

非消歧偏标记学习

张敏灵^{1,2*}, 吴璇^{1,2}

1. 东南大学计算机科学与工程学院, 南京 210096
2. 计算机网络和信息集成教育部重点实验室(东南大学), 南京 210096

* 通信作者. E-mail: zhangml@seu.edu.cn

收稿日期: 2018-06-10; 修回日期: 2019-01-21; 接受日期: 2019-04-29; 网络出版日期: 2019-08-29

国家重点研发计划(批准号: 2018YFB1004300)和国家自然科学基金(批准号: 61573104)资助项目

摘要 偏标记学习是一类重要的弱监督机器学习框架. 在该框架下, 每个对象在输入空间由单个示例进行刻画, 在输出空间与一组候选标记相对应, 其中仅有一个标记为其真实标记. 利用有歧义性的样本进行建模, 直观的策略是对候选标记集合进行消歧, 然而该策略会受到伪标记的影响, 因此有必要考虑从非消歧的角度解决偏标记学习问题. 本文将围绕基于消歧、非消歧策略的偏标记学习算法对该领域进行综述. 首先, 给出偏标记学习的定义以及其与其他相关学习框架的关系. 然后对现有几种代表性基于消歧策略的偏标记学习算法进行介绍. 接下来重点介绍我们提出的两种基于非消歧策略的偏标记学习算法. 最后对本文进行总结并简要讨论进一步的研究方向.

关键词 机器学习, 弱监督学习, 偏标记学习, 候选标记, 非消歧策略

1 引言

传统监督学习是机器学习中被研究得最广泛的一种学习框架^[1]. 假设 $\mathcal{X} = \mathbb{R}^d$ 为 d 维示例空间, $\mathcal{Y} = \{y_1, y_2, \dots, y_q\}$ 为包含 q 个类别的标记空间, 传统监督学习的任务是基于训练集 $\mathcal{D} = \{(\mathbf{x}_i, y_i) \mid 1 \leq i \leq m\}$ 学得函数 $f: \mathcal{X} \rightarrow \mathcal{Y}$. 其中, $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{id}]^\top \in \mathcal{X}$ 为 d 维属性向量(示例), $y_i \in \mathcal{Y}$ 为该示例对应的类别标记.

在该框架下, 每个示例由明确、单一的标记进行刻画. 该类别标记作为“监督信息(supervision information)”蕴含了学习问题的语义和规律, 是学习到强泛化性能模型的重要因素. 传统的监督学习框架在学习建模时, 采用的是“强监督(strong supervision)”假设, 即在训练时可以获得大量的有标记样本, 每个样本的标记信息均是明确、单一的. 然而, 真实世界的场景往往更加复杂, 由于标记成本过高、真实标记难以获得等原因, 无法获得大量具有明确标记的样本, 而只能利用十分有限的监督信息, 即弱监督(weakly-supervised)信息. 如何在弱监督信息条件下有效地进行学习, 已成为机器学习领域的热点研究问题^[2].

引用格式: 张敏灵, 吴璇. 非消歧偏标记学习. 中国科学: 信息科学, 2019, 49: 1083–1096, doi: 10.1360/N112018-00150
Zhang M L, Wu X. Disambiguation-free partial label learning (in Chinese). Sci Sin Inform, 2019, 49: 1083–1096, doi: 10.1360/N112018-00150

偏标记学习 (partial label learning) 是一类重要的弱监督学习框架 [3,4]. 在该框架下, 每个示例的标记不再具有单一性和明确性, 而是对应了一个“候选标记集合 (candidate label set)”, 其唯一的真实标记隐藏在候选标记集合中, 但在训练阶段无法被学习系统获得并加以利用. 在利用此类具有歧义性的样本进行学习建模时, 一个直观的策略是对候选标记集合进行“消歧 (disambiguation)”, 然而由于真实标记隐含在候选标记集合中, 基于消歧的技术会受到“伪标记 (false positive label)”的影响, 因此有必要考虑从“非消歧 (disambiguation-free)”的角度解决偏标记学习问题.

本文将围绕基于消歧、非消歧策略的偏标记学习算法对该领域进行综述. 接下来首先给出偏标记学习的定义以及与其他相关学习框架的关系 (第 2 节). 然后对现有几种代表性基于消歧策略的偏标记学习算法进行介绍 (第 3 节). 接下来重点介绍我们提出的两种基于非消歧策略的偏标记学习算法 (第 4 节). 最后对本文进行总结并简要讨论进一步的研究方向 (第 5 节).

2 偏标记学习

在现实生活中, 存在如下场景. 对网页新闻中的人脸进行命名时, 为减少标注代价, 可以分别从新闻中提取出名字和从图片中识别出人脸, 但却无法得知名字与人脸的对应关系. 需对某对象进行标注时, 为降低标注成本, 可允许用户进行在线标注, 但由于用户的不专业性、理解角度等因素, 一个在线对象往往会获得多个标注, 但其中只有一个正确的.

在上述场景中, 每个对象由一组候选标记进行刻画, 其真实标记无法在训练时被学习系统获得并加以利用, 无法使用传统监督学习的方法进行学习. 为了对上述场景进行有效地建模, 偏标记学习 [3,5] 应运而生. 其框架定义如下.

定义1 (偏标记学习) 假设 $\mathcal{X} = \mathbb{R}^d$ 为 d 维示例空间, $\mathcal{Y} = \{y_1, y_2, \dots, y_q\}$ 为包含 q 个类别的标记空间, 给定偏标记学习训练集 $\mathcal{D} = \{(\mathbf{x}_i, S_i) \mid 1 \leq i \leq m\}$, 其中 $\mathbf{x}_i \in \mathcal{X}$ 为 d 维属性向量 $[x_{i1}, x_{i2}, \dots, x_{id}]^T$, $S_i \subseteq \mathcal{Y}$ 为候选标记集合, 样本 \mathbf{x}_i 的真实标记 y_i 未知, 但满足 $y_i \in S_i$. 偏标记学习的任务是基于训练集 \mathcal{D} , 学习得到多类分类器 $f: \mathcal{X} \rightarrow \mathcal{Y}$.

由于偏标记学习在训练时无需已知样本的真实标记, 对监督信息要求较低, 因此可以以较小的成本获得大量的标记, 显著降低标注代价. 目前, 在解决实际问题方面, 偏标记学习已经展现出自己的能力与优势, 在网页挖掘 [6]、多媒体内容分析 [4,7]、生态信息学 [8] 等领域均成功得到了应用. 同时, 随着偏标记学习的发展, 也逐渐出现由偏标记学习问题衍生的相关工作, 例如: 解决偏标记样本中的类别不平衡问题 [9], 基于偏标记学习框架的度量学习 [10]、主动学习 [11] 等.

值得注意的是, 偏标记学习与现有的半监督学习 (semi-supervised learning) [12,13]、多示例学习 (multi-instance learning) [14,15] 以及多标记学习 (multi-label learning) [16,17] 等几种主流的弱监督学习问题也有着一定的联系与区别. 图 1 将这 4 种弱监督学习框架进行了对比.

如图 1(a) 所示, 半监督学习中, 仅有少量样本的标记已知, 而大量的样本标记是未知的, 显然学习系统从此类训练集中获得的监督信息是十分有限的. 在半监督学习中, 样本具有明确的 (单个真实标记) 或完全未知 (未标记) 的语义信息, 而偏标记学习中的训练样本对应了一个候选标记集合. 当候选标记集合仅包括了一个标记时, 该样本的语义信息则完全明确; 当候选标记集合包括了标记空间的所有标记时, 它的语义信息将完全未知. 一般来说, 偏标记训练样本的候选标记集合中包含的语义信息介于完全明确与完全未知之间, 即 $1 < |S_i| < q$.

