该方法将主动学习问题转化为核心集问题,目的是在无标注数据池上找到泛化误差最小的训练集。Ash 等<sup>[7]</sup>进一步在每个样本对模型参数的伪梯度上应用 k-means++<sup>[21]</sup>聚类算法,以保证样本对模型梯度的多样性。Yuan 等<sup>[22]</sup>提出了一种用于深度视觉跟踪的主动学习方法,该方法基于多帧协作选择具有多样性的样本,同时基于最近邻判别方法来筛选

孤立样本和低质量样本,以保证样本的代表性。

此外,另一类工作则倾向于选择会显著改变现有模型的样本,这类工作包括预期模型输出变化(Expected Model Output Change, EMOC)<sup>[23-24]</sup>、估计误差减少(Estimated Error Reduction, EER)<sup>[25-26]</sup>、以及预期梯度长度(Expected Gradient Length, EGL)<sup>[27]</sup>等。

### 2.3 基于深度神经网络的主动学习方法

随着深度学习的迅速发展,许多研究将神经网络应用于主动学习研究中,如基于元学习的主动学习算法<sup>[23]</sup>和基于强化学习的方法<sup>[28-29]</sup>等。最新的学习损失方法<sup>[9]</sup>旨在利用神经网络预测无标注数据的潜在“损失”,并选择具有最大“损失”的样本,该方法认为这些样本信息最丰富且最具备指导性。

受生成对抗网络(Generative Adversarial Network, GAN)<sup>[30]</sup>的启发,Gissin等<sup>[8]</sup>创新性地主动学习定义为一个二分类问题,通过训练一个能够区分训练集和无标注数据的对抗分类器来选择与训练集差异最大的样本。继该工作之后,Sinha等<sup>[31]</sup>、Kim等<sup>[32]</sup>和Zhang等<sup>[33]</sup>也在主动学习中利用了对抗网络的思想。然而,这些方法通常需要额外的参数量和计算成本,并且训练不稳定。

为了避免编码器层级的对抗训练,Cho等<sup>[34]</sup>提出基于分类器分歧的主动学习方法,通过计算多个分类器对样本的预测概率分布之间的差异来选择在各个分类器下差异最大的样本。Geng等<sup>[35]</sup>在多个辅助分类器的基础上,加入分类器层级的对抗训练,在增大不同分类器差异的同时尽可能对齐标注样本与无标注样本的分布。

### 2.4 主动学习方法的应用

除了关于主动学习算法本身的研究,也有部分研究将主动学习的思想应用于其他任务,例如文献<sup>[36]</sup>提出利用基于不一致性的主动采样来提高深度神经网络的鲁棒性。Ding等<sup>[37]</sup>则将主动学习应用于文本实体与关系联合抽取的任务。主动学习算法还可以用于构建自动标注系统,Dhiman等<sup>[38]</sup>设计了一种多模态主动学习(Multi-modal Active Learning, MAL)标注模型,使用卷积递归神经网络根据视觉相似的内容或特征自动标注标签。

## 3 基于最大影响力集合的主动学习算法

本章首先给出基于池的主动学习问题的形式化定义,其次概述本文提出的ALMIS的动机与意图,然后讲述该方法的具体细节,最后描述ALMIS的算法流程。ALMIS的整体框架如图1所示。

### 3.1 问题定义

在基于池的主动学习问题中,通常给定初始标签为 $y \in \mathcal{Y}$ 的少量标注数据 $S \subset \Omega$ ,以及从相同输入空间 $\Omega$ 中采样的大量无标注数据池 $\mathcal{U} \subset \Omega$ 。主动学习的目的是选择一批样本 $S' = \{x' | x' \in \mathcal{U}\}$ ,对其进行标注(例如使用人工标注者标注真实标签 $y' \in \mathcal{Y}$ ),并将其添加到标注数据集 $S$ 中,以最大程度地提高在相同标注数据量下训练的模型 $M: \Omega \rightarrow \mathcal{Y}$ 的性能。其中模型 $M$ 由一个编码器 $f$ 与一个分类头 $g$ 组成。本文使用 $x_i \in \mathbb{R}^d$ 代表样本 $i$ ;  $e_i = f(x_i)$ 表示样本 $i$ 经过神经网络编码器获得的表征; $y_i \in \{1, 2, \dots, C\}$ 表示样本 $i$ 对应的真实标签,其中 $C$ 表示标签的类别数。表1列出了本文使用的符号及其定义。

表1 本文使用的符号及其定义

Table 1 Notations in this paper and their definitions

符号	定义
$S = \{(x, y)\}$	标注数据集
$\mathcal{U} = \{x\}$	无标注数据集
$f(\cdot)$	编码器
$g(\cdot)$	分类器
$M(\cdot) = g \circ f(\cdot)$	模型架构
$C$	分类类别数
$\Omega \subset \mathbb{R}^d$	样本输入空间
$\mathcal{Y} = \{1, 2, \dots, C\}$	样本标签集合
$\mathcal{M}(\cdot)$	增益估计函数
$H(\cdot)$	样本预测概率分布熵
$G(\cdot)$	增益估计函数
$e$	样本隐层表征
$B$	样本批量数
$T$	迭代轮数

