计算机系统应用 ISSN 1003-3254, CODEN CSAOBN
Computer Systems & Applications,2023,32(10):184−191 [doi: 10.15888/j.cnki.csa.009268]

E-mail: csa@iscas.ac.cn
http://www.c-s-a.org.cn
Tel: +86-10-62661041

基于标签噪声鲁棒学习的疾病风险预测①

郭雨茜, 李华玲

(中北大学 软件学院, 太原 030051)
通信作者: 李华玲, E-mail: lihualing750108@163.com

摘　要: 疾病风险预测能够筛查易患人群, 并在早期进行预防干预措施以降低疾病的发生率及死亡率. 随着机器学习技术的快速发展, 基于机器学习的疾病风险预测得到了广泛应用. 然而, 机器学习十分依赖于高质量的标注信息, 医疗数据中存在的标签噪声会给构建高性能的疾病风险预测算法带来严峻挑战. 针对这一问题, 本文提出了一种基于深度神经网络和动态截断损失函数的噪声鲁棒学习方法用于疾病风险预测. 该方法引入动态截断损失函数, 融合了传统交叉熵函数的隐式加权特性和均方差损失函数的标签噪声鲁棒性; 通过构造训练损失下界, 并引入样本动态加权机制减小可疑样本的梯度, 限制可能的带噪样本在训练过程中的权重, 进一步增强模型的鲁棒性. 以脑卒中筛查数据集为例进行实验, 结果表明本文算法在各个标签噪声比例下均能取得良好的预测性能, 可降低疾病风险预测中标签噪声的负面影响, 实现了带有标签噪声数据的鲁棒学习.

关键词: 标签噪声; 鲁棒学习; 疾病风险预测; 深度学习

引用格式: 郭雨茜,李华玲.基于标签噪声鲁棒学习的疾病风险预测.计算机系统应用,2023,32(10):184–191. http://www.c-s-a.org.cn/1003-3254/9268.html

Disease Risk Prediction Based on Label Noise Robust Learning

GUO Yu-Xi, LI Hua-Ling

(School of Software, North University of China, Taiyuan 030051, China)

Abstract: Disease risk prediction enables the screening of vulnerable populations and early preventive interventions to reduce disease incidence and mortality. With the rapid development of machine learning technologies, disease risk prediction based on machine learning has been widely used. However, machine learning is highly dependent on high-quality labeling information, and the label noise in medical data will bring severe challenges to the construction of high-performance disease risk prediction algorithms. In order to solve this problem, a noise robustness learning method based on a deep neural network and dynamic truncation loss function is proposed for disease risk prediction. The dynamic truncation loss function is introduced in this method, which combines the implicit weighting characteristics of the traditional cross entropy function and the label noise robustness of the mean square error loss function. By constructing a training loss lower bound and introducing a dynamic sample weighting mechanism to reduce the gradient of suspicious samples, the weight of possible noisy samples in the training process is limited, and the robustness of the model is further enhanced. By taking the stroke screening dataset as an example, the experimental results show that the proposed algorithm can achieve excellent prediction performance under each ratio of label noises, reduce the negative impact of label noises in disease risk prediction, and realize robust learning of data with label noises.

Key words: label noise; robust learning; disease risk prediction; deep learning

① 基金项目: 山西省重点研发计划 (202102020101009)
收稿时间: 2023-03-17; 修改时间: 2023-04-20; 采用时间: 2023-05-17; csa 在线出版时间: 2023-08-22
CNKI 网络首发时间: 2023-08-23

在医疗研究领域, 疾病风险预测是指预测具有某些特征的人群未来患有某种疾病的概率. 疾病风险预测有助于患者了解自身的发病风险, 并通过早期介入预防干预措施, 以降低疾病的发生率及死亡率[1]. 目前, 基于机器学习的疾病风险预测得到了广泛应用, 对临床疾病的管理与决策起到了积极的辅助作用[2]. 但是, 机器学习算法的性能很大程度上依赖于准确的标注信息. 由于医疗数据通常由医生进行人工标注, 在海量的医疗数据中不可避免地会存在错误的标注信息. 如果数据集标注信息的准确性过低, 机器学习算法的性能将受到严重影响[3].