如图 1(b) 所示, 多示例学习中, 训练集的每个样本以“示例包 (bag of instances)”的形式存在, 样本的语义标记定义在包层次而非示例层次, 包为正包当且仅当包中含有正例, 为负包当且仅当包中完

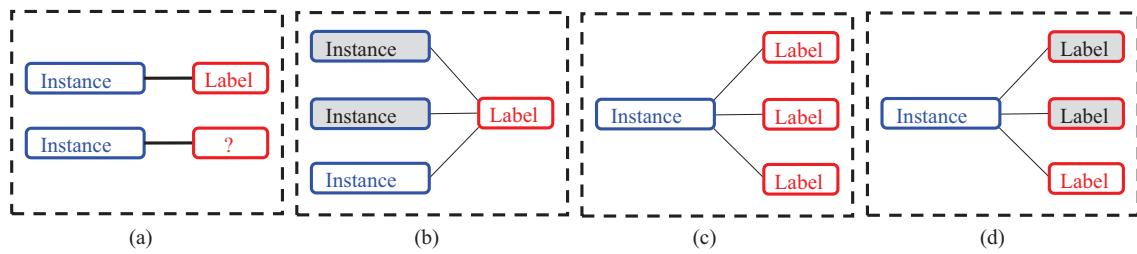
图1 (网络版彩图) 弱监督机器学习框架^[3,5]

Figure 1 (Color online) Weakly-supervised machine learning framework^[3,5]. (a) Semi-supervised learning; (b) multi-instance learning; (c) multi-label learning; (d) partial label learning

全为负例. 负包中各示例的语义信息明确, 即均为负例. 然而, 正包中虽包含正例但并未明确标识, 难以与包中“伪正例 (false positive instances)”加以区分, 因此, 学习系统从训练集中获得的监督信息较为有限. 多示例学习中, 训练样本的标记明确但与示例的对应关系不明确, 而偏标记学习中, 每个样本均由单个示例表示但与标记的对应关系不明确. 在学习系统利用训练样本进行建模时, 多示例学习的难度在于示例包中的伪正例, 而偏标记学习的难度在于候选标记集合中的伪标记. 从某种程度来讲, 多示例学习和偏标记学习是弱监督信息分别存在于示例空间或标记空间的对偶问题.

如图1(c)所示, 多标记学习中, 每个样本具有多个“正确 (valid)”的语义标记, 学习系统的目标是预测未见示例的标记集合. 表面上看, 每个样本具有多个正确的语义标记, 其监督信息十分明确. 然而, 若将每种可能的标记集合作为一个类别, 多标记学习则对应于一个多类分类问题, 其输出空间为指数规模. 面对庞大的输出空间, 许多标记集合在训练集中仅对应于少量样本, 甚至从未出现, 从这一角度看, 多标记训练样本同样具有较弱的监督信息. 不难发现, 多标记训练样本对应的多个标记均为真实标记, 且学习目标是从示例到标记集合的映射, 而偏标记训练样本对应的多个标记仅为候选标记, 学习目标为示例到单个标记的映射. 一方面, 从标记信息上看, 偏标记样本可以看作具有“噪声标记 (noisy label)”的多标记样本; 另一方面, 当多标记样本的真实标记缺失时, 则对应于“弱标记 (weak label)”^[18~20] 学习问题.

除此之外, 弱监督学习框架还包括多示例多标记学习 (multi-instance multi-label learning)^[21]、弱监督多标记学习 (partial multi-label learning)^[22~24] 等. 在真实世界中, 弱监督信息常见且表现形式多样, 需根据具体问题选择适当的学习框架. 而当对象的真实标记隐含于一组候选标记时, 选择偏标记学习框架进行描述与建模则显得十分自然^[20, 25~29].

3 基于消歧的偏标记学习算法

在偏标记学习框架下, 每个样本的标记信息不再具有单一性和明确性, 真实标记隐含在候选标记集合中. 针对这种具有歧义性的样本, 一种直观的解决偏标记学习问题的方法是对候选标记集合进行消歧. 采用该思路, 现有的偏标记学习算法主要采用两种不同的策略, 即“基于辨识 (identification-based)”的消歧和“基于平均 (averaging-based)”的消歧. 基于辨识的消歧将偏标记样本的真实标记作为隐变量, 通过迭代的方式优化内嵌隐变量的目标函数以实现消歧; 基于平均的消歧赋予偏标记样本的各个候选标记相同的权重, 通过综合学习模型在各候选标记上的输出实现消歧. 值得一提的是, 针对基于平均的消歧策略, 研究者们提出通过加权的方式学习候选标记的置信度, 对基于平均的消歧策略进行改进.

接下来, 本节将介绍 4 种代表性的基于消歧的偏标记学习算法, 即基于辨识消歧策略的极大似然估计方法 PL-EM^[25]、最大化间隔方法 M3PL^[30], 以及基于平均消歧策略的凸优化方法 CLPL^[3]、Boosting 方法 CORD^[31].

3.1 极大似然估计方法

假设偏标记学习系统学得的多类分类器 f 具有参数化的表示形式: $f(\mathbf{x}) = \arg \max_{y \in \mathcal{Y}} p(y | \mathbf{x}, \boldsymbol{\theta})$. 其中, $p(y | \mathbf{x}, \boldsymbol{\theta})$ 表示样本 \mathbf{x} 具有类别标记 y 的后验概率, $\boldsymbol{\theta}$ 为模型的参数向量. 假设训练集中样本满足条件独立, 一种直观的策略是采用“极大似然 (maximum likelihood)”估计准则对模型参数进行求解:

$$\begin{aligned} \boldsymbol{\theta}^* &= \arg \max_{\boldsymbol{\theta}} \prod_{i=1}^m p(y \in S_i | \mathbf{x}_i, \boldsymbol{\theta}) \\ &= \arg \max_{\boldsymbol{\theta}} \sum_{i=1}^m \log \left(\sum_{y \in S_i} p(y | \mathbf{x}_i, \boldsymbol{\theta}) \right). \end{aligned} \quad (1)$$

可采用经典的“期望最大化 (expectation-maximization, EM)”^[32] 算法对式 (1) 进行优化. EM 算法是一种迭代优化算法, 通过 E-step 和 M-step 对模型参数进行迭代更新.

