

基于实例的近邻传播偏标签学习算法

李博,熊天龙,杜宇慧*

(山西大学 计算机与信息技术学院,山西 太原 030006)

摘要:大多数偏标签学习算法的候选标签集生成方式没有很好地利用部分样本的可靠先验信息,建立的模型不适合现实情况中部分样本存在易混淆的候选标签的情况。另外,很多偏标签算法仅利用近邻节点来构建图,忽视了可靠度高的样本的信息的重要性。针对如何生成更符合现实情况的候选标签集并有效利用可靠度高的样本的信息,本文提出一种新的基于实例的近邻传播偏标签学习算法(Instance-based nearest neighbor propagation partial label learning, INNPL)。INNPL在候选标签集生成方面更好地利用先验信息,通过求取同一类内两两样本的相似度来选取可靠度高的典型样本并信任典型样本的原始标签,对其他样本的候选标签的生成根据它和典型样本中心之间的相似度进行。此外,INNPL迭代地根据样本的近邻样本和近邻典型样本建立和更新图结构,对样本分层逐步地进行标签传播,最终得到可靠的分类结果。本文基于三种UCI(University of California Irvine)数据集和两种图像数据对INNPL进行测试,并和七种偏标签学习方法进行全面的比较。准确度、精确度、召回率和F1分数四种分类指标评估结果显示,INNPL在三个数据集上达到最优,在另外两个的数据集上与最优算法结果相近。关于准确度指标,INNPL算法与其他任意一种偏标签算法经过配对 t 检验比较的结果同样证实了INNPL算法性能优异。综合不同数据集的四种分类指标结果,INNPL的综合排名位列第一。总之,INNPL从多个实验中证实了自身的有效性,可以有效提升分类准确度,也为偏标签学习提供了新的解决思路。

关键词:偏标签学习;图;基于实例的近邻传播;分类

中图分类号:TP 181 **文献标志码:**A **文章编号:**0253-2395(2024)06-1164-14

Instance-based Nearest Neighbor Propagation Based Partial Label Learning Method

LI Bo, XIONG Tianlong, DU Yuhui*

(School of Computer and Information Technology, Shanxi University, Taiyuan 030006, China)

Abstract: The candidate label set generation method for most partial label learning methods does not make good use of the reliable prior information of samples, consequently, the probably resulted trained models are unsuitable for realistic situations where some samples have confusing candidate labels. In addition, many partial label learning algorithms only use nearest neighbor nodes to construct graphs, but neglect the importance of reliable sample information. A new instance-based nearest neighbor propagation partial label learning method (INNPL) is proposed to address the problem of how to generate more realistic candidate label sets and effectively utilize the information from highly reliable samples. In terms of candidate label sets generation, INNPL takes advantages of the prior information. For high-reliability samples, INNPL selects them by calculating the similarity between pairwise samples in the same class, and trusts the original labels of typical samples. For other samples, their candidate labels are generated based on the simi-

收稿日期:2023-01-19;**接受日期:**2023-04-28

基金项目:国家自然科学基金(62076157;61703253);山西省留学人员科技活动择优资助项目(20210033)

作者简介:李博(1997-),男,山西大同人,硕士研究生,主要研究方向为机器学习、偏标签学习。E-mail:13934741978@163.com

* **通信作者:**杜宇慧(DU Yuhui),E-mail:duyuhui@sxu.edu.cn

引文格式:李博,熊天龙,杜宇慧.基于实例的近邻传播偏标签学习算法[J].山西大学学报(自然科学版),2024,47(6):1164-1177. DOI:10.13451/j.sxu.ns.2023087

ilarity between themselves and the typical sample center. INNPL also iteratively builds and updates graph structures based on nearest neighbor samples and highly reliable samples, and progressively propagates labels in layers over the samples to finally obtain reliable classification results. The validation of INNPL algorithm is tested based on three UCI ((University of California Irvine)) datasets and two image datasets and compared with seven partial label learning methods. The evaluation results of the four classification metrics including accuracy, precision, recall and $F1$ coefficient show that INNPL achieves the best performance on three datasets and is close to the optimum algorithm on the other two. Regarding the accuracy metric, the results of INNPL compared with any of the other partial label learning algorithms by paired t -test also confirm the superior performance of INNPL. Our method ranks first in the overall metric of the four classification metrics. In conclusion, INNPL confirms its effectiveness from several experiments, which can effectively improve the classification accuracy and also provides a new solution idea for partial label learning.

Key words: partial label learning; graph; instance-based nearest neighbor propagation; classification

0 引言

偏标签学习属于弱监督学习框架^[1]。不同于完全信任实例样本标签信息的有监督学习和只使用实例样本特征信息的无监督学习,弱监督学习假定实例样本中存在标签缺失、不可靠、错误的情况。因此,如何从携带不准确信息的实例样本中挖掘有效信息并构建模型是弱监督学习的主要问题^[2]。在偏标签学习中,训练样本的标签并不是唯一且明确的,而是包含不准确的标签信息。在本文中, X 表示实例样本集合, Y 表示标签集合, $Y = \{\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_q\}$ 代表 q 个类别的标签。也就是说,每个训练样本 $x_i (x_i \in X)$ 对应一个候选标签集 $S_i (S_i \in Y)$,这个候选标签集 S_i 包含多个可能的候选标签。偏标签学习的训练集是 $D = \{(x_i, S_i) | 1 \leq i \leq m\}$, m 表示训练集的所有样本个数。偏标签学习基于训练集 D 训练一个多类分类模型,基于训练好的模型对新的样本 x 进行分类,最终每个新样本被赋予一个标签 y ^[3-6]。

在现实情况中,由于人工标记成本昂贵或标注工作需要标注者极高的专业素养,部分数据存在标签不正确或者不精确的问题^[7]。例如,在精神疾病诊断领域,医生对于症状重叠、病症相似的精神疾病往往难以确诊^[8];在互联网应用领域,不同用户对同一个样本标注的多个标签可能仅有一个是正确的^[9];在网络挖掘领域^[10]、多媒体分析领域^[11-12]、生态信息学^[13]等领域都有类似的情况。偏标签学习可以在标签不准确的情况下发挥它独特的优势。

同时,已有的偏标签学习算法还存在一些有待改进的问题。很多偏标签学习算法^[14-15]使

用的候选标签集是通过在原始标签的基础上随机添加训练实例样本的额外标签这种方式生成的。这种做法不符合标签混淆程度很高、难以被区分的现实情况。其次,已有的偏标签学习方法^[4,16]在信息传播时平等地对待所有最近邻样本,或者仅通过样本间相似度确定不同节点在标签信息传播时的权重,但忽视了部分可靠度高但并非最近邻样本的样本信息的重要性。

为了解决上述问题,本文提出了一种新的基于实例的近邻传播偏标签学习算法(Instance-based Nearest Neighbor Propagation Partial Label Learning, INNPL)。INNPL基于训练样本(实例)的特征以及样本间相似度,挖掘训练样本中可靠度高的典型样本,同时利用最近邻样本和最近邻典型样本建立和更新表示样本间关系的稀疏加权图,以分层方式对样本进行标签传播,提高了分类模型标签推理的准确度。本文的主要贡献如下:

(1) INNPL在候选标签集生成方面更好地利用了先验信息,使得候选标签集更加贴近现实情况。对于典型样本,不为其候选标签集添加额外的随机标签。而对于非典型样本,则通过计算它们与各类别中心的距离,精选出多个高置信度的类别标签来共同构成候选标签集。这一做法不仅有效缓解了原始标签可能存在的不准确性,还精准地捕捉到了现实中候选标签易于混淆的实际情况。

(2) INNPL建立特殊的 $K+N$ 近邻节点图结构来进行标签信息的传播,有效利用了可靠度高的典型样本的信息。本文方法自动提取每个类别中的典型样本,对每个样本建立其与 K 个最近邻样本节点和 N 个最近邻典型样本节点

的连接。这种模型构建方式有助于强化典型样本信息传播,使消歧后的样本标签更加可靠。

(3) INNPL 在信息传播中使用迭代分层传播思想逐步对待传播样本标签进行标签消歧,传播方式更加合理。不同于大多数已有方法中对所有样本只进行一次传播的思路,INNPL 以数据驱动的方法挖掘和更新典型样本,迭代地更新候选标签集和构建图,对样本进行分层传播,可使得信息传播更稳定。

(4) 本文基于五种不同特性的数据进行实验,实验对 INNPL 和七种偏标签学习算法进行全面地比较。在每种数据集上的分类指标评估和综合所有数据集进行评估的排名结果表明本文算法较其他算法具有更好的分类效果。