错误的标注信息会导致机器学习算法的参考标签与真实信息存在偏差, 在模型训练过程中引入标签噪声[4]. 它通常由以下原因导致: (1) 标注者偏差, 由于各个医生的诊疗经验不同, 同一条医疗数据的标签可能存在偏差, 相似的医疗数据的标注信息可能存在较大差异; (2) 标注 (诊断) 过程中医学检测信息不够充足, 导致样本特征不足以描述相应标签[5]; (3) 待标记样本的可辨识度较低; (4) 医疗数据存储中数据编码或通信问题. 使用带有标签噪声的数据训练机器学习模型会导致其出现严重的性能退化, 无法取得理想的性能, 同时也会增加训练所需的样本数量和模型的复杂性[6]. 鉴于此, 许多学者针对标签噪声的处理开展了大量的研究工作, 主要包括基于样本隔离的方法[7–9], 基于损失函数的方法[10–12], 和样本重加权方法[13,14]. 样本隔离方法从有噪声的样本中筛选干净的样本, 使模型训练过程不受标签噪声的影响. 文献 [8] 发现在神经网络训练过程中, 网络会优先学习干净样本, 然后再拟合噪声样本, 因此, 研究人员以训练损失为准则, 通过筛选小损失的样本构造干净数据集实现抗标签噪声学习. 文献 [9] 认为多个网络具有不同的学习能力, 可以过滤不同类型的标签噪声. 因此他们提出一种基于 CNN 的 co-teaching 方法, 每个网络都选择一定数目的小损失样本进行学习, 并让他们互相指导对方的训练, 从而具备对标签噪声的鲁棒性. 基于损失函数的方法通过构造对称有界的损失函数提升模型对标签噪声的鲁棒性. 文献 [11] 提出一种对称的交叉熵损失函数, 通过引入反交叉熵函数构造对称性解决了交叉熵损失函数在有噪声标签数据集中学习不足和过拟合的现象. 文献 [12] 提出了泰勒交叉熵损失函数, 基于分类交叉熵损失的泰勒级数的阶数对训练标签的拟合程度进行加权, 提高了对标签噪声的鲁棒性. 样本重加权方法在训练过程中对样本分配不同的权重以调节他们的梯度, 通过降低潜在被污染样本的权重以缓和标签噪声对参数优化的影响. 文献 [13] 采用欧氏距离度量原始数据概率分布的密度以划分不同的区域, 进而根据区域设计相应的检测和过滤规则抑制标签噪声, 可以融合学习任务的先验知识进行局部化设计, 实现具有针对性的标签噪声过滤. 文献 [14] 通过无约束最小二乘重要性算法估计标签重要性, 结合自训练策略进行半监督训练, 实现样本重加权, 能够有效地抑制标签噪声对参数优化过程的影响, 取得较好的识别准确率. 尽管很多方法在图像识别取得了理想的性能, 但是针对疾病风险预测的标签噪声的相关工作却寥寥无几.

鉴于此, 本文提出了一种标签噪声鲁棒学习算法, 结合鲁棒损失函数和样本重加权方法的优势, 设计了一个非对称的有界损失函数提高对标签噪声的鲁棒性, 并在模型优化过程中动态地评估每个样本的权重, 进一步抑制标签噪声对疾病风险预测模型的影响. 本文的主要贡献如下.

(1) 提出了基于深度神经网络和动态截断损失函数的标签噪声鲁棒学习算法.

(2) 设计了一个动态的非对称有界截断损失函数, 融合了传统交叉熵函数的隐式加权特性和均方差损失函数的标签噪声鲁棒性, 通过限制损失下界增强模型的鲁棒性, 引入与样本相关的权重实现对可疑样本的动态隔离.