在 E-step 中, 基于当前轮次模型参数 $\boldsymbol{\theta}^{(t)}$, 对标记的后验概率分布进行估计:

$$\hat{p}(y | \mathbf{x}_i) = \begin{cases} \frac{p(y | \mathbf{x}_i, \boldsymbol{\theta}^{(t)})}{\sum_{y' \in S_i} p(y' | \mathbf{x}_i, \boldsymbol{\theta}^{(t)})}, & \forall y \in S_i, \\ 0, & \text{otherwise.} \end{cases} \quad (2)$$

在 M-step 中, 记式 (1) 中目标函数为 $L(\boldsymbol{\theta}) = \sum_{i=1}^m \log(\sum_{y \in S_i} p(y | \mathbf{x}_i, \boldsymbol{\theta}))$, 根据 Jensen 不等式可求得 $L(\boldsymbol{\theta})$ 的下界函数 $A(\boldsymbol{\theta})$:

$$\begin{aligned} L(\boldsymbol{\theta}) &= \sum_{i=1}^m \log \left(\sum_{y \in S_i} \hat{p}(y | \mathbf{x}_i) \cdot \frac{p(y | \mathbf{x}_i, \boldsymbol{\theta})}{\hat{p}(y | \mathbf{x}_i)} \right) \\ &\geq \sum_{i=1}^m \sum_{y \in S_i} \hat{p}(y | \mathbf{x}_i) \cdot \log \frac{p(y | \mathbf{x}_i, \boldsymbol{\theta})}{\hat{p}(y | \mathbf{x}_i)} \\ &= A(\boldsymbol{\theta}). \end{aligned} \quad (3)$$

$L(\boldsymbol{\theta}) \geq A(\boldsymbol{\theta})$ 且当 $\boldsymbol{\theta} = \boldsymbol{\theta}^{(t)}$ 时该不等式取等号. 基于此, EM 算法通过最大化下界函数 $A(\boldsymbol{\theta})$ 对参数向量进行更新:

$$\boldsymbol{\theta}^{(t+1)} = \arg \max_{\boldsymbol{\theta}} A(\boldsymbol{\theta}). \quad (4)$$

值得注意的是, E-step 在一定程度上实现了对候选标记集合 S_i 的消歧, 即候选标记 $y \in S_i$ 的后验概率 $\hat{p}(y | \mathbf{x}_i)$ 体现了该标记成为样本真实标记的置信度, 而非候选标记 $y \notin S_i$ 的后验概率为 0.

在 PL-EM 算法中, 采用“最大熵 (maximum entropy, ME)”^[25, 33, 34] 模型对后验概率模型 $p(y | \mathbf{x}, \boldsymbol{\theta})$ 的具体参数形式进行了刻画. 另一种基于极大似然估计的偏标记学习算法 LSB-CMM (logistic stick breaking conditional multinomial model) 采用“概率图模型 (probabilistic graphical model)”^[8, 35] 的方式刻画后验概率.

3.2 最大化间隔方法

给定标记空间 $\mathcal{Y} = \{y_1, y_2, \dots, y_q\}$, 设学习系统包含 q 个线性分类器 $\Theta = \{(\mathbf{w}_{y_j}, b_{y_j}) \mid \mathbf{w}_{y_j} \in \mathbb{R}^d, b_{y_j} \in \mathbb{R}, 1 \leq j \leq q\}$, 此时偏标记学习系统所需的多类分类器 f 对应于

$$f(\mathbf{x}) = \arg \max_{y_j \in \mathcal{Y}} \mathbf{w}_{y_j}^T \cdot \mathbf{x} + b_{y_j}. \quad (5)$$

对式(5)所示线性模型进行优化,一种常用的策略为最大化“间隔(margin)”,其目标函数通常具有如下的表现形式:

$$\min_{\Theta} L(\Theta, \mathcal{D}) + \lambda \cdot \Omega(\Theta), \quad (6)$$

其中 $L(\Theta, \mathcal{D})$ 用于考察模型在训练样本上的“经验损失(empirical loss)”, $\Omega(\Theta)$ 用于考察模型复杂度,而参数 λ 为平衡经验损失与模型复杂度对目标函数的影响.

针对偏标记学习问题,需选择合适的经验损失函数 $L(\Theta, \mathcal{D})$ 以及模型复杂度函数 $\Omega(\Theta)$ 以体现问题的特性.通常来说,模型复杂度可采用L2范数描述: $\Omega(\Theta) = \frac{1}{2} \|\mathbf{w}\|^2$.经验损失函数则需反映线性模型对每个偏标记训练样本 (\mathbf{x}_i, S_i) 的分类能力.考虑到在偏标记学习问题中,对象的真实标记隐含在候选标记集合中,给定一组线性模型,最大化间隔方法M3PL(maximum margin partial label learning)希望将候选标记集合中线性输出值最大的标记作为真实标记,并最大化真实标记与其他标记之间的间隔,式(6)所示的优化问题可重写为

$$\begin{aligned} & \min_{\mathbf{y}, \Theta, \xi} \frac{1}{2} \sum_{j=1}^q \|\mathbf{w}_j\|^2 + \lambda \sum_{i=1}^m \xi_i \\ \text{s.t. } & (\mathbf{w}_{y_i}^T \cdot \mathbf{x}_i + b_{y_i}) - \max_{\tilde{y}_i \neq y_i} (\mathbf{w}_{\tilde{y}_i}^T \cdot \mathbf{x}_i + b_{\tilde{y}_i}) \geq 1 - \xi_i, \\ & \xi_i \geq 0, \quad \forall i \in \{1, 2, \dots, m\}, \\ & \mathbf{y} \in \mathcal{S}, \\ & \sum_{i=1}^m \mathbb{I}(y_i = j) = n_j, \quad \forall j \in \{1, 2, \dots, q\}, \end{aligned} \quad (7)$$

其中前两个约束条件形式化表达了每个示例上的最大间隔准则, ξ 为松弛变量;第3个约束条件表示(未知的)真实标记指派 $\mathbf{y} = \{y_1, y_2, \dots, y_m\}$ 需在可行的解空间 $\mathcal{S} = S_1 \times S_2 \times \dots \times S_m$ 中取得;第4个约束条件表示真实标记指派中每个类别的个数需满足类别个数分布的先验, n_j 表示训练集中真实标记为第 j 个类别的样本数,可由每个样本第 j 个类别的置信度总和近似得到. $\mathbb{I}(\pi)$ 为指示函数, π 为真时,取值为1,反之取值为0.

求解式(7)所示的优化问题,M3PL算法采用一种“交替优化(alternating optimization)”的策略,依次固定真实标记指派 \mathbf{y} 和模型参数 Θ ,对另一变量进行优化,直至收敛.值得注意的是,在固定 Θ ,更新 \mathbf{y} 时,可看作对候选标记集合的辨识消歧.

在M3PL算法中,优化的是模型在真实标记上的输出与在其他标记上的最大输出之间的间隔.另有一种基于最大间隔策略的算法PL-SVM^[36],优化候选标记集合上的最大输出与非候选标记集合上最大输出之间的间隔.

3.3 凸优化方法

假设 $g_j : \mathcal{X} \rightarrow \mathbb{R}$ 为与第 j 类对应的二类分类器,则多类分类器 f 可由上述二类分类器 g_j ($1 \leq$

$j \leq q$) 按如下方式获得:

$$f(\mathbf{x}) = \arg \max_{y_j \in \mathcal{Y}} g_j(\mathbf{x}). \quad (8)$$

对分类器的参数模型进行求解, 常用的方式为最小化损失函数. 在偏标记学习中, 给定偏标记训练集 \mathcal{D} 可考察学习系统的“偏标记 0/1 损失 (partial 0/1 loss)”: $L_p(\mathcal{D}) = \sum_{i=1}^m \mathbb{I}(\arg \max_{y_i \in \mathcal{Y}} g_j(\mathbf{x}_i) \notin S_i)$, 然而 $L_p(\mathcal{D})$ 无法直接优化, 在凸优化偏标记算法 CLPL (convex loss for partial label) 中, 提出基于特定的二类凸损失函数 $\Psi: \mathbb{R} \rightarrow \mathbb{R}^+$ 而定义的损失函数:

$$\begin{aligned} L_\Psi(\mathcal{D}) &= \sum_{i=1}^m L_\Psi(\mathbf{x}_i, S_i) \\ &= \sum_{i=1}^m \left[\Psi\left(\frac{\sum_{y_j \in S_i} g_j(\mathbf{x}_i)}{|S_i|}\right) + \sum_{y_k \in \bar{S}_i} \Psi(-g_k(\mathbf{x}_i)) \right], \end{aligned} \quad (9)$$

其中函数第 1 项在一定程度上实现了对候选标记集合的消歧操作, 即偏标记样本在候选标记集合上的经验损失由各候选标记的模型输出的平均值决定. $\bar{S}_i = \mathcal{Y} \setminus S_i$ 为非候选标记集合. 当凸函数 Ψ 递减且 $\Psi(0) \geq 1$ 时有性质 $L_p(\mathcal{D}) \leq \frac{1}{2}L_\Psi(\mathcal{D})$, 即可将 $L_\Psi(\mathcal{D})$ 作为 $L_p(\mathcal{D})$ 的“替代损失 (surrogate loss)”. 满足上述性质的常用凸损失函数包括“铰链损失 (hinge loss)”、“指数损失 (exponential loss)”、“逻辑斯蒂损失 (logistic loss)”等.