1 相关工作

偏标签学习假设真实标签隐藏在候选标签集中,它的主要任务是对候选标签进行消歧以获得实例样本的真实标签。已有的偏标签学习方法根据消歧方式的不同大概可以分为三类^[17]:基于候选标签平均的消歧方法,基于真实标签辨识的消歧方法,非消歧方法。

在第一类基于候选标签平均的消歧方法中,候选标签集中所有候选标签都是被平等对待的,输出标签预测结果可看作是对候选标签进行消歧处理。Cour 等^[11]将凸优化策略引入偏标签学习提出了 CLPL (Convex Loss for Partial Labels) 方法,基于凸损失函数构造二分类器来实现新样本的标签预测和分类。Zhang 等^[15]提出 PL-LEAF (Partial Label LEARNING via Feature Aware Disambiguation) 方法,将偏标签学习改进思路从标签信息转移到特征空间信息,通过挖掘特征空间的潜在信息完成偏标签学习模型构建。基于候选标签平均的消歧方法简单直观,模型易于建立,但是模型分类准确性可能极大地受到不准确标签的干扰。

第二类基于真实标签辨识的消歧方法将真实标签视为一个潜在的变量,通过迭代优化目标函数的方法辨识真实标签并完成消歧。基于真实标签辨识的消歧方法通常采用期望最大化程序来迭代重新确定由最大边准则^[14, 18-19]或最大似然准则^[9]所定义的目标函数。例如, Jin

等^[9]提出了最大似然法; Nguyen 等^[14]提出了基于最大边界技术的偏标记支持向量机 PL-SVM (Partial Label Support Vector Machine Classification) 方法; Yu 等^[18]提出了 M3PL (MaxiMum Margin Partial Label Learning) 方法; Chai 等^[19]开发的 LM-PLANE (LM Partial Label machiNE) 方法与 PL-SVM 的方法类似,但在边界定义上有所不同。虽然基于真实标签辨识的消歧方法相较于第一类方法减少了错误标签的干扰,但它仍面临一些挑战,其中之一是如何改进目标函数,以使消歧结果更加可靠,这成为了一个难点。

第三类偏标签学习方法是非消歧方法。该类方法将候选标签集消歧这一过程直接略去,通过将偏标签学习问题转化为其他监督学习问题完成模型构建。Zhang 等^[17]将 ECOC (Error Correcting Output Codes) 思想引入偏标签学习中,采用纠错输出码方法,通过编码和解码步骤将偏标签多类分类问题转化为二元分类问题,提出了 PL-ECOC (Partial Label Error Correcting Output Codes)。PALOC (PArtial Label Learning via One-vs-one deComposition)^[20]是通过一对一分解策略将偏标签学习问题转换为二元分类问题解决的方法。非消歧方法最大优势在于省略候选标签集消歧过程,避免错误标签在消歧过程中造成的噪声干扰。但预测模型难以建立,同时将偏标签学习转换为其他监督学习框架也是这类方法的难点。

标签传播算法 (Label Propagation Algorithm, LPA)^[21]将节点的标签信息借助图结构进行标签传播,信息由已知标签信息的节点向外传递,节点之间的相似度决定标签信息在图中的传递难易程度。该思路简单易实现且效果很好,通过图进行信息传播方式同样适用于解决标签信息不准确问题,因此通过改进图结构优化标签传播的思路开始被研究者引入偏标签学习框架中^[22-24]。PL-KNN (Partial Learning K-Nearest Neighbor Classification)^[16]是直接利用近邻样本标签预测新样本的输出标签的偏标签学习方法,是标签传播思想运用在偏标签学习领域的改进算法。IPAL (an Instance-based PArtial Label Learning)^[4]同样借助于标签传播思路进行算法改进。相比于 PL-KNN, IPAL 引入近邻

节点的最小误差重建思想对未见过的实例样本进行标签预测。但是上述两种算法仅基于样本间相似度吸收近邻样本的标签信息,忽视了部分可靠度高但并非近邻样本信息的重要性。在现实场景中,对典型样本引进额外的候选标签可能会增加模型的误导信息,而且信息传递过程也并没有充分利用到这类样本所携带的可靠信息。

此外,大部分偏标签算法是通过在原始标签基础上添加随机标签组成样本的候选标签集。但在实际中,当实例的类别难以被区分时,它对应的候选标签间的混淆程度可能很高。因此,我们认为,添加的候选标签应该依赖于实例特征与标签间关系决定,而非随机生成。事实上,已有少部分工作注意到了这一问题。例如,Xu等^[25]提出了VALEN(VARIational Label ENhancement for Instance-dependent Partial Label Learning)算法,改进候选标签集生成方式,并将标签分布转化为标签增强过程迭代训练模型,但该工作依然没有关注到典型样本的重要性。

2 基于实例的近邻传播偏标签学习算法

本文方法通过同时利用近邻典型样本和近邻样本建立特殊的 $K+N$ 近邻节点图,传播过

程中除了吸收近邻样本的标签信息,还强化了近邻典型样本的可靠信息传播的影响。该方法在分层迭代过程中逐层增加图中的样本数目,并对每次迭代新增样本的候选标签进行消歧。INNPL算法分为基于训练数据的模型训练阶段和新样本测试阶段两部分,下面分两小节分别对这两部分内容说明。

2.1 模型训练阶段

INNPL算法训练阶段流程如图1所示。首先,INNPL基于样本间相似度确定样本的度中心性。依据度中心性提取出训练样本的初始典型样本集、初始类别中心集,生成候选标签集。然后,INNPL迭代地完成训练样本的 $K+N$ 近邻节点图模型的构建和训练样本的标签推理过程,基本步骤说明如下:

(1)确定本层样本并提取其候选标签集。本层样本是本次迭代过程中所涉及的样本,包括标签已确定的样本和本层待传播样本。本文选择标签确定样本的近邻节点样本作为待传播样本。确定本层样本后,从候选标签集中提取出本层样本的候选标签。

(2)构建本层样本的 $K+N$ 近邻节点图。对原始全连接图进行稀疏化,得到 K 近邻样本图和 N 近邻典型样本图,将这两种图叠加构成

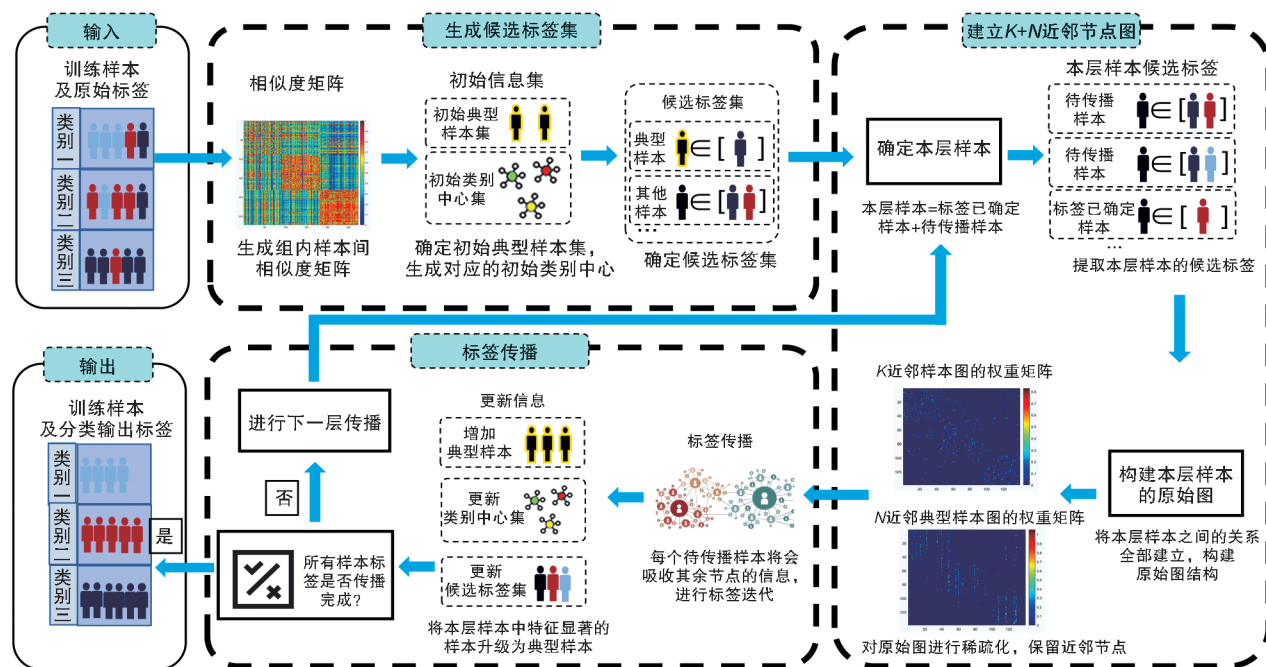


图1 INNPL算法训练阶段流程图

Fig. 1 Flowchart of INNPL algorithm training phase

$K + N$ 近邻节点图。

(3)对本层样本进行标签推理,对候选标签进行消歧,确定它们的分类输出标签,并更新典型样本集、类别中心集以及候选标签集。在此步骤中,我们根据当前的 $K + N$ 近邻节点图确定本层样本最终的标签。此外,根据已确定标签的样本,选择同一类别组内度中心性排序前15%的非典型样本作为新的典型样本,更新典型样本集,并将属于同一类的典型样本进行平均以更新类别中心集。依据更新后的类别标签集,更新候选标签集中未消歧样本的候选标签。