(3) 以真实的脑卒中筛查数据集为例, 验证了所提出算法的有效性和可行性.

本文第 1 节介绍了符号定义及问题描述. 第 2 节介绍了所用算法. 第 3 节介绍了实验过程及结果分析. 第 4 节对本文内容进行了总结.

1 符号定义及问题描述

1.1 符号定义

考虑给定数据集D, $D=\{X\in R^{n\times d_x}, \widetilde{Y}\in R^{n\times c}\}$, 其中$X$, $\widetilde{Y}$分别表示特征空间和带噪标签空间, n为样本数量, d_x, c分别为特征空间、标签空间的维度. 对于一个任意样本$x(i)\in X$, 它可以由一个索引i检索. 定义一个带噪标签$\widetilde{y}(i)\in\widetilde{Y}$, 它从类别$c_1$被错判为类别$c_2$的概率为$P_{c_1c_2}(x(i))$, 即$P_{c_1c_2}(x(i))=P(\widetilde{y}(i)=c_2|y(i)=c_1)$, 其中$y(i)$为真实标签. 定义标签噪声$\varepsilon$, 相应地, 带噪标签可

以描述为$y(i)=y(i)+\varepsilon(i)$.

根据标签噪声的统计性质, 可将其分为以下 4 类.

(1) 随机标签噪声. 受到随机标签噪声影响时, 带噪标签的生成过程是完全随机的, 标签错误与样本特征和真实标签均无关, 常见于人工误差引起的标注错误.

(2) 类相关标签噪声. 受到类相关标签噪声影响时, 标签错误仅与真实标签相关, 与样本特征无关.

(3) 样本相关标签噪声. 受到样本相关标签噪声影响时, 标签错误仅与样本特征相关, 与真实标签无关.

(4) 混合标签噪声. 受到混合标签噪声影响时, 标签错误不仅与样本特征相关, 也与真实标签相关.

由于医院和医疗机构采用统一的行业标准进行数据标注, 人工标注所带来的标签噪声通常可认定为随机的[15]. 因此, 本文针对随机标签噪声开展了相关研究, 带噪标签可表示为真实标签与标签噪声的和.

1.2 问题描述

由于不同医生的诊疗经验不同导致的主观性偏差、大量标注工作中的疏忽、数据编码或通信问题导致的标签错误等原因, 医疗数据中可能存在着较多的错误标注信息. 基于带有标签噪声的数据对机器学习模型进行训练和参数优化会使其预测性能急剧下降, 严重阻碍其大范围应用.

给定一个预测模型f, $x(i)$为测试样本, $\tilde{y}(i)$为带噪标签, $y(i)$为$x(i)$的真实标签, $f(x(i);D)$为训练集D上模型f在$x(i)$上的预测输出, 学习算法的期望预测为:

$$\overline{f}(x(i))=E_D[f(x(i);D)] \tag{1}$$

定义目标函数为L, 如式 (2) 所示:

$$L=\min E_D\left[(f(x(i);D)-\overline{f}(x(i)))^2\right] \tag{2}$$

进而, 泛化误差可以由式 (3) 表示:

$$\begin{aligned}E(f;D)=&\underbrace{E_D\left[\left(f(x(i);D)-\overline{f}(x(i))\right)^2\right]}_{bias^2(x(i))}\\&+\underbrace{E_D\left[\left(\overline{f}(x(i))-\tilde{y}(i)+\varepsilon(i)\right)^2\right]}_{var(x(i))}\\&+\underbrace{E_D\left(\varepsilon^2(i)\right)+2E_D\left[\left(\overline{f}(x(i))-\tilde{y}(i)+\varepsilon(i)\right)\varepsilon(i)\right]}_{\varepsilon^2(i)}\end{aligned} \tag{3}$$

其中, $bias^2(x(i))$表示偏差, $var(x(i))$表示方差, $\varepsilon^2(i)$表示噪声.