记 Φ 为属性空间映射函数 $\Phi: \mathcal{X} \times \mathcal{Y} \rightarrow \mathbb{R}^{d \times q}$, 给定“示例 – 标记”配对 $(\mathbf{x}, y) \in \mathcal{X} \times \mathcal{Y}$, 该函数将其映射至新的属性向量 $\Phi(\mathbf{x}, y)$:

$$\Phi(\mathbf{x}, y) = \begin{pmatrix} \mathbf{x} \cdot \mathbb{I}(y = y_1) \\ \mathbf{x} \cdot \mathbb{I}(y = y_2) \\ \vdots \\ \mathbf{x} \cdot \mathbb{I}(y = y_q) \end{pmatrix}. \quad (10)$$

CLPL 将偏标记学习问题转换为二类分类问题, 定义正样本集 \mathcal{D}^+ 和负样本集 \mathcal{D}^- :

$$\begin{aligned} \mathcal{D}^+ &= \left\{ \frac{1}{|S_i|} \sum_{y_j \in S_i} \Phi(\mathbf{x}_i, y_j) \mid 1 \leq i \leq m \right\}, \\ \mathcal{D}^- &= \{ \Phi(\mathbf{x}_i, y_k) \mid 1 \leq i \leq m, y_k \in \bar{S}_i \}. \end{aligned} \quad (11)$$

CLPL 算法将 m 个偏标记样本转换为 m 个正样本和 $\sum_{i=1}^m (q - |S_i|)$ 个负样本. 设 \mathcal{B}_Ψ 为优化凸损失函数 Ψ 的二类学习算法, 则基于 \mathcal{B}_Ψ 在数据集 $\mathcal{D}^+ \cup \mathcal{D}^-$ 上可学习一个二类分类器 $h: \mathbb{R}^{d \times q} \rightarrow \mathbb{R}$, 即 $h \leftarrow \mathcal{B}_\Psi(\mathcal{D}^+ \cup \mathcal{D}^-)$. 对比式 (9) 和 (11), 优化该分类器的经验损失等价于优化式 (9) 所示的经验损失函数.

3.4 Boosting 方法

Boosting 技术在机器学习中被广泛应用, 它通过迭代将弱学习器构建为泛化能力较强的学习系统. 基于标记置信度的判别式偏标记学习算法 CORD (confidence-rated discriminative partial label learning) 适应了 boosting 算法对偏标记样本进行学习, 在每一轮迭代中, 同时更新样本权重与候选标记的置信度.

给定偏标记训练集 $\mathcal{D} = \{(\mathbf{x}_i, S_i) \mid 1 \leq i \leq m\}$, 在第 t 轮迭代中, 定义样本权重为 $\mathbf{w}^{(t)} = [w_1^{(t)}, w_2^{(t)}, \dots, w_m^{(t)}]^T$, 标记置信度矩阵为 $\mathbf{P}^{(t)} = [p_{ij}^{(t)}]_{m \times q}$, CORD 算法通过最大化目标函数 (12) 来得到模型 $g(y \mid \mathbf{x}, \boldsymbol{\theta}^{(t)})$:

$$\mathcal{J}(\mathcal{D}, \boldsymbol{\theta}^{(t)}) = \sum_{i=1}^m w_i^{(t)} \log \left(\sum_{y_j \in S_i} p_{ij}^{(t)} \cdot g(y_j \mid \mathbf{x}_i, \boldsymbol{\theta}^{(t)}) \right). \quad (12)$$

可以看出, 候选标记的模型输出 $g(y_j \mid \mathbf{x}_i, \boldsymbol{\theta}^{(t)})$ 以 $p_{ij}^{(t)}$ 为权重, 即 y_j 成为 \mathbf{x}_i 真实标记的置信度, 实现了对候选标记集合的消歧. 而当候选标记置信度相同时, 即退化为平均消歧策略.

在传统的 Boosting 过程中, 利用分类精度来评估训练过的基分类器在 (带权重的) 训练样本上的性能. 然而, 在偏标记学习中, 由于训练样本的真实标记未知, 无法通过这种方式来评估基分类器的性能. CORD 算法采用模型在候选标记集合与非候选标记集合最大输出之差来评估基分类器的性能 [30, 36]:

$$\begin{aligned} r^{(t)} &= \sum_{i=1}^m w_i^{(t)} \cdot \gamma_i^{(t)}, \\ \gamma_i^{(t)} &= \max_{y_j \in S_i} g(y_j \mid \mathbf{x}_i, \boldsymbol{\theta}^{(t)}) - \max_{y_k \in \bar{S}_i} g(y_k \mid \mathbf{x}_i, \boldsymbol{\theta}^{(t)}). \end{aligned} \quad (13)$$

下一轮的样本权重 $\mathbf{w}^{(t+1)}$ 更新如下:

$$\forall i \in \{1, \dots, m\}: w_i^{(t+1)} = \frac{w_i^{(t)} \cdot \exp(-\alpha^{(t)} \gamma_i^{(t)})}{Z^{(t+1)}}, \quad (14)$$

其中 $\alpha^{(t)}$ 为第 t 轮中迭代基分类器的组合系数 $\alpha^{(t)} = \frac{1}{2} \cdot \log(\frac{1+r^{(t)}}{1-r^{(t)}})$, $Z^{(t+1)}$ 为归一化因子, 以确保 $\sum_{i=1}^m w_i^{(t+1)} = 1$. 相应地, 下一轮的置信度矩阵 $\mathbf{P}^{(t+1)}$ 更新如下:

$$\begin{aligned} \forall i \in \{1, \dots, m\}, j \in \{1, \dots, q\}: p_{ij}^{(t+1)} &= \frac{p_{ij}^{(t)} \cdot \exp(\beta \cdot \mathbb{I}(y_j = y_i^{(t)}))}{R_i^{(t+1)}}, \\ y_i^{(t)} &= \arg \max_{y \in S_i} g(y \mid \mathbf{x}_i, \boldsymbol{\theta}^{(t)}), \end{aligned} \quad (15)$$

其中 $\beta > 0$ 为置信度矩阵的更新参数; $y_i^{(t)}$ 为在第 t 轮迭代中模型在候选标记中的最大输出; $R_i^{(t+1)}$ 为归一化因子, 以确保 $\sum_{j=1}^q p_{ij}^{(t+1)} = 1$.