### 3.2 动机与方法

如第2章所述,之前的研究已经提出许多基于不确定性和多样性的主动学习策略,以及其他启发式的方法。例如选择最具有对比性的样本或者选择对模型梯度最大的样本等。然而,本文认为主动学习策略应该集中于提高模型在整个数据分布上的整体性能,同时要考虑到不确定性在整个样本空间中分布的不均匀性,即要选择具备足够代表性的不确定样本。如图2所示,基于不确定性的方法最有可能选择样本A,因为它距离分类边界最近。而诸如Core-Set<sup>[6]</sup>这样考虑样本多样性的方法则可能会选择样本D或者E,因为此类方法要求选择的样本尽可能覆盖整个样本空间。然而,相比于选择具有最大不确定性或多样性的单个样本,模型更应该选择那些具备足够代表性与影响力且具备不确定性的样本,例如图2中的样本B与样本C,两者周围均有足够多的样本,但C的邻域的不确定性更高,更应该被优先选择。




图1 ALMIS主动学习算法的框架

Fig. 1 Framework of ALMIS active learning algorithm




图2 主动学习样本选择示意图

Fig. 2 Schematic diagram of active learning sample selection

本文认为,少量精心选择的训练样本可以使得模型能够区分相邻区域中的大量未标注样本。换言之,主动学习策略应当选择包含模型尚未掌握且最容易泛化知识(即最具影响力)的样本,而非单纯选择最困难的样本,以最大限度地提高模型在整个数据分布中的整体增益。形式化地,期望目标是选择一个无标注样本池的子集 $S'$ 来最大化以下等式:

$$S^* = \arg \max_{S' \subset \mathcal{U}, |S'|=B} \mathbb{E}_{x \in \mathcal{U}} \mathcal{M}(M_S(x), M_{S \cup S'}(x)) \quad (1)$$

其中, $M_S(x)$ 表示在标注数据 $S$ 上训练的模型, $B$ 是每次选择样本的批量大小, $\mathcal{M}$ 是更新训练集合后潜在的增益。但对于深度神经网络而言,通过更新训练集并重新训练模型来估计模型在样本上的表现的变化是不现实的,但其可以通过其他方式来衡量。本文认为,对于某个未标注样本,其在更新训练集后的模型对其预测表现的增益主要取决于两个因素。

1)该样本距离训练集样本的距离。如果一个样本被选择为训练样本,则其周围的近邻也会受到影响并变得置信。反之,一个无标注样本与训练集的距离越小,则其受到训练样本的影响越大,并在更新训练集后更有可能变得置信。

2)该样本在当前模型下的置信程度。如果一个无标注样本在当前模型的预测不确定性越高,在选择其近邻加入训练集后,带来的增益也会越大。反之,如果一个无标注样本已经很置信,则选择其近邻加入训练集也不会带来明显增益。

对于第一个因素,需要构造一个关于样本距离的递减函数来建模该因素。考虑到样本之间关系的对称性,本文采用具备对称性质的高斯核函数来建模一对样本 $x_i, x_j$ 之间的影响力。

$$K(x_i, x_j) = e^{-\frac{\|e_i - e_j\|^2}{h}} \quad (2)$$

其中, $h$ 表示核函数的带宽,可以根据数据集自身的分布自适应地选择合适的带宽( $h$ 取决于数据集隐含层表征的平均距离)。显然,样本 $x_j$ 距离 $x_i$ 越近, $x_i$ 对 $x_j$ 的影响力越大,反之亦然。需要注意的是,式(2)在样本的隐含层表征 $e_i$ 和 $e_j$ 上计算欧氏距离,这是因为当前模型已经进行过一定的监督训练,模型所抽取的高层语义表征与监督目标 $y$ 的相关性更好,在该层计算距离可以一定程度地排除原始输入 $x_i$ 和 $x_j$ 中与 $y$ 无关的信息,该方式更为合理。

除了样本距离标注样本的距离,第二点需要考虑的因素是样本的不确定性,即被影响的样本本身应当是不确定的。类似之前的工作,本文利用基于样本集 $S$ 训练的模型对样本 $x$ 的预测分布信息熵来衡量样本在当前模型下的不确定性。

$$H(x) = -\sum_c p(y=c|x, S) \log p(y=c|x, S) \quad (3)$$

其中, $c$ 表示预测类别。信息熵越大,表示当前模型对该样本的预测结果越不确定。综合考虑以上两点因素,本文将选择样本 $x_i$ 后会对无标注样本 $x_j$ 带来的潜在收益表示为 $x_i$ 对 $x_j$ 的影响力与样本 $x_j$ 的不确定性的乘积。

$$G(x_i, x_j) = H(x_j)K(x_i, x_j) \quad (4)$$

其中, $H(x_j)$ 表示样本 $x_j$ 的预测熵,根据式(3)计算得到; $K(x_i, x_j)$ 根据式(2)计算得到。获得了单个无标注样本可能的增益,对于任意一个候选样本 $x_i$ ,就可以基于其在整个无标注数据集上的平均增益来评估其是否应当被选择。更直观的