(4)判断全部训练样本是否迭代完成,若没有完成迭代,则继续进行(1)到(3)的迭代;若完成迭代则输出所有样本的最终分类输出标签,完成训练集分类模型的构建。下面对上述过程中关键步骤进行详细的阐述,内容将涵盖生成候选标签集,建立 $K + N$ 近邻节点图以及标签传播三部分内容。

2.1.1 生成候选标签集

INNPL通过衡量训练样本的度中心性^[26]区别化对待不同的样本,对不同的样本 x_i ($x_i \in X$)生成不同的候选标签,最终组成混淆程度更高且更加符合现实复杂数据的候选标签集 S_i ($S_i \in Y$)。每一类训练样本中度中心性较高的样本被选择为该类的典型样本。对典型样本的候选标签集,我们仅将典型样本的原始标签作为其分类输出标签。以类别 λ_q 为例,我们求解该类别内样本间相似度得到权重矩阵 $W = [w_{i,j}]_{n \times n}$ 。权重 $w_{i,j}$ 表示类别 λ_q 组内 x_i 样本与 x_j 样本之间的相似度,数值越大则两个样本间相似程度越高。在本文中,我们用公式(1)计算任意两个样本节点间的相似度, $d_{i,j}$ 表示 x_i 样本与 x_j 样本之间的距离:

$$\forall x_i \in \lambda_q, x_j \in \lambda_q: w_{i,j} = e^{-\frac{d_{i,j}^2}{2}}. \quad (1)$$

我们将样本与其他样本的相似度总和作为度中心性,根据度中心性对 λ_q 组内所有样本进行排序,选择前10%的样本作为典型样本,接着将类别 λ_q 组内所有典型样本的均值作为该类当前的类别中心。其他样本的候选标签集根据初始典型样本集和初始类别中心集生成。INNPL使用样本与各个类别中心的相似度代表

该样本属于某标签对应类别的可能程度。因此,对其他样本,我们先将所有标签成为它的分类输出标签的可能性进行排序,依次选择可能性高的多个类别标签作为它的候选标签生成候选标签集。所有训练样本的候选标签共同组成了初始候选标签集 S 。

2.1.2 建立 $K + N$ 近邻节点图

INNPL算法借鉴包装器法的思想迭代地构建 $K + N$ 近邻节点图模型。每一次迭代都需要确立本层样本,从候选标签集中提取本层样本对应的候选标签,构建本层样本的 $K + N$ 近邻节点图,进行标签推理,完成对候选标签集进行消歧的过程。

在迭代建立 $K + N$ 近邻节点图模型过程中,每一次迭代中样本都是上一层样本的近邻样本,第一次迭代样本选择典型样本的近邻样本。本层样本是本次迭代过程中所涉及的所有样本,是标签已确定的样本和本层待传播样本的集合。本层待传播样本是指本次迭代中准备进行候选标签集消歧的样本,本文选择标签确定的样本的近邻节点样本作为待传播样本。确定本层样本后,从候选标签集中提取出本层样本的候选标签集。

首先,我们需要生成本层样本的全连接图 $G = (V, E)$, V 表示所有训练样本构成的节点集合, E 是反映样本与样本间相似程度的权重边集合。图 G 是一个无向对称的稠密图,包含本层样本节点之间的连接信息。使用公式(1),生成两个节点之间连接对应边的权重为 $w_{i,j}$,权重矩阵 $W = [w_{i,j}]_{n \times n}$, n 表示本层样本数量。在获取到权重矩阵后行归一化处理,使得节点之间的连接权重可以处于同一比较水平,以免权重值较小的有效的信息被淹没。

随后INNPL方法对原始图 G 进行两种不同方式的稀疏化,分别得到 K 近邻样本图 G_K 和 N 近邻典型样本图 G_N ,再将两种图进行叠加产生最终的 $K + N$ 近邻节点图以用于后续的标签传播。

K 近邻样本图 G_K 是指原始图 G 保留每个节点与 K 个近邻节点之间的权重边,进行稀疏化所生成的无向非对称图。也就是说,在 G_K 中,当 x_j 是节点 x_i 的 K 近邻节点时,两节点间

的权重边被保留。设 K 近邻权重矩阵 $\mathbf{W}^K = [\omega_{i,j}^K]_{n \times n}$ 包含了每个节点与近邻节点的相似度关系。权重系数 $\omega_{i,j}^K$ 按照公式(2)由原权重矩阵 \mathbf{W} 稀疏化权重边得出。公式(2)中 $N(x_i)$ 表示节点 x_i 的 K 个最近邻节点的集合:

$$\forall 1 \leq i \leq n, 1 \leq j \leq n: \omega_{i,j}^K = \begin{cases} \omega_{i,j}, & \text{if } x_j \in N(x_i) \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

K 近邻权重矩阵 \mathbf{W}^K 内的数值为非0值和0值,其中非0值表示节点与其近邻节点的相似度,0值表示两节点没有近邻关系。由于相邻关系并不对称,因此 K 近邻权重矩阵并非对称矩阵。

N 近邻典型样本图 G_N 是指原始图 G 保留每个节点与 N 个典型样本节点之间的权重边,进行稀疏化生成的无向非对称图。本文按照公式(3)对原始图 G 进行稀疏化得到 N 近邻典型样本权重 \mathbf{W}^N 。即:在 G_N 中,当 x_j 属于节点 x_i 的 N 个近邻典型样本节点时,保留两个节点之间的权重边。设 N 近邻权重矩阵 $\mathbf{W}^N = [\omega_{i,j}^N]_{n \times n}$ 描述每个节点与近邻典型样本节点的相似度。 $\omega_{i,j}^N$ 由公式(3)得到,公式(3)中 $N^*(x_i)$ 表示节点 x_i 的 N 个最近的典型样本节点的集合。

$$\forall 1 \leq i \leq n, 1 \leq j \leq n: \omega_{i,j}^N = \begin{cases} \omega_{i,j}, & \text{if } x_j \in N^*(x_i) \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

N 近邻典型样本权重 \mathbf{W}^N 内的数值也是非0值和0值,非0值表示当前节点与邻近的典型样本节点的相似度关系,0表示两节点没有近邻关系。显然, G_N 也是一个不对称的加权图。

INNPL 在借助 $K + N$ 近邻节点图在进行标签传播时,样本既会吸收近邻节点的信息,又可以吸收信任程度很高的典型样本所携带的信息,可达到增强分类模型携带的更多有效信息的目的。

2.1.3 标签传播

在生成 $K + N$ 近邻节点图后,对本层样本进行标签推理。首先确定置信度矩阵 $F = [f_{i,c}]_{n \times q}$ 。 F 中的每个元素 $f_{i,c}$ 表示候选标签集中第 i 个样本的分类输出标签为类别 c 的置信度, n 表示本层样本数量, q 表示类别个数。 $F^{(t)}$

来表示第 t 次传播后样本的标签属于各分类输出标签的置信度。初始的标签置信度矩阵 $F^{(0)} = [f_{i,c}^{(0)}]_{n \times q}$,由公式(4)所示求解得到, y_c 表示 c 类别的标签。

$$\forall 1 \leq i \leq n: f_{i,c}^{(0)} = \begin{cases} \frac{1}{|S_i|}, & \text{if } y_c \in S_i \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

初始标签置信度矩阵中候选标签为均匀分布。 $\alpha \in (0, 1)$ 表示第 $t - 1$ 次迭代的结果对第 t 次迭代的影响权重, $(1 - \alpha)$ 反映初始的标签置信度矩阵对第 t 次迭代的影响权重。按照公式(5)所示,进行标签置信度迭代。

$$\tilde{F}^{(t)} = \alpha \cdot (\mathbf{W}^K + \mathbf{W}^N) F^{(t-1)} + (1 - \alpha) \cdot F^{(0)} \quad (5)$$