在 CORD 中, 利用 Boosting 技术同时更新样本的权重与候选标记的置信度, 对候选标记集合进行消歧. 除此之外, 一种 k 近邻方法 PL- k NN [37] 直接通过对近邻样本的加权投票来对未见示例进行预测. 在此基础上, 一种基于示例的偏标记学习算法 IPAL [38], 利用近邻样本构建带权图, 并通过标记传播得到候选标记的置信度从而进行消歧. 而 RegISL [39] 方法引入正则项, 进一步挖掘候选标记间的互斥关系, 进行消歧. LALO 方法 [40] 希望在挖掘候选标记的隐式标记分布 (latent label distribution) 的同时, 构建具有判别性的分类器. PL-LEAF 方法 [41] 则利用特征空间的结构来构建候选标记的置信度, 并基于该置信度进行多输出回归 (multi-output regression) 的学习. 在此基础上, PL-LE 方法 [42] 不仅强调候选标记间的置信度, 更通过泛化标记分布 (generalized label distribution) 对非候选标记加以利用.

4 基于非消歧的偏标记学习算法

基于消歧的策略直观地实现对偏标记对象候选标记集合的利用, 然而由于对象的真实标记 y_i 隐含在候选标记集合中, 基于消歧的偏标记学习技术会受到伪标记 (即 $S_i \setminus y_i$) 带来的不利影响. 对于辨识消歧策略, 算法每一轮的迭代中识别出的类别标记 \hat{y}_i 可能为对象的伪标记而非真实标记; 对于平均消歧策略, 对象真实标记的模型输出可能湮没于其伪标记的模型输出中.

因此, 我们提出基于非消歧策略求解偏标记学习问题. 本节接下来将介绍 2 种相应的非消歧偏标记学习算法, 即纠错输出编码方法 PL-ECOC^[43] 以及二类分解机制方法 PALOC^[44].

4.1 纠错输出编码方法

偏标记学习系统最终的目标是学习得到多类分类器 $f : \mathcal{X} \rightarrow \mathcal{Y}$, 可采用“纠错输出编码 (error-correcting output codes, ECOC)”方法通过“编码 – 解码”的步骤将多类分类问题转换为二类分类问题.

在编码阶段, 首先定义二值编码矩阵 $\mathbf{M} \in \{+1, -1\}^{q \times L}$, 其中 \mathbf{M} 的每一行 $\mathbf{M}(j,:)$ 代表标记 y_j 对应的码字, 长度为 L , 每一列是长度为 q 的编码 $\mathbf{v} = [v_1, v_2, \dots, v_q] \in \{+1, -1\}^q$, 基于 \mathbf{v} , 标记空间可被划分为 $\mathcal{Y}_{\mathbf{v}}^+$ 和 $\mathcal{Y}_{\mathbf{v}}^-$ 两个不相交的子集:

$$\begin{aligned}\mathcal{Y}_{\mathbf{v}}^+ &= \{y_j \mid v_j = +1, 1 \leq j \leq q\}, \\ \mathcal{Y}_{\mathbf{v}}^- &= \mathcal{Y} \setminus \mathcal{Y}_{\mathbf{v}}^+.\end{aligned}\tag{16}$$

给定偏标记样本 (\mathbf{x}_i, S_i) , PL-ECOC 算法不试图对候选标记结合 S_i 进行消歧, 而是将其看作一个“整体 (entirety)”. 在构建二类分类器 h_l 时, 若候选标记集合 S_i 完全落在 $\mathcal{Y}_{\mathbf{v}}^+$ 中, 则将 \mathbf{x}_i 视为一个正样本; 若候选标记集合 S_i 完全落在 $\mathcal{Y}_{\mathbf{v}}^-$ 中, 则将 \mathbf{x}_i 视为一个负样本, 否则在训练分类器 h_l 时将忽略 \mathbf{x}_i , 即

$$\mathcal{D}_v = \{(\mathbf{x}_i, +1) \mid S_i \subseteq \mathcal{Y}_{\mathbf{v}}^+, 1 \leq i \leq m\} \cup \{(\mathbf{x}_i, -1) \mid S_i \subseteq \mathcal{Y}_{\mathbf{v}}^-, 1 \leq i \leq m\}.\tag{17}$$

注意到, 由于编码生成的随机性, 可能会出现 \mathcal{D}_v 中样本稀少的情况, 而使得训练时的监督信息较少, 无法得到泛化性较强的分类器. 因此, PL-ECOC 设置了一个阈值 τ 控制训练集中样本数目. 当 \mathcal{D}_v 中样本数目小于 τ 时, 会重新生成一组码字, 直到 \mathcal{D}_v 中数目达到阈值. 之后, 可利用二类学习算法 \mathcal{B} 对该训练集进行学习建模得到基分类器 h_l , 即 $h_l \leftarrow \mathcal{B}(\mathcal{D}_v)$, 并将编码 \mathbf{v} 加入 PL-ECOC 的编码矩阵中 $\mathbf{M}(:, l) = \mathbf{v}$.

在解码阶段, 对于未见示例 \mathbf{x}^* , 基于各二类分类器在 \mathbf{x}^* 上的分类输出可得与 \mathbf{x}^* 对应的长度 L 比特的码字: $h(\mathbf{x}^*) = [h_1(\mathbf{x}^*), h_2(\mathbf{x}^*), \dots, h_L(\mathbf{x}^*)]^T$, PL-ECOC 将与码字 $h(\mathbf{x}^*)$ 最接近的类别作为测试样本的预测输出:

$$f(\mathbf{x}^*) = \arg \max_{y_j \in \mathcal{Y}} \text{dist}(h(\mathbf{x}^*), \mathbf{M}(j,:)),\tag{18}$$

其中距离函数 $\text{dist}(\mathbf{u}, \mathbf{v})$ 可采用多种方法进行实现, 如“海明 (Hamming)”距离^[38]、“欧式 (Euclidean)”距离^[45]、“基于损失的 (loss-based)”距离^[46, 47]等.

算法 1 给出了 PL-ECOC 算法^[43] 的伪码描述, 算法分为编码阶段 (步骤 1~11) 和解码阶段 (步骤 12 和 13). 在编码阶段, 首先生成码字 \mathbf{v} , 根据 \mathbf{v} 划分标记空间并构造二类训练集 (步骤 3~5); 当二类训练集中样本数目大于阈值时, 将码字 \mathbf{v} 加入编码矩阵中, 然后将训练集提交给二类学习算法 (步

Algorithm 1 The pseudo-code of PL-ECOC

Input: \mathcal{D} : partial label training set $\{(\mathbf{x}_i, S_i) \mid 1 \leq i < m\}$, ($\mathbf{x}_i \in \mathcal{X}, S_i \subseteq \mathcal{Y}, \mathcal{X} = \mathbb{R}^d, \mathcal{Y} = \{y_1, y_2, \dots, y_q\}\}$);
 L : the codeword length;
 \mathcal{B} : binary training algorithm;
 τ : the thresholding binary training set size;
 \mathbf{x}^* : the unseen instance;

Output: y^* : the predicted class label for \mathbf{x}^* ;

- 1: $l = 0$;
- 2: **while** $l \neq L$ **do**
- 3: Randomly generate a q -bits column coding: $\mathbf{v} = [v_1, v_2, \dots, v_q] \in \{+1, -1\}^q$;
- 4: Dichotomize the label space according to (16);
- 5: Construct binary training set according to (17);
- 6: **if** $|\mathcal{D}_v| \leq \tau$ **then**
- 7: $l = l + 1$;
- 8: Set the l -th column of the coding matrix \mathbf{M} to \mathbf{v} : $\mathbf{M}(:, l) = \mathbf{v}$;
- 9: Build the binary classifier by invoking \mathcal{B} on \mathcal{D}_v , i.e., $h_l \leftarrow \mathcal{B}(\mathcal{D}_v)$;
- 10: **end if**
- 11: **end while**
- 12: Generate codeword $h(\mathbf{x}^*)$ by querying binary classifier' outputs: $h(\mathbf{x}^*) = [h_1(\mathbf{x}^*), h_2(\mathbf{x}^*), \dots, h_L(\mathbf{x}^*)]^T$;
- 13: Return $y^* = f(\mathbf{x}^*)$ according to (18).