从式 (3) 可知, 标签噪声会显著提高方差和噪声, 进而提高模型泛化误差的下界, 导致模型的泛化性能显著下降.

2 标签噪声鲁棒学习算法

针对上述问题, 本文提出深度神经网络和动态截断损失函数相结合的标签噪声鲁棒学习算法. 主要策略是设计动态非对称有界的截断损失函数, 结合传统交叉熵函数的隐式加权特性和均方差损失函数的对称特性, 实现了带有标签噪声下的鲁棒性学习; 同时构造了训练损失下界, 并引入了样本动态加权机制有效隔离了带噪样本, 提高了模型对标签噪声的鲁棒性.

第 2.1 节介绍了模型结构, 第 2.2 节介绍了动态截断损失函数的相关内容, 第 2.3 节介绍了模型的实现过程.

2.1 模型结构

所提出算法的模型结构图如图 1 所示. 在模型训练过程中, 神经网络的输入为$x(i)$, 每一层设有权重θ和偏置b两个参数. w为样本权重参数, 其作用是动态评估样本被污染的概率, 因此w参数在图中的位置是独立于模型之外的. 对参数进行初始化后, 通过$y(i)=\theta x(i)+b$计算得到当前一层的输出值, 输出值经过激活函数计算后作为下一层的输入. 本文使用的激活函数为 ELU, 如式 (4) 所示:

$$f(x)=\begin{cases}x, & x\geqslant 0\\ \alpha(\mathrm{e}^x-1), & x<0\end{cases} \tag{4}$$

经过每一层的计算后, 得到最终的输出值. 通过误差反向传播的方式更新参数, 并使用动态截断损失函数实现对带噪标签的鲁棒性, 迭代到一定次数后, 模型训练完毕.

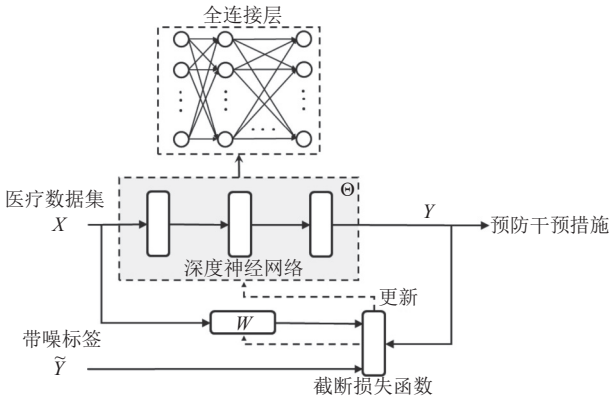

图 1 模型结构图

2.2 动态截断损失函数

在多分类问题中, 对于任意损失函数L, 分类器f的经验风险可以被定义为$R_L(f)=E_D[L(f(x(i)),y(i))]$. 以分类任务最常用的交叉熵损失函数为例, 相应的经验风险可由式 (5) 表示:

$$R_L(f)=E_D[L(f(x(i);\theta),y(i))]=-\frac{1}{n}\sum_{i=1}^{n}\sum_{j=1}^{c}y_{ij}\log f_j(x(i);\theta) \tag{5}$$

其中, θ为模型参数, y_{ij}为样本$x(i)$的第j个元素, 对于$y(i)=e_{y(i)}\in\{0,1\}^c$, 满足$1^Ty(i)=1\forall i$. f_j为模型预测的第j位元素, 由于输出层是一个 Softmax 层, 有$\sum_{j=1}^{n}f_j(x(i);\theta)=1$, 且满足$f_j(x(i);\theta)\geqslant 0,\forall j,i,\theta$. DNN 的参数可以通过经验风险最小化进行优化.