其中 t 表示第 t 次传播, $\tilde{F}^{(t)}$ 表示第 t 次传播得到的临时置信度矩阵, $\tilde{F}^{(t)} = [\tilde{f}_{i,c}^{(t)}]_{n \times q}$ 。 \mathbf{W}^K 表示 K 近邻样本权重矩阵, \mathbf{W}^N 表示 N 近邻典型样本权重矩阵。再将 $\tilde{F}^{(t)}$ 通过样本的候选标签集确定,经过公式(6)处理后,确保每个样本对应的置信度向量和仍为1。最终得到置信度矩阵 $F^{(t)}$,用于下一次迭代。 y_l 表示 l 类别的标签。

$$\forall 1 \leq i \leq n: f_{i,c}^{(t)} = \begin{cases} \frac{\tilde{f}_{i,c}^{(t)}}{\sum_{y_l \in S_i} \tilde{f}_{i,l}^{(t)}}, & \text{if } y_c \in S_i \\ 0, & \text{otherwise} \end{cases} \quad (6)$$

当标签传播稳定后,即迭代结束,得到最终标签置信矩阵 \hat{F} 。通过置信度矩阵和候选标签集,选择样本置信度矩阵中置信度最大的候选标签作为当前样本的本次迭代最终标签,完成对此候选标签集的消歧。如表1所示,我们将INNPL中主要符号再次进行说明,其余符号在文中进行介绍。

2.2 测试阶段

在测试阶段,INNPL 算法对测试集新样本进行标签预测。测试阶段分为生成候选标签集,更新 $K + N$ 近邻节点图和标签预测三个步骤。生成候选标签集过程中,我们计算测试样本与训练阶段最终的各个类别中心的相似度,选择相似度最高的多个类别中心对应的标签作为候选标签,生成候选标签集。然后将所有的新样本加入训练阶段已经完成的 $K + N$ 近邻节点图,并更新 $K + N$ 近邻节点图。这里,我们根据公式(1)使用高斯核函数求解样本间的相

表1 符号与定义

Table 1 Symbols and definitions

符号	定义	符号	定义
X	实例样本集	x_i	第 i 个实例样本
Y	标签集	y_c	c 类别的标签
D	训练集 $D = \{(x_i, S_i) 1 \leq i \leq m\}$	c	c 类别
S_i	实例样本 x_i 的候选标签集, $S_i \in Y$	q	类别个数
m	实例样本个数	n	本层样本数量
K	近邻节点个数	N	近邻典型样本节点个数
W	权重矩阵 $W = [w_{i,j}]_{n \times n}$	$w_{i,j}$	x_i 样本与 x_j 样本之间的相似度
W^K	K 近邻样本权重矩阵 $W^K = [w_{i,j}^K]_{n \times n}$	W^N	N 近邻典型样本权重矩阵 $W^N = [w_{i,j}^N]_{n \times n}$
$N(x_i)$	x_i 的 K 个近邻节点的集	$N^*(x_i)$	x_i 的 N 个近邻典型样本节点集
F	标签置信矩阵 $F = [f_{i,c}]_{n \times q}$	$f_{i,c}$	候选标签集中第 i 个样本的分类输出标签为类别 c 的置信度
$\tilde{F}^{(t)}$	第 t 次传播得到的临时置信度矩阵	\hat{F}	最终标签置信矩阵

似度。再将测试集新样本加入 $K + N$ 近邻节点图中,确定新样本的 K 个近邻节点和 N 个近邻典型样本节点,完成测试阶段 $K + N$ 近邻节点图的确定。最后根据公式(5)、公式(6)对新样本的候选标签置信度进行迭代,迭代结束后,选择置信度最高的标签作为新样本进行标签,完成标签预测。

3 实验及结果分析

在实验中,我们对INNPL和七种偏标签学习方法进行全面地比较。使用的五个数据集中,Seed、Waveform和Glass三个数据集来源于UCI(University of California Irvine,网址为<http://archive.ics.uci.edu/ml/index.php>),Lost^[1]和MSRCv2^[13]数据集来源于文献。本文实验采用十折交叉验证方式,将每个数据集划分训练集和测试集,即将数据集中90%数据(九折)作为训练集数据,基于训练集数据得到最终 $K + N$ 近邻节点图模型,将其余10%的数据(一折)作为测试集数据,对这部分样本进行标签预测,得到它们的类别标签。接着,对测试集样本进行分类结果评估,我们综合评估十折交叉验证试验的结果以确保结果的可靠性。性能评估包括准确度、精确度、召回率和 $F1$ 分数^[27]。本文对评估结果进行总结和综合评估,使用配对 t 检验对准确度进行性能比较,并结合所有数据集的结果使用综合排名方式^[28]对算法进行性能排序。

3.1 实验数据集

为了评估INNPL算法的有效性,实验使用五个数据集进行性能测试。表2总结所使用的数据集的样本量、特征个数类别数等信息。Seed数据集记录了不同种类小麦种子的数据,该数据集的标签共有三类,特征表示不同品种的小麦种子的几何特性的数值。Waveform数据集是记录不同的波形特征的数据集,类别较少(3类),但实例样本数多(5 000个)。Glass数据集是氢化物含量不同的六种玻璃数据集,该数据集共有214个实例样本,样本特征为各类化学元素含量。在其余数据集中,Lost数据集^[1]是同名电视剧中人脸图像数据集,从视频帧中裁剪的人脸图像表示实例,人物名称代表类别,特征维度较高。MSRCv2数据集^[13]同样是图像数据,共有48个特征维度,类别数较多(23类)。

表2 实验数据集的特点

Table 2 Characteristics of the experimental data sets

数据集	样本数/个	特征数/个	类别数/类
Seed	210	7	3
Waveform	5 000	21	3
Glass	214	9	6
Lost	1 122	108	14
MSRCv2	1 758	48	23

3.2 实验过程

本文,我们使用十折交叉验证方式进行实验,确保结果的可靠性。其次,本文对不同的算法采用同样的数据划分和候选标签集生成方

式,保证多种偏标签算法对比的公平性。值得指出的是,本文在生成候选标签集时通过求解实例样本与初始类别中心的相似度,选择相似度更高的候选标签进入候选标签集。这样生成的候选标签集混淆度更高,更加接近现实情况。此外,我们与七种成熟的偏标签学习方法进行比较,这些方法涵盖了基于候选标签平均的消歧方法,基于真实标签辨识的消歧方法和非消歧方法这三大类目前最主要的偏标签方法。每个算法都配置各自文献中建议的参数,确保对比算法的有效性。

INNPL分类模型中 K 和 N 参数基于数据本身进行确定,而非人为设定。在实验中,我们通过在一定范围下遍历不同的 K 与 N 值评估训练集数据上的分类结果,进行 K 与 N 值的选择。本文为了满足所有数据集的条件,我们对 K 值和 N 值的范围进行统一设定为 $K \in (1, 30)$, $N \in (1, 8)$ 。我们用分类准确度和区域内分类准确度来评估分类效果,也就是说,如果使用某 (K, N) 的邻域参数下得到的分类效果都能达到较好的水平,我们会优先考虑这一 (K, N) 参数组。某 (K, N) 参数组的区域内分类准确度定义为 $(K-1, N)$ 、 $(K-1, N+1)$ 、 $(K-1, N-1)$ 、 $(K+1, N)$ 、 $(K+1, N+1)$ 、 $(K+1, N-1)$ 、 (K, N) 、 $(K, N+1)$ 以及 $(K, N-1)$ 这些参数下的分类准确度的平均值。若 K 为边界值, N 不为边界值,则选择 $(K+1, N)$ 、 $(K+1, N+1)$ 、 $(K+1, N-1)$ 、 (K, N) 、 $(K, N+1)$ 和 $(K, N-1)$ 的准确度平均值表示区域准确度。若 N 为边界值, K 不为边界值,方法类似。若 K 和 N 均为边界值,则选择附近三个参数的准确度及本身的准确度的平均值作为区域准确度。当得到排序位于前五的区域内分类准确度对应的五个参数组 (K, N) 后,再对这五个参数对应的自身分类准确度比较,选择自身准确度最高的分类模型对应的 K 与 N 参数作为最终模型训练的 K 和 N 参数,如果出现准确度相同的情况,则选择 K 值较小的参数组。