骤 6~10); 重复以上步骤直到构建 L 列码字. 在解码阶段, 首先基于各二类分类器生成未见示例对应码字, 然后返回预测结果 (步骤 12 和 13).

PL-ECOC 不再对各候选标记进行区分, 而是将其看作一个整体进行操作, 是一种非消歧偏标记学习算法.

4.2 二类分解机制方法

正如第 2 节中所述, 偏标记学习的目标是基于训练集 \mathcal{D} 学习一个多类分类器, 通常来讲, 解决多分类问题的直观策略是利用二类分解机制将其转换为多个二分类问题, 然而偏标记样本 (\mathbf{x}_i, S_i) 的真实标记 y_i 隐藏于其候选标记集 S_i 中, 使得二类分解机制无法直接使用. 若采用“一对多”分解机制, 针对某一标记, 无法确定 (\mathbf{x}_i, S_i) 应被划分为正类或是负类. 若采用“一对一”分解机制, 针对某一标记对, 无法确定 (\mathbf{x}_i, S_i) 应被划分为哪一个标记.

我们所提出的 PALOC 方法 (patial label learning via one-vs-one decomposition) 使偏标记样本适应“一对一”分解机制, 使二类分解机制得以应用于偏标记学习中. 具体来说, 对于每组标记对 (y_j, y_k) , y_j 和 y_k 与 (\mathbf{x}_i, S_i) 的关联由它们与候选标记集合的指派关系决定, 而非它们与 (未知的) 真实标记的相关性决定. 令 (\mathbf{x}_i, S_i) 表示 S_i 在 \mathcal{Y} 中的补集, 对于每组标记对 (y_j, y_k) , 相应二类训练集构建如下:

$$\mathcal{D}_{jk} = \{(\mathbf{x}_i, \psi(S_i, y_j, y_k)) \mid \phi(S_i, y_j) \neq \phi(S_i, y_k), 1 \leq i \leq m\},$$

$$\text{where } \phi(S_i, y) = \begin{cases} +1, & \text{if } y \in S_i, \\ -1, & \text{otherwise,} \end{cases} \quad \text{and}$$

$$\psi(S_i, y_j, y_k) = \begin{cases} +1, & \text{if } y_j \in S_i \text{ and } y_k \in \bar{S}_i, \\ -1, & \text{if } y_j \in \bar{S}_i \text{ and } y_k \in S_i. \end{cases} \quad (19)$$

也就是说, 对于偏标记训练样本 (\mathbf{x}_i, S_i) , 只有当 y_j 和 y_k 与 S_i 有直接的指派关系时, 该样本才会被加入至二类训练集 \mathcal{D}_{jk} 中。接下来, 基于训练集 \mathcal{D}_{jk} , 利用二类学习算法 \mathcal{B} 构造二类分类器 g_{jk} , 即 $g_{jk} \leftarrow \mathcal{B}(\mathcal{D}_{jk})$ 。不失一般性, 采用上述“一对”分解机制, 共可以构建 $\binom{q}{2}$ 个二类分类器(假设 $j < k$)。每个偏标记训练样本 (\mathbf{x}_i, S_i) 会参与到 $|S_i||\bar{S}_i|$ 个二类分类器的训练过程中。

给定 $\binom{q}{2}$ 个二类分类器, 任一示例 \mathbf{x} 的标记可由所有分类器共同投票得出

$$\begin{aligned} y &= \arg \max_{y_j \in \mathcal{Y}} V_{\text{ovo}}(\mathbf{x}, y_j) \\ &= \arg \max_{y_j \in \mathcal{Y}} \sum_{h=1}^{j-1} \mathbb{I}(g_{hj}(\mathbf{x}) < 0) + \sum_{k=j+1}^q \mathbb{I}(g_{jk}(\mathbf{x}) > 0). \end{aligned} \quad (20)$$

尽管基于式(20)进行预测是一个可行的方法, PALOC 仍选择采用 Stacking 策略^[46] 提升模型泛化性能。对于每个偏标记训练样本 (\mathbf{x}_i, S_i) , 其候选标记集合 S_i 可被改写为 \hat{S}_i , 具体如下:

$$\hat{S}_i = \begin{cases} \{\hat{y}_i\}, & \text{if } \hat{y}_i \in S_i, \\ S_i, & \text{if } \hat{y}_i \notin S_i, \end{cases} \quad (21)$$

其中 $\hat{y}_i = \arg \max_{y_j \in \mathcal{Y}} V_{\text{ovo}}(\mathbf{x}_i, y_j)$ 表示基于式(20)对示例 \mathbf{x}_i 的预测结果。因此, 若预测结果属于 S_i , 候选标记集合改写为 $\{\hat{y}_i\}$, 反之候选标记集合保持不变。

给定 $\binom{q}{2}$ 个二类分类器 g_{jk} ($1 \leq j < k \leq q$), 进一步利用 Stacking 策略构建 q 个辅助的二类分类器(每个标记构建一个)。对于每个标记 y_j ($1 \leq j \leq q$), 对应的二类训练集构造如下:

$$\begin{aligned} \mathcal{D}_j &= \{(\hat{\mathbf{x}}_i, \varphi(\hat{S}_i, y_j)) \mid 1 \leq i \leq m\}, \\ \text{where } \hat{\mathbf{x}}_i &= [\mathbf{x}_i, g_{12}(\mathbf{x}_i), g_{13}(\mathbf{x}_i), \dots, g_{(q-1)q}(\mathbf{x}_i)], \\ \text{and } \varphi(\hat{S}_i, y_j) &= \begin{cases} +1, & \text{if } y_j \in \hat{S}_i, \\ -1, & \text{if } y_j \notin \hat{S}_i. \end{cases} \end{aligned} \quad (22)$$

换句话说, 对于 \mathcal{D}_j 中的每个二类训练样本, $\hat{\mathbf{x}}_i$ 由原始特征向量 \mathbf{x}_i 与 $\binom{q}{2}$ 个分类器的预测结果增广构成。标记 $\varphi(\hat{S}_i, y_j)$ 由 y_j 与 \hat{S}_i 的指派关系决定。基于此, 对于训练集 \mathcal{D}_j , 利用二类学习算法 \mathcal{B} 构造二类分类器 $g_j : \mathcal{X} \mapsto \mathbb{R}$ 。

在测试阶段, 对于未见示例 \mathbf{x}^* , 首先通过 $\binom{q}{2}$ 个分类器构建增广特征向量:

$$\hat{\mathbf{x}}^* = [\mathbf{x}^*, g_{12}(\mathbf{x}^*), g_{13}(\mathbf{x}^*), \dots, g_{(q-1)q}(\mathbf{x}^*)]. \quad (23)$$