理解是,根据候选样本 $x_i$ 的影响力与其局部的信息密度来选择最有价值的样本。

需要注意的是,式(4)仅表示一对样本之间的增益,实际的主动学习算法通常每次选择一批样本进行标注,其中每个被选择的样本均会对所有无标注样本产生影响。但这些影响不应该被单纯叠加,因为当一个无标注样本受到周围多个训练样本影响时,其边际收益是递减的。此外,这种方式也会导致某个区域的样本被重复选择,因为相同区域的样本具有相近的总收益。为了将样本选择的排他性纳入考虑,对于每一个受到多个被选择样本影响的无标注样本,本文仅计算其受到的最大增益 $\max_{x_k \in S} G(x_i, x_j)$ 。由于计算在所有可能的子集 $S' \subset \mathcal{U}$ 上的全局最优解的复杂度极高,因此本文采用贪心算法,每次迭代选择具有最大边际增益的样本,然后将其添加到训练集中。

$$\arg \max_{x_i \in \mathcal{U}} \frac{1}{|\mathcal{U}|} \sum_{x_j \in \mathcal{U}} \max(0, G(x_i, x_j) - \max_{x_k \in S} G(x_k, x_j)) \quad (5)$$

其中, $G$ 根据式(4)计算得到。

### 3.3 算法流程

本节描述基于ALMIS的主动学习循环流程。假设存在一个具有 $C$ 类的分类任务、一个标注的数据集 $S$ 和一个未标注的数据池 $\mathcal{U}$ ,给定模型架构 $M$ 、迭代时间 $T$ 和每次迭代中的主动学习策略选择的样本批量大小 $B$ ,算法输出在最终标注集合上训练的模型 $M_T$ 。ALMIS的流程如算法1所示。

**算法1** 基于最大影响力集合的主动学习算法

输入:模型 $M$ ,无标注样本池 $\mathcal{U}$ ,初始标注样本集 $S$ ,迭代轮数 $T$ ,每次迭代批量大小 $B$

输出:最终模型 $M_T$

1. for  $t \leftarrow 1$  to  $T$  do
2. 在标注数据集 $S$ 上训练模型 $M_t$
3. for  $i \leftarrow 1$  to  $|\mathcal{U}|$  do
4. 计算样本 $x_i$ 的表征 $e_i$
5. 计算样本 $x_i$ 的预测分布信息熵 $H(x_i)$
6. end for
7. 计算每一对样本之间的 $G(x_i, x_j) = H(x_j)K(x_i, x_j)$
8. for  $b \leftarrow 1$  to  $B$  do
9. 计算样本 $x_i$ 对无标注样本集 $\mathcal{U}$ 的边际收益总和
 
$$G_i = \frac{1}{|\mathcal{U}|} \sum_{x_j \in \mathcal{U}} \max(0, G(x_i, x_j) - \max_{x_k \in S} G(x_k, x_j))$$
10. 选择收益最大的样本 $x_s = \arg \max_{x_i \subset \mathcal{U}} G_i$
11. end for
12. end for
13. return  $M_T$

在每次迭代中,ALMIS首先基于当前标注集训练模型 $M_T$ 。其次,ALMIS将无标注集合 $\mathcal{U}$ 中的所有样本通过模型,计算其预测分布信息熵和隐含层表征。然后,ALMIS根据式(4)计算每个样本对之间的增益,得到增益矩阵 $G$ 。基于矩阵 $G$ ,ALMIS迭代地根据式(5)计算收益最大的样本,然后将所选样本添加到标注样本集合中。在执行上述操作 $B$ 次之后,即获得了该轮更新后的标注数据集 $S$ ,用于下一次迭代中的模型训练。

在执行上述过程  $T$  次后,主动学习循环达到停止条件并获得最终的标注数据集与在该集合上训练的模型  $M_T$ 。以上即整个主动学习算法循环的流程。

## 4 实验设置

### 4.1 数据集

为了验证主动学习算法的有效性,在不同领域的多个数据集上进行了实验。参考 Gal 等<sup>[4]</sup>和 Siddhant 等<sup>[14]</sup>的工作,实验数据集包含图像分类数据集 MNIST<sup>[39]</sup>、文本分类数据集 TREC<sup>[40]</sup>以及来自于 OpenML 的传统机器学习字母分类数据集 OpenML # 6。这些数据集的类别信息与样本数量信息如表 2 所列。

表 2 实验数据集信息  
Table 2 Experimental dataset information

Dataset	Classes	Train	Test
MNIST	10	60 000	10 000
TREC	6	5 452	500
OpenML # 6	26	16 000	4 000

### 4.2 基线方法

为了评估 ALMIS 方法的效果,将其与基于不确定性的传统主动学习方法以及近年来几种有影响力的主动学习方法进行了比较,比较的基线方法如下。

1) Random: 从未标注数据池中随机采样。

2) Entropy: 基于模型对样本预测结果的不确定性,选择模型预测分布信息熵最大的样本。

3) BALD<sup>[12]</sup>: 基于分歧的贝叶斯主动学习,选择模型输出和模型参数之间的互信息最大的样本。本文使用基于丢弃法和蒙特卡洛采样的近似方法来估算 BALD 中的互信息<sup>[4]</sup>。