由于INNPL属于基于候选标签平均的消歧方法,所以本文选择了PL-KNN、IPAL、CLPL和PL-LEAF四种基于候选标签平均的消歧方法进行对比。PL-KNN是一种采用平均策略的

偏标签学习方法,在该算法中近邻数量 k 被设定为10。IPAL是一种基于实例的方法,通过迭代的标签传播过程来确定每个训练实例样本的有效标签,然后根据近邻节点的最小误差重建对未见过的实例进行分类。运行时,代码参数设置为近邻数量 $k=10$,平衡系数 $\alpha=0.95$,迭代次数 $T=100$ 。CLPL采用平均化策略,对偏标签学习采取参数化方法,其中参数化模型被设定为具有平方铰链损失的SVM。PL-LEAF是一种通过操纵特征空间中的有用信息来消除候选标签集的歧义的方法。具体来说,PL-LEAF基于训练实例之间的流形关系生成归一化的标注置信度向量,然后基于多输出回归分析得出预测模型。代码参数设置为近邻数量 $k=10$,回归损失函数的正则化参数 $C_1=10$ 和 $C_2=1$ 。

除上述四种算法外,本文也进行了基于真实标签辨识的消歧方法M3PL、LSBCMM(the Logistic Stick-Breaking Conditional Multinomial Model)和非消歧方法PALOC三种算法的实现。M3PL是一种通过最大化真实标签与其余所有标签边距进行候选标签集消歧的偏标签算法。具体来说,利用一个优化流程对真实标签的识别并控制边界最大化。M3PL算法的正则化参数最大值 C_{\max} 设置为0.01。LSBCMM^[11]同样是一种基于EM的消歧策略采用最大似然法对部分标签进行学习的偏标签方法,其中混合成分的数量被设定为每个数据集的类标签的数量。PALOC是一种通过一对一分解策略,将多类分类问题转换为二元分类问题解决的偏标签学习算法,该算法的平衡参数设置为 $\mu=10$ 。

对每一种方法,我们采用十折交叉验证的方式来重复实验,在每一次的实验中,九折的数据作为训练集,剩余一折的数据作为测试集。基于准确度、精确度、召回率和F1分数四种不同分类性能对由训练集上得到模型在测试集上得到的分类结果进行评估。准确度是指分类输出标签与原始标签相同的测试样本数占总测试样本数的比例。因为偏标签算法为多分类算法,因此对于精确度和召回率两个指标的计算是得到每一个类别的精确度和召回率,再将所有类别的结果平均得到最终的分分类精确度和召

回率。每一类别的精确度是指所有预测为此类别的测试样本中原始标签为此类别的测试样本所占比例。每一类别的召回率是指所有原始标签为此类别的测试样本中预测为此类别的测试样本所占的比例。 $F1$ 分数是基于精确度和召回率的调和平均。关于每种评估指标,十折交叉验证会得到十个评估结果,本文使用误差棒柱状图对这些结果进行展示。此外本文使用排名图对算法排名结果进行展示,我们平等对待每一折数据的不同性能评估排名结果,进行平均化排名,得到当前数据集不同算法的排名结果。

3.3 实验结果

在本文实验中,我们以误差棒柱状图对十折实验的性能结果进行展示,总结了INNPL、PL-KNN、IPAL、CLPL、PL-LEAF、M3PL、LSBCMM和PALOC在准确性、精确性、召回率和 $F1$ 分数四个性能的表现。多次试验结果证明,我们算法与其他方法相比普遍具有更好的分类效

果。尽管在Waveform数据集上的表现并非最优,但在其他数据集的排名结果中,INNPL都超过PL-KNN和IPAL这两种标签传播的偏标签学习算法。另外,与其他算法相比,INNPL算法有性能的提升,并产生更准确的分类结果。对不同数据集的四种性能进行排名评估,可以清晰地看到INNPL算法在不同数据集都具有良好的排名结果,在五个数据集上三个处于第一名,尤其在基于所有数据集进行综合排名时,INNPL依旧处于第一名。上述实验结果体现了INNPL算法的有效性。

图2(a)、(b)和(c)展示了三种UCI数据集上各类算法的准确度评估结果。虽然本文提出的INNPL不能保证每一折数据的准确率保持在最高水平,但INNPL算法在十折评估结果中准确度都处于较高水平。如图2(d)和图2(e)显示,在两个真实数据集测试的每一类算法的准确度评估结果。图中显示,INNPL算法在MSRCv2数据集的表现更好,准确度更高。然

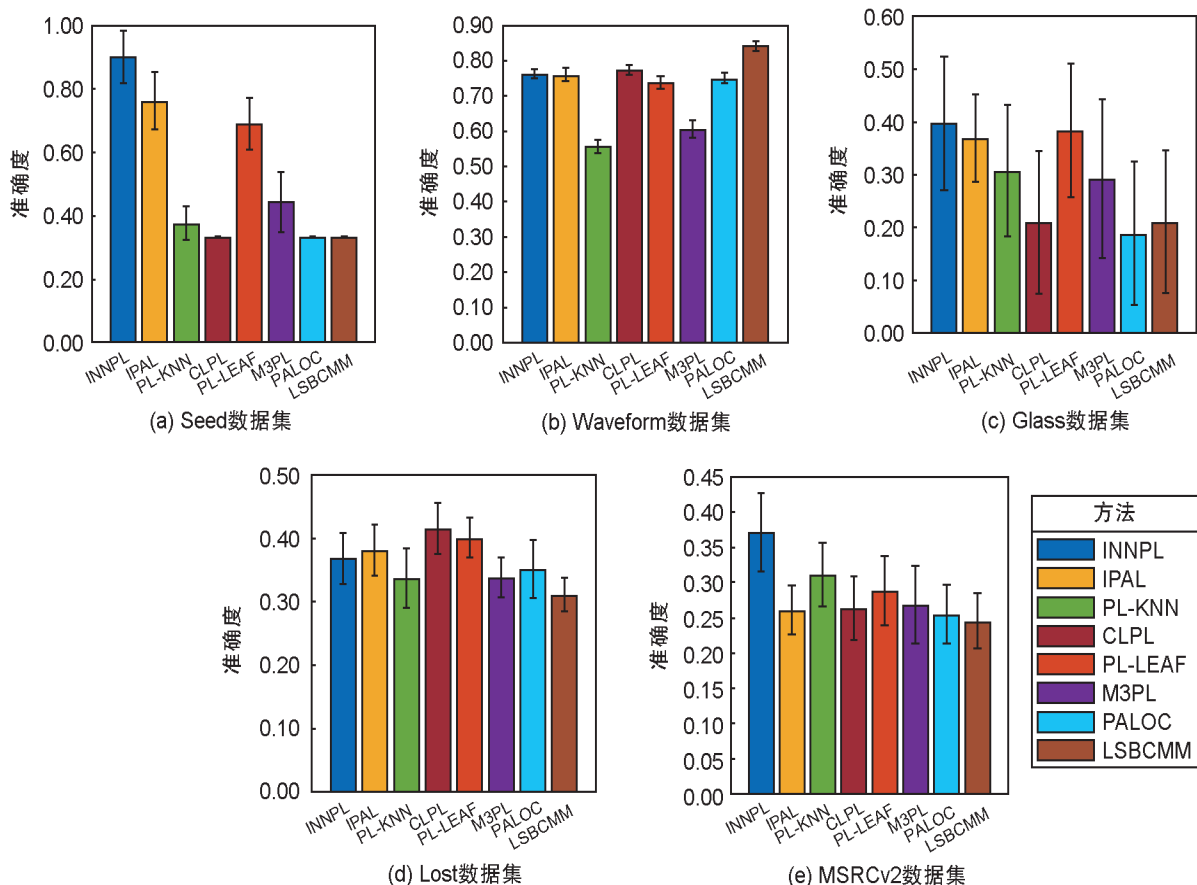


图2 不同数据集上八种算法准确度评估结果

Fig. 2 Accuracy evaluation results of eight algorithms on different datasets

而,在 Lost 数据集上的表现一般,但准确度指标仍然优于 PL-KNN、M3PL、PALOC、LSBCMM 这四类算法,与其他三类算法相差并不多。

图 3 显示五种数据集的各类算法的精确度评估结果,结果表明在精确度性能评估中,INNPL 算法仍然具有良好的评估结果。如图 3(a)和 3(e)显示,Seed 数据集和 MSRCv2 数据集的精确度大幅优于其他算法。如图 3(c)和 3(d)显示,在 Glass 数据集和 Lost 数据集,INNPL 算法的精确度评估结果较好。如图 3(b)显示,在 Waveform 数据集上,INNPL 算法与大部分算法精确度评估结果类似。尽管 INNPL 并不在每一个数据集都有最优的表现,但 INNPL 算法的精确度在该性能评价指标的不同算法中仍处于较高数值。