然后, $\binom{q}{2}$ 个分类器 g_{jk} ($1 \leq j < k \leq q$) 与 q 个分类器 g_j ($1 \leq j \leq q$) 协同作用, 预测 \mathbf{x}^* 的标记:

$$\begin{aligned} y^* &= f(\mathbf{x}^*) = \arg \max_{y_j \in \mathcal{Y}} V_{\text{ovo}}(\mathbf{x}^*, y_j) + \mu \cdot V_{\text{stack}}(\hat{\mathbf{x}}^*, y_j) \\ &= \arg \max_{y_j \in \mathcal{Y}} \sum_{h=1}^{j-1} \mathbb{I}(g_{hj}(\mathbf{x}^*) < 0) + \sum_{k=j+1}^q \mathbb{I}(g_{jk}(\mathbf{x}^*) > 0) + \mu \cdot \mathbb{I}(g_j(\hat{\mathbf{x}}^*) > 0), \end{aligned} \quad (24)$$

其中 μ 为“一对一”二类分类器的投票数 $V_{\text{ovo}}(\mathbf{x}^*, y_j)$ 与 Stacking 二类分类器 $V_{\text{stack}}(\mathbf{x}^*, y_j)$ 的投票数的平衡参数。

算法 2 总结了 PALOC 算法的完整步骤。给定偏标记训练集, 利用“一对一”分解机制构建二类训练集, 并构造 $\binom{q}{2}$ 个分类器(步骤 1~6)。然后利用这些二类分类器对训练样本构造增广特征向量,

Algorithm 2 The pseudo-code of PALOC

Input: \mathcal{D} : partial label training set $\{(\mathbf{x}_i, S_i) \mid 1 \leq i < m\}$, ($\mathbf{x}_i \in \mathcal{X}, S_i \subseteq \mathcal{Y}, \mathcal{X} = \mathbb{R}^d, \mathcal{Y} = \{y_1, y_2, \dots, y_q\}\}$);
 \mathcal{B} : binary training algorithm;
 μ : the balance parameter;
 \mathbf{x}^* : the unseen instance;

Output: y^* : the predicted label label for \mathbf{x}^* ;

```

1: for  $j = 1$  to  $q - 1$  do
2:   for  $k = j + 1$  to  $q$  do
3:     Construct the one-vs-one binary training set  $\mathcal{D}_{jk}$  according to (19);
4:      $g_{jk} \leftarrow \mathcal{B}(\mathcal{D}_{jk})$ ;
5:   end for
6: end for
7: for  $i = 1$  to  $m$  do
8:   Obtain the disambiguation prediction  $\hat{y}_i$  for  $\mathbf{x}_i$  according to (20);
9:   Indentify the refined candidate label set  $\hat{S}_i$  for  $\mathbf{x}_i$  according to (21);
10: end for
11: for  $r = 1$  to  $q$  do
12:   Construct the stacking binary training set  $\mathcal{D}_j$  according to (22);
13:    $g_r \leftarrow \mathcal{B}(\mathcal{D}_j)$ ;
14: end for
15: Generate the augmented feature vector  $\hat{\mathbf{x}}^*$  for  $\hat{\mathbf{x}}^*$  according to (23);
16: Return  $y^* = f(\hat{\mathbf{x}}^*)$  according to (24).

```

同时改写候选标记集合 (步骤 7~10). 相应地, 基于 Stacking 策略进一步构造 q 个二类分类器 (步骤 11~14). 最后, 对于未见示例, 其预测标记由所有分类器共同预测得到 (步骤 15 和 16).

PALOC 算法从问题转换的角度解决偏标记学习问题, 基于“一对一”分解机制将偏标记学习转换为二类分类问题, 在划分标记对时, 将候选标记中标记同等看待, 并未对其进行消歧, 因此可看作一种非消歧的偏标记学习算法.

5 结束语

偏标记学习是一类重要的弱监督框架, 在该框架下, 每个示例的标记不再具有单一性和明确性, 而是对应了多个候选标记, 其中仅有一个为其真实标记. 本文对基于消歧策略与非消歧策略的偏标记学习算法进行综述. 对于偏标记学习领域, 我们认为有如下问题值得进一步研究.

(1) 问题转换角度: 问题转换指的是改造偏标记数据, 使其适应已有学习框架. 在本文中, 有 3 种算法将偏标记学习问题进行转换, 即 CLPL, PL-ECOC, 以及 PALOC, 然而这 3 种算法均将偏标记学习转换为二类学习问题. 如文中描述, 偏标记学习的目标是得到多类分类器, 因此可尝试直接将偏标记学习转换为多类分类问题、回归问题等.

(2) 相关信息利用: 偏标记学习的标记具有歧义性, 训练样本的监督信息十分有限, 因此更应充分挖掘已有数据之间的相关性. 从示例出发, 可考虑样本之间满足的“流形 (manifold)”假设、“聚类 (cluster)”假设, 输入相近的样本具有相似的输出; 从标记出发, 候选标记之间通常相关性较强, 候选标记与非候选标记之间相关性较弱.

(3) 弱监督学习框架融合: 如第 2 节中所述, 偏标记学习与其他弱监督学习框架既有联系也有区别, 如当偏标记学习候选标记数较高时, 则可将其视为未标记样本, 又如偏标记学习与多示例学习互

为对偶问题, 因此可适当引入其他弱监督学习框架的技术对偏标记学习问题进行求解.