4) Core-Set<sup>[6]</sup>: 该工作将主动学习定义为寻找问题,其中通过理论推导证明,任何选定的样本子集的泛化误差上界取决于样本点的几何位置分布。基于此,该方法进一步使用聚类方法来选择核心集。

5) BADGE<sup>[7]</sup>: 一种通过对模型最后一层参数的伪梯度进行聚类,从而尽可能多样化梯度表征的批量式主动学习方法。该方法能够自然地融合多样性和不确定性,并且在足够简单的同时具备很好的效果。

6) CAL<sup>[11]</sup>: 对比主动学习,通过计算相邻数据点的预测概率分布之间的 KL 散度来选择最具对比性的样本的主动学习方法。

7) MCDAL<sup>[34]</sup>: 基于分类器分歧的主动学习方法,计算多个分类器对样本的预测概率分布之间的差异来选择在各个分类器下差异最大的样本。

### 4.3 实现细节

在不同数据集上,实验采用不同的网络架构。在 MNIST 上,本文沿用 Gal 等<sup>[4]</sup>的工作,使用两层的层卷积神经网络(CNN)。该网络具有 32 个  $3 \times 3$  大小的卷积核,以及一个  $2 \times 2$  的池化层,一个 128 个神经元的线性层。对于 OpenML 数据集,与 Ash 等<sup>[7]</sup>的工作一致,本文使用多层感知器(Multilayer Perceptron, MLP)与 ReLU 激活函数,并

将 MLP 的隐含层维度设置为 1024。对于 TREC 数据集,沿用 Siddhant 等<sup>[14]</sup>的研究,本文采用双向长短期记忆网络(Bidirectional Long Short-Term Memory, BiLSTM)<sup>[41]</sup>作为网络架构,并使用 300 维的 glove 预训练词向量<sup>[42]</sup>作为词表征的初始化。

关于主动学习循环的设置,本文也参考了之前的研究<sup>[4,14,20]</sup>。对于 MNIST,初始训练集大小为 20,并在每轮迭代中选择 10 个样本加入训练集,直到标注样本量达到 1000。对于 OpenML 数据集,初始训练集大小为 100,并在每次迭代中增加 100 个样本,直到有 4000 个标注样本为止。对于 TREC,初始训练集大小为全训练样本的 1%,并在每一轮迭代中选择 1% 的样本加入训练集,直到训练样本数达到全样本的 20%。

在模型优化方面,本文使用 Adam 优化器<sup>[43]</sup>训练模型,在所有数据集上均训练 50 个回合。优化器初始学习率为  $1 \times 10^{-3}$ ,权重衰减为  $5 \times 10^{-4}$ , $\beta_1$  为 0.9, $\beta_2$  为 0.999。为了避免过拟合,在训练过程中利用一个小规模验证集来选择最佳模型,并在每个回合中评估一次。对于原本没有验证集的数据集,将随机从训练集中抽取 3% 作为验证集。对于模型效果的评估,本文使用各数据集的标准测试集。此外,在所有数据集上,在主动学习的每次迭代中均会重新初始化模型参数并重新训练模型。

为了确保结果的可靠性和稳健性,本文在不同的随机种子下重复所有实验 3 次,并报告平均结果。实验中所有模型都基于 PyTorch 实现,并在单个 Nvidia 3090 GPU 上进行训练。

## 5 实验结果

### 5.1 主要结果

为了评估 ALMIS 方法的性能,本文将 ALMIS 与上述多种基线方法进行了比较。如图 3 所示,在各数据集上,随着主动学习算法迭代轮数的增加,各个主动学习策略在测试集上的平均准确率与 F1 值(多个随机种子的平均值)均有提升。可以观察到,在 MNIST, OpenML # 6 和 TREC 数据集上,ALMIS 均表现出了比所有基线方法更好的效果,并且在所有数据集上,ALMIS 在标注样本较少时取得的增益更为明显,相较于其他方法的提升也更为明显。随着标注样本数量的增加,增益则逐渐降低。BADGE 则是所有任务上平均表现第二好的方法,这主要是由于它将伪梯度和聚类方法相结合,同时考虑了不确定性和多样性。然而,BADGE 仍然逊色于 ALMIS,因为它忽略了样本之间的相互作用,并且没有考虑样本空间的局部密度。

表 3 进一步列出了各个主动学习策略达到全样本性能的 90% 所需要的样本数占全样本的比例。容易观察到,在所有数据集上,ALMIS 均只需要最少的数据量就能够达到 90% 的全样本训练性能。相比于随机采样,ALMIS 在 MNIST, OpenML # 6 和 TREC 数据集上需要的数据量分别减少了 0.52%, 7.1%, 6.4%。实验结果进一步证明了 ALMIS 在一系列任务上的有效性和优越性。