图 4 显示五种数据集的各类算法的召回率评估结果。图 5 显示 F1 分数评估结果。INNPL 在以上两个指标的性能评估结果中同样优于其他七种偏标签算法。如图 4(a)和 4(e)、图 5(a)和 5(e)显示,在 Seed 数据集和 MSRCv2 数据集上召回率和 F1 分数性能评估结果大幅

优于其他算法。如图 4(c)显示 Glass 数据集上,INNPL 算法的召回率的结果略优于其他算法,图 5(c)中 F1 分数同样略优于其他算法。图 4(b)和 4(d)、图 5(b)和 5(d)显示:在 Waveform 和 Lost 数据集上,INNPL 算法与其他对比算法的召回率和 F1 分数接近。

我们综合各算法的不同性能评价结果,在图 6 中进行排名结果展示。我们将所有算法的整体性能进行排名。在每一个数据集中,平均对待每一折数据下不同算法的四种性能结果。对同一种算法的不同折数据的不同性能评估排名结果进行平均化,得到当前数据集综合排名结果,如图 6 中(a)、(b)、(c)、(d)、(e)五个子图所示。从上述子图中可以看出,在不同的数据集中,本文提出的 INNPL 算法的综合排名都很高,证实 INNPL 与 PL-KNN、IPAL 两种标签传播偏标签学习方法和其他偏标签方法相比,具有更大的优势。同时,本文将算法在所有的数据集上的排名进行平均处理得到最终的算法比较排名图,如图 6(f)所示。本文提出的算法