参考文献

- 1 Zhou Z H. Machine Learning. Beijing: Tsinghua University Press, 2016 [周志华. 机器学习. 北京: 清华大学出版社, 2016]
- 2 Zhou Z H. A brief introduction to weakly supervised learning. *Natl Sci Rev*, 2018, 5: 44–53
- 3 Cour T, Sapp B, Taskar B. Learning from partial labels. *J Mach Learn Res*, 2011, 12: 1501–1536
- 4 Chen C H, Patel V M, Chellappa R. Learning from ambiguously labeled face images. *IEEE Trans Pattern Anal Mach Intell*, 2018, 40: 1653–1667
- 5 Zhang M L. Research on partial label learning. *J Data Acquis Process*, 2015, 30: 77–87 [张敏灵. 偏标记学习研究综述. 数据采集与处理, 2015, 30: 77–87]
- 6 Luo J, Orabona F. Learning from candidate labeling sets. In: Proceedings of Advances in Neural Information Processing Systems, Cambridge, 2010. 1504–1512
- 7 Zeng Z, Xiao S, Jia K, et al. Learning by associating ambiguously labeled images. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Portland, 2013. 708–715
- 8 Liu L, Dietterich T G. A conditional multinomial mixture model for superset label learning. In: Proceedings of Advances in Neural Information Processing Systems, Cambridge, 2012. 548–556
- 9 Wang J, Zhang M L. Towards mitigating the class-imbalance problem for partial label learning. In: Proceedings of the 24th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, London, 2018. 2427–2436
- 10 Zhou Y, Gu H. Geometric mean metric learning for partial label data. *Neurocomputing*, 2018, 275: 394–402
- 11 Nguyen V L, Destercke S, Masson M H. Querying partially labelled data to improve a k-nn classifier. In: Proceedings of the 31st AAAI Conference on Artificial Intelligence, San Francisco, 2017. 2401–2407
- 12 Chapelle O, Schölkopf B, Zien A. Semi-supervised learning. *IEEE Trans Neural Netw*, 2009, 20: 542
- 13 Zhu X J, Goldberg A B. Introduction to semi-supervised learning. In: Synthesis Lectures on Artificial Intelligence and Machine Learning. Morgan and Claypool Publishers, 2009. 3: 1–130
- 14 Dietterich T G, Lathrop R H, Lozano-Pérez T. Solving the multiple instance problem with axis-parallel rectangles. *Artif Intell*, 1997, 89: 31–71
- 15 Amores J. Multiple instance classification: review, taxonomy and comparative study. *Artif Intell*, 2013, 201: 81–105
- 16 Tsoumakas G, Katakis I, Vlahavas I. Mining multi-label data. In: Proceedings of Data Mining and Knowledge Discovery Handbook, Boston, 2009. 667–685
- 17 Zhang M L, Zhou Z H. A review on multi-label learning algorithms. *IEEE Trans Knowl Data Eng*, 2014, 26: 1819–1837
- 18 Sun Y Y, Zhang Y, Zhou Z H. Multi-label learning with weak label. In: Proceedings of the 24th AAAI Conference on Artificial Intelligence, Atlanta, 2010. 593–598
- 19 Wang D Y, Hoi S C H, He Y, et al. Mining weakly labeled web facial images for search-based face annotation. *IEEE Trans Knowl Data Eng*, 2014, 26: 166–179
- 20 Li Y F, Tsang I W, Kwok J T, et al. Convex and scalable weakly labeled svms. *J Mach Learn Res*, 2013, 14: 2151–2188
- 21 Zhou Z H, Zhang M L, Huang S J, et al. Multi-instance multi-label learning. *Artif Intell*, 2012, 176: 2291–2320
- 22 Xie M K, Huang S J. Partial multi-label learning. In: Proceedings of the 32nd AAAI Conference on Artificial Intelligence, New Orleans, 2018. 4302–4309
- 23 Yu G X, Chen X, Domeniconi C, et al. Feature-induced partial multi-label learning. In: Proceedings of 2018 IEEE International Conference on Data Mining, Singapore, 2018. 1398–1403
- 24 Fang J P, Zhang M L. Partial multi-label learning via credible label elicitation. In: Proceedings of the 33rd AAAI Conference on Artificial Intelligence, Honolulu, 2019
- 25 Jin R, Ghahramani Z. Learning with multiple labels. In: Proceedings of Advances in Neural Information Processing Systems, Cambridge, 2003. 921–928
- 26 Satoh S, Nakamura Y, Kanade T. Name-it: naming and detecting faces in news videos. *IEEE Multimedia*, 1999, 6: 22–35
- 27 Barnard K, Duygulu P, Forsyth D, et al. Matching words and pictures. *J Mach Learn Res*, 2003, 3: 1107–1135
- 28 Berg T L, Berg A C, Edwards J, et al. Names and faces in the news. In: Proceedings of the IEEE Computer Society

- Conference on Computer Vision and Pattern Recognition, Washington, 2004. 848–854
- 29 Everingham M, Sivic J, Zisserman A. “Hello! My name is... Buffy”—automatic naming of characters in TV video. In: Proceedings of the 17th British Machine Vision Conference, Edinburgh, 2006. 889–908
- 30 Yu F, Zhang M L. Maximum margin partial label learning. In: Proceedings of Asian Conference on Machine Learning, Hamilton, 2016. 96–111
- 31 Tang C Z, Zhang M L. Confidence-rated discriminative partial label learning. In: Proceedings of the Association for the Advancement of Artificial, San Francisco, 2017. 2611–2617
- 32 Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm. *J Royal Stat Soc Ser B*, 1977, 39: 1–38
- 33 Grandvallet Y. Logistic regression for partial labels. In: Proceedings of the 9th International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems, Annecy, 2002. 1935–1941
- 34 Della Pietra S, Della Pietra V, Lafferty J. Inducing features of random fields. *IEEE Trans Pattern Anal Machine Intell*, 1997, 19: 380–393
- 35 Koller D, Friedman N. Probabilistic Graphical Models: Principles and Techniques. Cambridge: MIT Press, 2009
- 36 Nguyen N, Caruana R. Classification with partial labels. In: Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Las Vegas, 2008. 551–559
- 37 Hüllermeier E, Beringer J. Learning from ambiguously labeled examples. *Intell Data Anal*, 2006, 10: 419–439
- 38 Zhang M L, Yu F. Solving the partial label learning problem: an instance-based approach. In: Proceedings of International Conference on Artificial Intelligence, Buenos Aires, 2015. 4048–4054
- 39 Gong C, Liu T L, Tang Y Y, et al. A regularization approach for instance-based superset label learning. *IEEE Trans Cybern*, 2018, 48: 967–978
- 40 Feng L, An B. Leveraging latent label distributions for partial label learning. In: Proceedings of the 27th International Joint Conference on Artificial Intelligence, Stockholm, 2018. 2107–2113
- 41 Zhang M L, Zhou B B, Liu X Y. Partial label learning via feature-aware disambiguation. In: Proceedings of the 22nd ACM SIGKDD Conference on Knowledge Discovery and Data Mining, San Francisco, 2016. 1335–1344
- 42 Xu N, Lv J Q, Geng X. Partial label learning via label enhancement. In: Proceedings of the 33rd AAAI Conference on Artificial Intelligence, Honolulu, 2019
- 43 Zhang M L, Yu F, Tang C Z. Disambiguation-free partial label learning. *IEEE Trans Knowl Data Eng*, 2017, 29: 2155–2167
- 44 Wu X, Zhang M L. Towards enabling binary decomposition for partial label learning. In: Proceedings of the 27th International Joint Conference on Artificial Intelligence, Stockholm, 2018. 2868–2874
- 45 Pujol O, Escalera S, Radeva P. An incremental node embedding technique for error correcting output codes. *Pattern Recogn*, 2008, 41: 713–725
- 46 Zhou Z H. Ensemble Methods: Foundations and Algorithms. Boca Raton: Chapman & Hall/CRC, 2012
- 47 Allwein E L, Schapire R E, Singer Y. Reducing multiclass to binary: a unifying approach for margin classifiers. *J Mach Learn Res*, 2000, 1: 113–141

Disambiguation-free partial label learning

Min-Ling ZHANG^{1,2*} & Xuan WU^{1,2}

1. School of Computer Science and Engineering, Southeast University, Nanjing 210096, China;

2. Key Laboratory of Computer Network and Information Integration (Southeast University), Ministry of Education, Nanjing 210096, China

* Corresponding author. E-mail: zhangml@seu.edu.cn

Abstract Partial label learning is an important weakly supervised machine learning framework. In partial label learning, each object is described by a single instance in the input space; however, in the output space, it is associated with a set of candidate labels among which only one is valid. An intuitive strategy is to disambiguate candidate labels, but this strategy tends to be misled by false positive labels; therefore, new disambiguation-free approaches need to be considered. In this paper, several algorithms are reviewed from the perspective of disambiguation and disambiguation-free strategies. First, the problem definition on partial label learning and its relationship with other related learning frameworks are given. Second, several representative partial label learning algorithms via the disambiguation strategy are introduced. Third, two of our proposed disambiguation-free algorithms are presented. Finally, the summary of this paper is given and possible future investigations on partial label learning are briefly discussed.

Keywords machine learning, weakly-supervised learning, partial label learning, candidate label, disambiguation-free strategy



Min-Ling ZHANG received his B.S., M.S., and Ph.D. degrees in Computer Science from Nanjing University, China in 2001, 2004, and 2007, respectively. Currently, he is a Professor at School of Computer Science and Engineering, Southeast University, China. His main research interests include machine learning and data mining.



Xuan WU received her B.S. degree in Computer Science from Southeast University, China, in 2016. Currently, she is a master's student at School of Computer Science and Engineering, Southeast University, China. Her main research interests include machine learning and data mining, especially learning from partial label data.