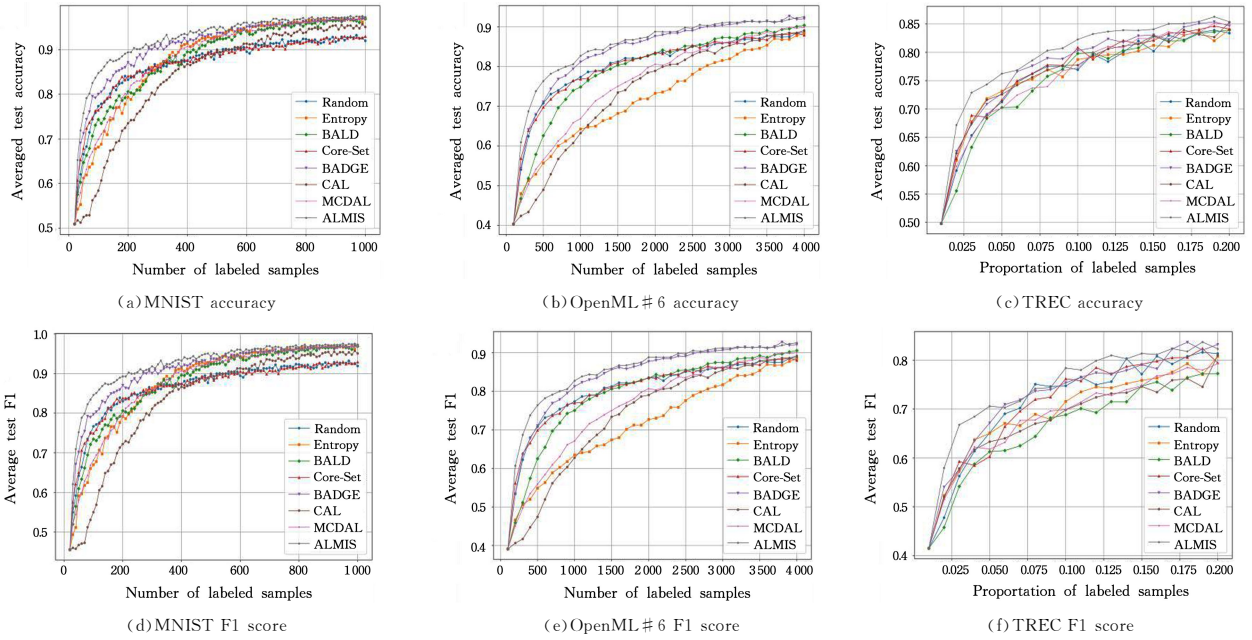


图3 各个主动学习策略下模型的准确率曲线与F1值曲线

Fig. 3 Accuracy curves and F1 score curves with different active learning strategies

表3 各个主动学习策略达到全样本性能的90%所需的样本数比例

Table 3 Proportion of samples required for each active learning strategy to achieve 90% of the training performance of full data

Dataset	MNIST	OpenML #6	TREC
Random	0.90	15.6	18.0
Entropy	0.69	21.6	17.8
BALD	0.79	14.9	18.7
Core-Set	0.93	15.5	16.8
BADGE	0.52	9.0	16.6
CAL	0.98	18.4	16.8
MCDAL	0.73	17.2	15.9
ALMIS	0.38	8.5	11.6

另一个重要的实验结论是,在主动学习迭代的前期,聚焦于模型不确定性的方法,例如 Entropy 与 BALD,通常表现更差,甚至不如 Random 的结果;而在主动学习迭代的后期,未能考虑模型预测概率信息的两种方法,即 Random 和 Core-Set,总是比不确定性的方法表现更差。这表明主动学习问题在不同阶段(或者说不同的样本标注量下)侧重的目标应该是不同的。ALMIS 很好地权衡了两者并且自适应地不同阶段侧重不同的因素。观察图 3(a)中的结果,ALMIS 在早期阶段具有更明显的优势(例如,100 个标注样本时的 ALMIS 为 84.76%,而 BADGE 仅为 80.03%)。原因是 ALMIS 在早期倾向于具有高多样性的样本,因为此时整体的不确定样本仍然是大量且分布不集中的;而 Entropy 可能会获得许多十分相似的冗余样本。这一结论也可以从 Entropy 策略早期的失败中得出(例如,在 100 个标注样本的情况下,Entropy 策略的表现甚至比 Random 更差,68.17% vs 77.33%)。而当已经有足够的标记样本来保证多样性时,基于不确定性的策略才显示出有效的性能。ALMIS 则自适应地在后期更倾向于不确定样本,因为只有不确定样本才能够对其他样本产生足够的影响并带来增益。在 5.4 节中将进一步量化地分析不确定性与多样性之间的权衡。

## 5.2 算法性能分析

为了探究 ALMIS 的算法性能,本文在 MNIST 数据集上,从计算量和算法参数数量两个方面对不同算法进行定量分析。其中,计算量基于主动学习循环迭代一轮的平均消耗时间来评估;参数量则只统计除模型参数之外需要的额外参数数量。