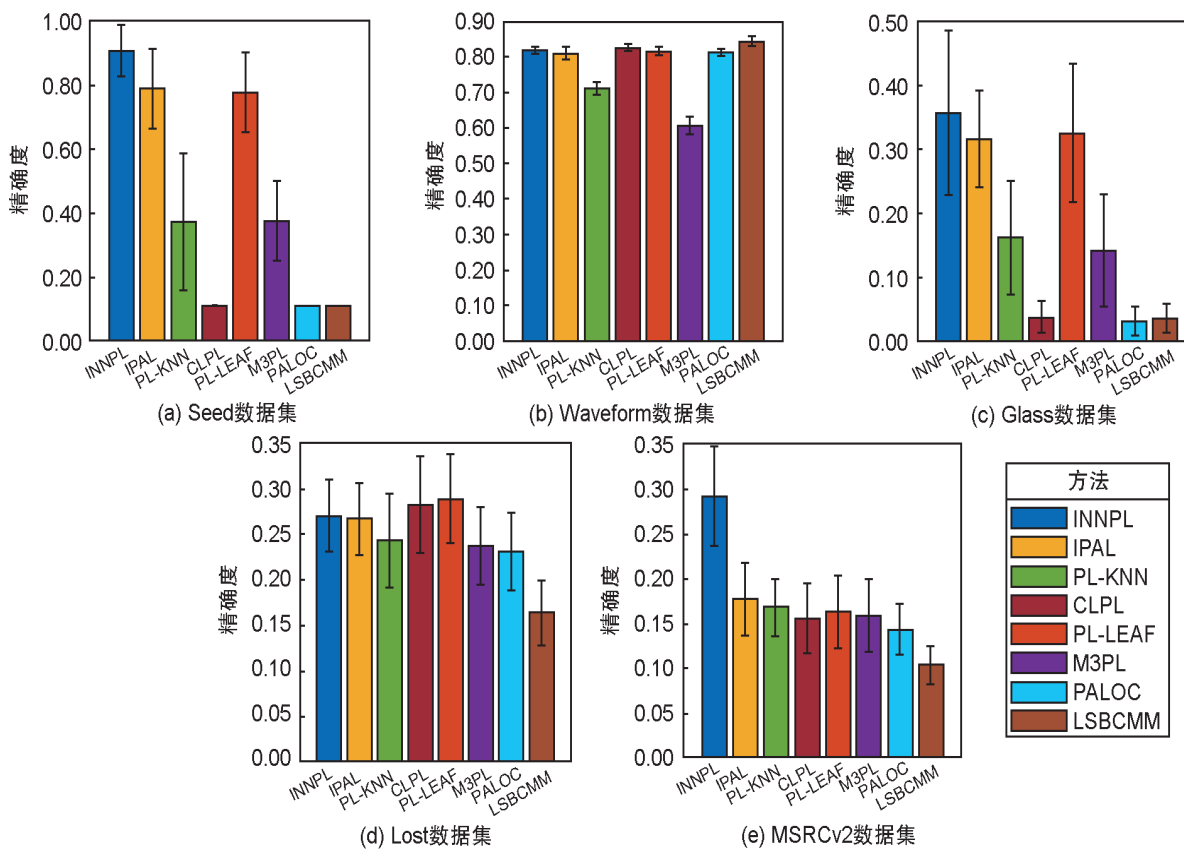


图 3 不同数据集上八种算法精确度评估结果

Fig. 3 Precision evaluation results of eight algorithms for different datasets

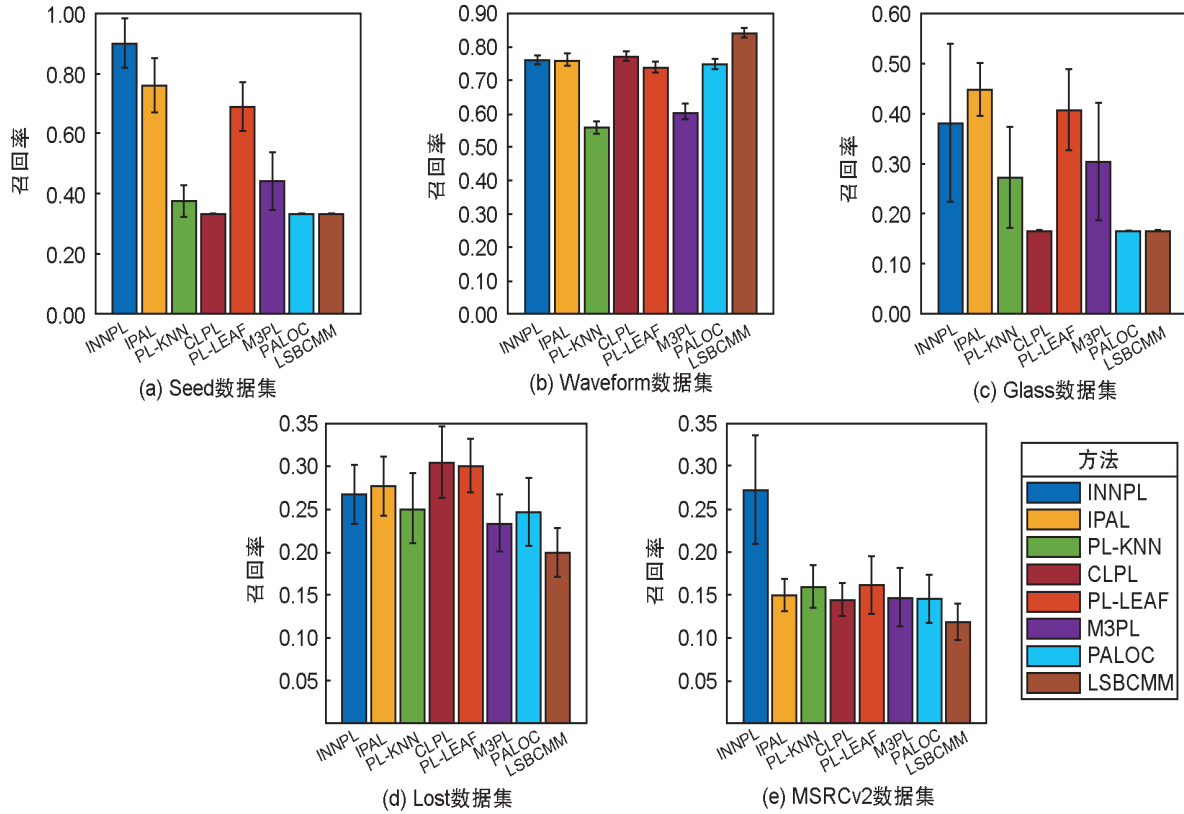


图4 不同数据集上八种算法召回率评估结果

Fig. 4 Recall evaluation results of eight algorithms on different datasets

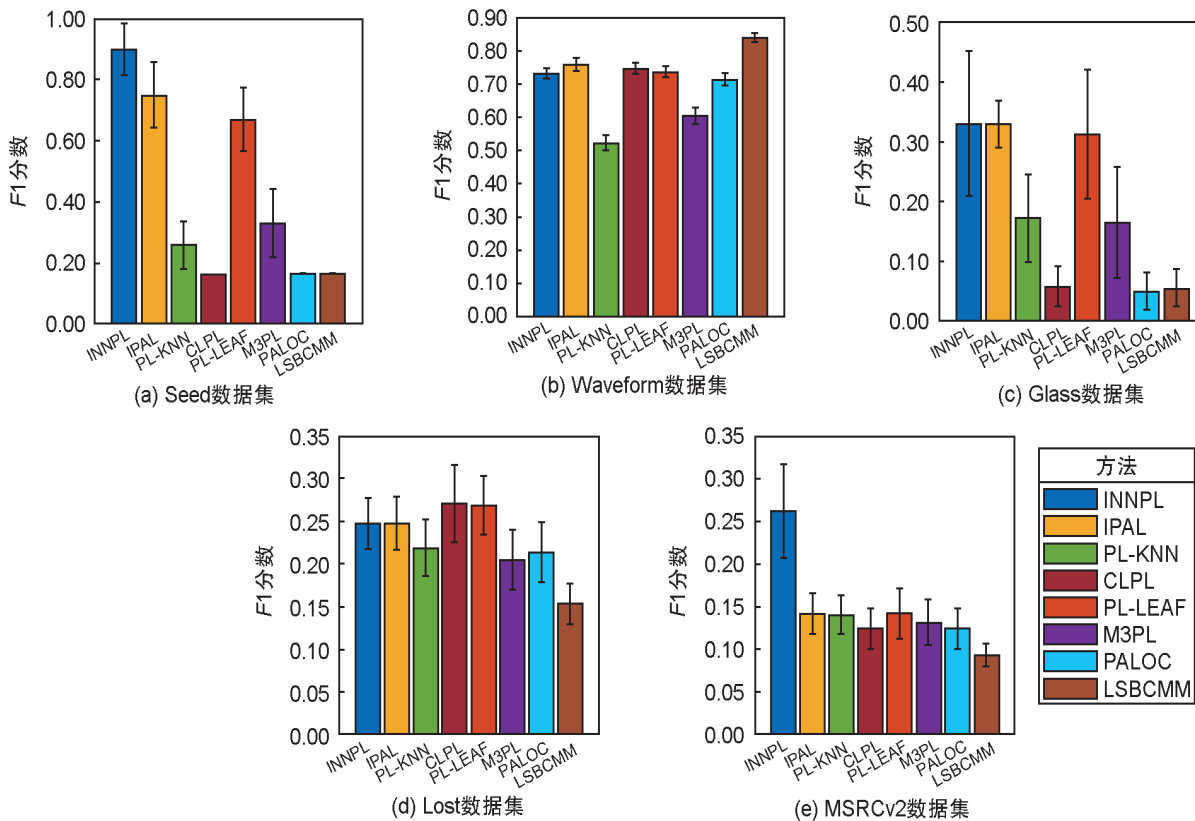


图5 不同数据集上八种算法F1分数评估结果

Fig. 5 F1 scores evaluation results of eight algorithms on different datasets

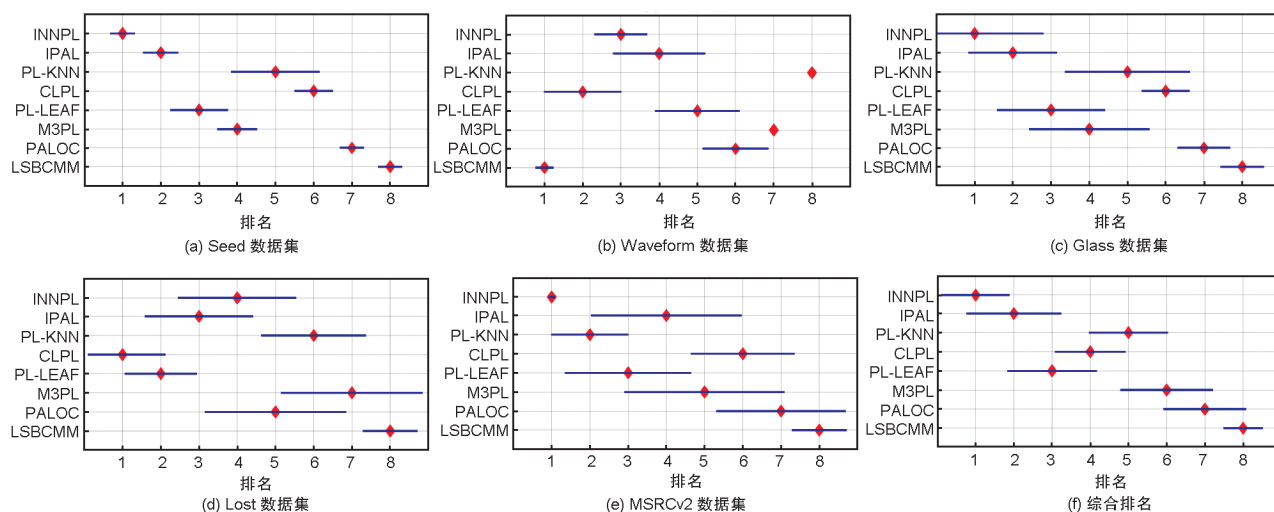


图6 不同数据集上八种算法排名和综合排名结果

Fig. 6 Ranking results of eight methods on each dataset and overall ranking result measured using all datasets

与现有的偏标签学习方法相比,总排名处于第一的位置,说明INNPL具有较大的优势。

如图6所示,INNPL的性能在大多数情况下与其他比较算法相比具有很强的竞争力。准确度性能结果是偏标签算法性能的主要评估指标,因此我们根据十折交叉验证的准确度结果对INNPL算法和其他算法进行了配对 t 检验,显著性水平由 $p=0.05$ 决定。表3总结了INNPL与其他算法的准确度比较结果。五个数据集的统计比较结果验证了INNPL算法的性能竞争力。

表3 INNPL与其他算法的准确度比较结果。针对每个数据集,我们对INNPL和某种对比算法(比如IPAL)在十折交叉验证中得到的准确度进行配对 t 检验,●/○表示INNPL在统计上显著优于/劣于比较算法(显著性水平由 $p=0.05$ 决定)

表3 INNPL与其他算法的准确度比较结果。针对每个数据集,我们对INNPL和某种对比算法(比如IPAL)在十折交叉验证中得到的准确度进行配对 t 检验,●/○表示INNPL在统计上显著优于/劣于比较算法(显著性水平由 $p=0.05$ 决定)

Table 3 Results of accuracy comparison of INNPL with other algorithms. For each dataset, we performed a paired t -test between the accuracy obtained from INNPL and that from one comparison algorithm (e.g. IPAL) in ten cross-validations, and ●/○ indicates that INNPL is statistically significantly better/worse than the comparison algorithm (with the significance level determined by $p=0.05$)

数据集	IPAL	PL-KNN	CLPL	PL-LEAF	M3PL	PALOC	LSBCMM
Seed	1.99×10^{-3} ●	2.86×10^{-7} ●	4.30×10^{-9} ●	6.93×10^{-4} ●	2.54×10^{-6} ●	4.30×10^{-9} ●	4.30×10^{-9} ●
Waveform	7.13×10^{-1}	7.19×10^{-10} ●	2.58×10^{-3} ○	4.61×10^{-3} ●	2.28×10^{-10} ●	8.67×10^{-4} ●	2.43×10^{-8} ○
Glass	6.57×10^{-1}	1.31×10^{-1}	1.61×10^{-2} ●	8.40×10^{-1}	1.84×10^{-1}	1.34×10^{-2} ●	1.61×10^{-2} ●
Lost	2.34×10^{-1}	2.03×10^{-3} ●	4.27×10^{-3} ○	1.30×10^{-3} ○	6.23×10^{-2}	2.34×10^{-1}	4.42×10^{-3} ●
MSRCv2	9.43×10^{-5} ●	1.75×10^{-4} ●	1.07×10^{-5} ●	7.27×10^{-5} ●	3.07×10^{-4} ●	5.54×10^{-6} ●	5.08×10^{-6} ●