实验结果如表 4 所列。从计算量角度看,Random 方法耗时最短,这是因为 Random 方法不需要计算每个样本的模型输出。Entropy 与 MCDAL 次之,其中 MCDAL 方法由于有多个辅助分类器用于计算分类器差异,因此耗时高于 Entropy。Core-Set, BADGE, CAL 以及 ALMIS 这 4 种方法需要计算每一对样本隐含层表征之间的距离,故消耗时间相较于 Entropy 更长。其中,ALMIS 方法选择批量样本时需要逐个选择,因此耗时会略高于其他 3 种方法。BALD 方法的耗时则远超其他所有方法,这是因为该方法需要将每个样本多次通过模型以模拟对模型参数的采样,故计算量最高。此外,从参数量的角度分析,除了 MCDAL 方法需要额外的辅助分类器,其余方法均不会增加模型参数数量。综合来看,ALMIS 方法在计算量与参数量上均没有显著高于基线方法,验证了 ALMIS 的实用价值。

表4 不同算法的计算量与额外参数量


Table 4 Amount of calculation and extra parameters of different algorithms

算法	迭代一轮消耗时间/ms	额外参数量
Random	0.52	0
Entropy	137	0
BALD	13 224	0
Core-Set	353	0
BADGE	297	0
CAL	347	0
MCDAL	157	2 580
ALMIS	383	0


### 5.3 探究样本选择排他性的影响

为了进一步研究主动学习方法有效的原因,本节通过消融实验探究样本排他性的影响。在式(5)中,ALMIS算法在每次迭代中只考虑边际增益,这有助于避免在同一区域中重复选择具有相似增益的样本,也即隐式地考虑了样本的排他性。为了探索这一设置的合理性,消融实验将式(5)替换为:


$$\arg \max_{x_i \subset u} \frac{1}{|U|} \sum_{x_j \in u} G(x_i, x_j) \quad (6)$$



(a) MNIST



(b) OpenML #6



(c) TREC

图4 样本选择排他性的消融实验

Fig. 4 Ablation study on exclusivity of sample selection

### 5.4 主动学习算法的量化指标分析

为了量化地分析各个主动学习策略的侧重点,并探究不同阶段影响主动学习策略效果的关键因素,本文从3个角度对各个主动学习策略进行了量化分析。

1)不确定性的衡量。与Yuan等<sup>[44]</sup>的工作一致,本文基于全部数据训练的模型来衡量主动学习策略选择的样本的不确定性,以确保每种主动学习方法对比的公平性以及不确定性衡量的可靠性。对于每个样本 $x$ ,首先计算模型对该样本的预测概率熵,然后计算各个主动学习算法在整个迭代过程中所选择的所有样本的熵的平均值 $-\frac{1}{|Q|} \sum_{x \in Q} \sum_c p(y=c|x)$   $\log p(y=c|x)$ 作为不确定性的衡量指标,其中, $Q$ 是主动学习策略在整个循环中选择的样本集合。

2)多样性的衡量。具有较高多样性的样本子集意味着它对整体数据分布的覆盖范围足够广,并且无标注池中的每个样本都应该足够接近某个标注样本。类似之前的工作<sup>[16,45]</sup>,本文利用每个无标注样本距离标注样本的最小距离的平均值的倒数来评估主动学习策略选择的标注样本集的多样性,即 $\left(\frac{1}{|U|} \sum_{x_i \in U} \min_{x_j \in Q} d(x_i, x_j)\right)^{-1}$ 。其中, $Q$ 是主动学习策略选择的样本集合; $d$ 表示距离度量函数,这里采用模型隐含层表征上的欧氏距离。

3)代表性的衡量。评估主动学习方法的代表性的目的是观察主动学习策略选择的样本是否能够很好地代表整个数据分布,或者说采样权重是否符合原始数据分布的概率密度。不同于多样性,代表性需要考虑样本分布的密度,而非单纯地考虑覆盖性,因此计算主动学习策略选择的样本集的平均局部密度作为代表性的量化指标。Zhu等<sup>[46]</sup>提出了一种局部密度估计的方式,即某一样本点与其 $K$ 个最接近的样本点的平均距离的倒数,则代表性可以表示为 $\left(\frac{1}{|Q|} \sum_{x_i \in Q} \frac{1}{K} \sum_{x_j \in KNN(x_i)} d(x_i, x_j)\right)^{-1}$ 。

这样,来自同一相邻区域的相似样本将具有相似的总体增益,并且它们更有可能被重复选择,这可能导致主动学习算法无法选择更多样的样本。本文在所有数据集上比较了ALMIS、去除边际增益机制的ALMIS和Random采样方法。图4展示了消融实验的结果。可以观察到,在没有隐含地考虑排他性的情况下,在MNIST与OpenML #6上主动学习策略仍然优于随机选择,而在所有数据集上都显著次于ALMIS,这表明了主动学习策略考虑样本排他性的必要性。

$(x_i, x_j)^{-1}$ ,其中 $K=10$ , $KNN(x_i)$ 表示样本 $x_i$ 的 $K$ 近邻。本文在模型倒数第二层表征上计算欧氏距离下的 $K$ 近邻。

量化分析的结果如表5所列,其中UNC,DIV和REPR分别表示不确定性、多样性和代表性。在不确定性指标上,最大熵的方法毫无疑问获得了最高的不确定性分数,相反,随机采样和Core-Set的不确定性分数最低,因为这两种方法是唯一没有考虑到样本预测概率熵的策略。从多样性的角度来看,每种方法的差距并不明显。BADGE和Core-Set获得了最高的多样性分数,因为它们采用了聚类方法来最大限度地覆盖数据分布。最后,观察代表性指标的结果,可以发现Random优于其他方法。这与之前提到的假设是一致的,随机采样策略在空间上的权重分布正好取决于某一点的局部密度,其采样结果能够最好地代表整体数据分布。而其他方法涉及某种采样偏置(例如最大熵策略注重不确定的样本),实际上是对原始数据分布的有偏采样,因此在代表性指标上较差。综合来看,选择不确定性最高、多样性最高或者代表性最高的样本都不是主动学习的最优策略,而ALMIS很好地平衡了三者,取得了最优结果。

表5 MNIST数据集上各个主动学习策略在不确定性、多样性与代表性上的量化指标分析

Table 5 Uncertainty, diversity and representativeness analysis of each active learning strategy on MNIST dataset

Method	UNC	DIV	REPR
Random	0.067	0.083	0.129
Entropy	0.470	0.067	0.078
BALD	0.333	0.069	0.085
Core-Set	0.060	0.085	0.104
BADGE	0.216	0.085	0.097
CAL	0.206	0.076	0.089
MCDAL	0.262	0.075	0.088
ALMIS	0.302	0.081	0.113

此外,结合表5和图3中的实验结果,容易发现考虑不

确定性的方法在后期表现更好,但在早期表现较差。相反,专注于代表性的方法在早期阶段通常是更优越的。这种现象可归因于两个方面:一方面,当标记集不足以充分训练模型时,熵的评估是不可靠的;另一方面,最大熵策略可能会采样冗余的相似样本(最大熵策略的代表性分数最低)。总的来说,本文方法具有第二高的代表性和足够的不确定性,在不确定性、多样性和代表性之间实现了最佳的平衡。

**结束语** 本文提出了 ALMIS,这是一种新的有效的主动学习策略,旨在通过估计模型在整体数据分布上潜在的不确定性降低来选择最具影响力的样本。实验结果表明,ALMIS的效果优于一系列基于不同出发点的基线模型。进一步的分析实验也表明,ALMIS在多样性和不确定性之间进行了自适应的有效权衡。通过比较各种主动学习策略,本文进一步分析了主动学习策略在不同阶段取得成功的关键因素,并展示了ALMIS在不同阶段自适应注重不同因素的优势。

基于 ALMIS,未来的研究可以集中于以下两点:1)寻找更好的样本距离度量方式,例如综合考虑网络不同层的表征,以同时考虑浅层与深层的样本语义特征;2)利用参数化模型建模样本之间的影响力,以更加准确地评估样本能够带来的整体增益。

## 参 考 文 献

[1] LEWIS D D, CATLETT J. Heterogeneous uncertainty sampling for supervised learning [C] // Machine Learning Proceedings 1994. Elsevier, 1994: 148-156.

[2] COHN D A, GHAMRANI Z, JORDAN M I. Active learning with statistical models [J]. Journal of Artificial Intelligence Research, 1996, 4: 129-145.

[3] LEWIS D D. A sequential algorithm for training text classifiers: Corrigendum and additional data [C] // Acm Sigir Forum, 1995: 13-19.

[4] GAL Y, ISLAM R, GHAMRANI Z. Deep bayesian active learning with image data [C] // Proceedings of the 34th International Conference on Machine Learning, 2017: 1183-1192.

[5] NGUYEN H T, SMEULDERS A. Active learning using pre-clustering [C] // Proceedings of the Twenty-first International Conference on Machine Learning, 2004.

[6] SENNER O, SAVARESE S. Active learning for convolutional neural networks: A core-set approach [C] // International Conference on Learning Representations, 2018: 1-13.

[7] ASH J T, ZHANG C, KRISHNAMURTHY A, et al. Deep batch active learning by diverse, uncertain gradient lower bounds [C] // International Conference on Learning Representations, 2020: 1-26.

[8] GISSIN D, SHALEV-SHWARTZ S. Discriminative active learning [J]. arXiv: 1907. 06347, 2019.

[9] YOO D, KWEON I S. Learning loss for active learning [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 93-102.

[10] ROTH D, SMALL K. Margin-based active learning for structured output spaces [C] // European Conference on Machine Learning, 2006: 413-424.

[11] MARGATINA K, VERNIKOS G, BARRAULT L, et al. Active learning by acquiring contrastive examples [C] // Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing, 2021: 650-663.

[12] HOULSBY N, HUSZR F, GHAMRANI Z, et al. Bayesian active learning for classification and preference learning [J]. arXiv: 11125745, 2011.

[13] GAL Y, GHAMRANI Z. Dropout as a bayesian approximation: Representing model uncertainty in deep learning [C] // Proceedings of the 33rd International Conference on Machine Learning, 2016: 1050-1059.

[14] SIDDHANT A, LIPTON Z C. Deep bayesian active learning for natural language processing: Results of a large-scale empirical study [C] // Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018: 2904-2909.

[15] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding [C] // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2019: 4171-4186.