4 结束语

本文针对偏标签学习中的问题,提出一种新的基于实例的近邻传播偏标签学习算法INNPL。INNPL挑选训练样本中可信度更高的样本将之作为典型样本,并建立特殊的 $K+N$ 近邻节点图。在标签传播过程中,INNPL强调了可靠度高的标签信息传播的重要性,增强分类模型携带的有效信息。INNPL算法通过生成 $K+N$ 近邻节点图并改进标签传播方式提升了训练模型准确度,提供了一种偏标签学习的新思路。其次,INNPL算法改进了候选标签集的生成方式,增加候选标签集中不同候选标签的混淆程度,使得数据集更符合真实世界获取的数据的情况。

在验证INNPL性能的实验中,本文在五个数据集上和其他七种偏标签算法进行对比测试。比较的偏标签算法包括了基于候选标签平

均的消歧方法、基于真实标签辨识的消歧方法和非消歧方法三类不同思路的偏标签学习算法,且对比算法都配置各自文献中建议的最佳参数,保证对比结果的可靠性。同时我们进行四个分类指标(准确度、精确度、召回率和F1分数)的性能评估,并在实验过程中采用十折交叉验证的方式对实验数据进行多次测试。实验结果表明INNPL相比于其他偏标签学习算法有着不错的表现。关于准确度指标,INNPL算法在五个数据集上三次达到最优,另外两次也达到中等偏上的水平。结合不同数据集的综合评估结果,INNPL性能评估综合排名第一。总之,实验表明INNPL与现有的偏标签学习方法相比普遍具有更好的分类效果。

当前,INNPL算法在模型参数设定上仍存在一定不足之处,无法完全基于数据自行设定参数,还需要预先设定参数范围。在后续工作中,我们会继续探寻该算法如何应对不同数据集,如何更好地自动确定算法参数。在模型改进方面,未来的工作是继续探寻候选标签集消歧的其他方法,更好地消除候选标签集中的不准确标签带来的干扰。在算法应用方面,该算法未来可运用在多个现实领域,探索算法的实际应用效果。以精神疾病领域为例,当前的精神疾病的诊断主要基于患者对其主观经历的描述和临床医生或知情人对患者行为的观察,而多种精神疾病病症重叠,病况复杂,因此想要获得大量的可靠的精神疾病标签信息是十分困难的事情。此外,由于当前精神疾病医疗诊断方式不够完善,得到的少量昂贵的标签信息可靠程度依旧值得商榷。因此,将INNPL算法应用于精神疾病领域,借助少量特征明显且标签可靠的典型样本和特征不够明显但具有候选标签集的样本可有助于探寻精神疾病影像标志。

参考文献:

- [1] COUR T, SAPP B, TASKAR B. Learning from Partial Labels[J]. *J Mach Learn Res*, 2011, **12**: 1501-1536.
- [2] ZHOU Z H. A Brief Introduction to Weakly Supervised Learning[J]. *Natl Sci Rev*, 2018, **5**(1): 44-53. DOI: 10.1093/nsr/nwx106.
- [3] 张敏灵. 偏标记学习研究综述[J]. *数据采集与处理*, 2015, **30**(1):77-87. DOI: 10.16337/j.1004-9037.2015.01.007.
- [4] ZHANG M, YU F. Solving the Partial Label Learning Problem: An Instance-Based Approach[C]//Proceedings of the 24th International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2015.
- [5] TIAN Y J, YU X T, FU S J. Partial Label Learning: Taxonomy, Analysis and Outlook[J]. *Neural Networks*, 2023 **161**: 708-734. DOI: 10.1016/j.neunet.2023.02.019.
- [6] WANG W, ZHANG M L. Partial Label Learning with Discrimination Augmentation[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: Association for Computing Machinery, 2022.
- [7] WANG H, XIAO R, LI Y, *et al.* PiCO: Contrastive Label Disambiguation for Partial Label Learning[EB/OL]. (2022-11-30)[2022-12-30]. <https://arXiv.org/abs/2201.08984>.
- [8] SCHRETLEN D J, CASCELLA N G, MEYER S M, *et al.* Neuropsychological Functioning in Bipolar Disorder and Schizophrenia[J]. *Biol Psychiatry*, 2007, **62**(2): 179-186. DOI: 10.1016/j.biopsych.2006.09.025.
- [9] JIN R, GHAHRAMANI Z. Learning with Multiple Labels[C]//Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2003.
- [10] LUO J, ORABONA F. Learning from Candidate Labeling Sets[M]. Cambridge: MIT Press, 2010.
- [11] COUR T, SAPP B, JORDAN C, *et al.* Learning from Ambiguously Labeled Images[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. 2009: 919-926. Miami: IEEE. DOI: 10.1109/CVPR.2009.5206667.
- [12] ZENG Z N, XIAO S J, JIA K, *et al.* Learning by Associating Ambiguously Labeled Images[C]//2013 IEEE Conference on Computer Vision and Pattern Recognition. 2013: 708-715. Portland: IEEE. DOI: 10.1109/CVPR.2013.97.
- [13] LIU L P, DIETTERICH T G. A Conditional Multinomial Mixture Model for Superset Label Learning[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems-Volume 1. New York: ACM, 2012: 548-556. DOI: 10.5555/2999134.2999196.
- [14] NGUYEN N, CARUANA R. Classification with Partial Labels[C]//ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: Association for Computing Machinery, 2008.
- [15] ZHANG M L, ZHOU B B, LIU X Y. Partial Label Learning via Feature-aware Disambiguation[C]//Pro-

- ceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 1335–1344. DOI: 10.1145/2939672.2939788.
- [16] HÜLLERMEIER E, BERINGER J. Learning from Ambiguously Labeled Examples[J]. *Intell Data Anal*, 2006, **10**(5): 419–439.
- [17] ZHANG M L, WU X. Disambiguation-free Partial Label Learning[J]. *Sci Sin Inf*, 2019, **49**(9): 1083–1096. DOI: 10.1360/n112018-00150.
- [18] YU F, ZHANG M L. Maximum Margin Partial Label Learning[J]. *Mach Learn*, 2017, **106**(4): 573–593. DOI: 10.1007/s10994-016-5606-4.
- [19] CHAI J, TSANG I W, CHEN W J. Large Margin Partial Label Machine[J]. *IEEE Trans Neural Netw Learn Syst*, 2020, **31**(7): 2594–2608. DOI: 10.1109/TNNLS.2019.2933530.
- [20] WU X, ZHANG M L. Towards Enabling Binary Decomposition for Partial Label Learning[C]//Proceedings of the 24th International Joint Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2018.
- [21] RAGHAVAN U N, ALBERT R, KUMARA S. Near Linear Time Algorithm to Detect Community Structures in Large-scale Networks[J]. *Phys Rev E Stat Nonlin Soft Matter Phys*, 2007, **76**(3): 036106. DOI: 10.1103/PhysRevE.76.036106.
- [22] 陈鸿昶, 谢天, 高超, 等. 候选标记信息感知的偏标记学习算法[J]. 电子与信息学报, 2019, 41(10)2516–2524. DOI: 10.11999/JEIT181059.
- CHEN H C, XIE T, GAO C, *et al.* Candidate Label-aware Partial Label Learning Algorithm[J]. *J Electron Inf Technol*, 2019, 41(10)2516–2524. DOI: 10.11999/JEIT181059.
- [23] SUN K W, MIN Z J, WANG J. PP-PLL: Probability Propagation for Partial Label Learning[C]//Proceedings of the ECML/PKDD. Cham: Springer Cham, 2020.
- [24] 征察, 吉立新, 高超, 等. 基于成对约束的偏标记数据消歧算法[J]. 自动化学报, 2020, 46(7)1367–1377. DOI: 10.16383/j.aas.c170522.
- ZHENG C, JI L X, GAO C, *et al.* Partial Label Data Disambiguation Algorithm Based on Pairwise Constraints [J]. *Acta Autom Sin*, 2020, 46(7)1367–1377. DOI: 10.16383/j.aas.c170522.
- [25] XU N, QIAO C, GENG X, *et al.* Instance-dependent Partial Label Learning[EB/OL]. (2021–10–26) [2023–01–10]. <https://doi.org/10.48550/arXiv.2110.12911>.
- [26] FREEMAN L C. Centrality in Social Networks Conceptual Clarification[J]. *Soc Netw*, 1978, **1**(3): 215–239. DOI: 10.1016/0378-8733(78)90021-7.
- [27] POWERS D M W. Evaluation: From Precision, Recall and F-measure to ROC, Informedness, Markedness and Correlation[EB/OL]. (2020–10–11) [2023–01–10]. <https://doi.org/10.488550/arXiv.2010.16061>.
- [28] LI F, QIAN Y, WANG J, *et al.* Clustering Ensemble Based on Sample's Stability[J]. *Artif Intell*, 2019, **273**: 37–55. DOI: 10.1016/j.artint.2018.12.007.