[16] EIN-DOR L, HALFON A, GERA A, et al. Active Learning for BERT: An Empirical Study [C] // Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing, 2020: 7949-7962.

[17] SHELMANOV A, PUZYREV D, KUPRIYANOVA L, et al. Active learning for sequence tagging with deep pre-trained models and Bayesian uncertainty estimates [C] // Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics, 2021: 1698-1712.

[18] MARGATINA K, BARRAULT L, ALETRAS N. On the Importance of Effectively Adapting Pretrained Language Models for Active Learning [C] // Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers), 2022: 825-836.

[19] LINDENBAUM M, MARKOVITCH S, RUSAKOV D. Selective sampling for nearest neighbor classifiers [J]. Machine Learning, 2004, 54(2): 125-152.

[20] WAN F, YUAN T, FU M, et al. Nearest Neighbor Classifier Embedded Network for Active Learning [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 10041-10048.

[21] ARTHUR D, VASSILVITSKII S. K-means++ the advantages of careful seeding [C] // Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms, 2007: 1027-1035.

[22] YUAN D, CHANG X, LIU Q, et al. Active Learning for Deep Visual Tracking [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 35(10): 13284-13296.

[23] FREYTAG A, RODNER E, DENZLER J. Selecting influential examples: Active learning with expected model output changes [C] // European Conference on Computer Vision, 2014: 562-577.

[24] KDING C, RODNER E, FREYTAG A, et al. Active and continuous exploration with deep neural networks and expected model output changes [J]. arXiv: 1612. 06129, 2016.

- [25] ROY N, MCCALLUM A. Toward optimal active learning through sampling estimation of error reduction [C] // Proceedings of the Eighteenth International Conference on Machine Learning. 2001:441-448.
- [26] MAC AODHA O, CAMPBELL N D F, KAUTZ J, et al. Hierarchical subquery evaluation for active learning on a graph [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2014:564-571.
- [27] SETTLES B, CRAVEN M, RAY S. Multiple-instance active learning [C] // Advances in Neural Information Processing Systems 20, Proceedings of the Twenty-First Annual Conference on Neural Information Processing Systems. 2007:1289-1296.
- [28] FANG M, LI Y, COHN T. Learning how to active learn: A deep reinforcement learning approach [C] // Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. 2017:595-605.
- [29] LIU M, BUNTINE W, HAFFARI G. Learning how to actively learn: A deep imitation learning approach [C] // Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2018:1874-1883.
- [30] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C] // Proceedings of the 27th International Conference on Neural Information Processing Systems (Volume 2). 2014:2672-2680.
- [31] SINHA S, EBRAHIMI S, DARRELL T. Variational adversarial active learning [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019:5972-5981.
- [32] KIM K, PARK D, KIM K I, et al. Task-aware variational adversarial active learning [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021:8166-8175.
- [33] ZHANG B, LI L, YANG S, et al. State-relabeling adversarial active learning [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:8756-8765.
- [34] CHO J W, KIM D J, JUNG Y, et al. Medal: Maximum classifier discrepancy for active learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(11):8753-8763.
- [35] GENG L, LIU N, QIN J. Multi-classifier adversarial optimization for active learning [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2023:7687-7695.
- [36] ZHOU H, SHI H C, TU Y F, et al. Robust Deep Neural Network Learning Based on Active Sampling [J]. Computer Science, 2022, 49(7):164-169.
- [37] DING H, ZOU P, ZHAO J, et al. Active Learning-based Text Entity and Relation Joint Extraction Method [J]. Computer Science, 2023, 50(10):126-134.
- [38] DHIMAN G, KUMAR A V, NIRMALAN R, et al. Multi-modal active learning with deep reinforcement learning for target feature extraction in multi-media image processing applications [J]. Multimedia Tools and Applications, 2023, 82(4):5343-5367.
- [39] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [40] VOORHEES E M, TICE D M. Building a question answering test collection [C] // Proceedings of the 23rd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. 2000:200-207.
- [41] SCHUSTER M, PALIWAL K. Bidirectional recurrent neural networks [J]. IEEE Transactions on Signal Processing, 1997, 45(11):2673-2681.
- [42] PENNINGTON J, SOCHER R, MANNING C D. Glove: Global vectors for word representation [C] // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. 2014:1532-1543.
- [43] KINGMA D P, BA J. Adam: A method for stochastic optimization [C] // International Conference on Learning Representations. 2015:1-15.
- [44] YUAN M, LIN H T, BOYD-GRABER J. Cold-start active learning through self-supervised language modeling [C] // Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. 2020:7935-7948.
- [45] ZHDANOV F. Diverse mini-batch active learning [J]. arXiv: 1901.05954, 2019.
- [46] ZHU J, WANG H, YAO T, et al. Active learning with sampling by uncertainty and density for word sense disambiguation and text classification [C] // Proceedings of the 22nd International Conference on Computational Linguistics (Coling 2008). 2008:1137-1144.



**LI Yahe**, born in 2000, postgraduate. His main research interests include machine learning and nature language processing.



**XIE Zhipeng**, born in 1976, Ph.D, associate professor, Ph. D supervisor, is a member of CCF (No. 50903M). His main research interests include data mining, machine learning and natural language processing.