进而, 最小化经验风险可以由式 (6) 表示:

$$f^*=\arg\min R_L(f) \tag{6}$$

其中, f^*为无噪声下的全局最优分类器. 若f^*在一定的噪声比例下的经验风险为全局最优解时, 此时的损失函数对标签噪声具有鲁棒性.

若损失函数满足式 (7), 则此损失函数为对称损失函数:

$$\sum_{j=1}^{c}L(f(x(i)),j)=C,\ \forall x(i)\in X,\forall f \tag{7}$$

其中, X为特征空间, f为模型, C表示遍历所有类别的总损失和, 它是一个常数.

所有的样本都以同样的概率会错标成其他标签的情况, 被称为均匀噪声. 本文所研究的噪声类型属于均匀噪声. 噪声率$\eta_{c_1c_2}(x(i))$可表示为$\eta_{c_1c_2}(x(i))=p(\widetilde{y}_i=c_2|y_i=c_1,x(i))$, 本文假设噪声条件独立于给定真实标签的输入, 因此噪声率的公式可转化为式 (8):

$$p(\widetilde{y}_i=c_2|y_i=c_1,x(i))=p(\widetilde{y}_i=c_2|y_i=c_1)=\eta_{c_1c_2} \tag{8}$$

对于均匀噪声, 若损失函数是对称的且噪声比例满足$\eta_{c_1c_2}<\frac{c-1}{c},\forall c_1,c_2$, 则损失函数是具有噪声鲁棒性的[16].

传统的交叉熵 (cross entropy, CE) 损失函数是一类非有界非对称函数, 如式 (9) 所示:

$$L_{\mathrm{CE}}=-\sum_{i=1}^{n}y(i)\log\widehat{y}(i) \tag{9}$$

其中, n表示样本数, $y(i)$表示某个真实标签, $\widehat{y}(i)$表示对应的预测标签. 由于 CE 的非对称特性, 难以学习的样本的损失更大, 在正常情况下有助于模型的快速收敛, 但是受到标签噪声影响时, 被污染的样本会潜在得到更大的损失. 由于 CE 损失函数的非有界特性, 被污染样本的损失和干净样本的损失容易出现显著差异. 因此, CE 损失函数非常容易过拟合于标签噪声.

平均绝对误差 (mean absolute error, MAE) 损失函数的公式如式 (10) 所示:

$$L_{\mathrm{MAE}}=\frac{\sum_{i=1}^{n}|\widehat{y}(i)-y(i)|}{n} \tag{10}$$

其中, n表示样本数, $y(i)$表示某个真实标签, $\widehat{y}(i)$表示对应的预测标签. 由于 MAE 的对称特性, 每个样本的损失都是相同的, 在受到标签噪声影响时, 被污染样本的损失和干净样本的损失没有差异. 因此, MAE 损失函数对标签噪声具有鲁棒性.

接下来, 将从梯度的角度进一步分析 CE 和 MAE 损失函数的标签噪声鲁棒性. 它们的梯度如式 (11) 所示:

$$\sum_{i=1}^{n}\frac{\partial L(f(x(i);\theta),y(i))}{\partial\theta}=\begin{cases}\sum_{i=1}^{n}-\dfrac{1}{f_{y(i)}(x(i);\theta)}\nabla_\theta f_{y(i)}(x(i);\theta), & \mathrm{CE}\\ \sum_{i=1}^{n}-\nabla_\theta f_{y(i)}(x(i);\theta), & \mathrm{MAE}\end{cases} \tag{11}$$

在 CE 损失函数中, 若某些样本经过 Softmax 层输出的预测值和给定标签之间存在偏差, 则会导致$f_{y(i)}(x(i);\theta)$变小, 即$\frac{1}{f_{y(i)}(x(i);\theta)}$会增大. 在梯度更新的过程中, 由于这些样本的预测值和给定标签不一致, 此类样本会受到更多的关注, 因此拥有更多权重. 因此, 在使用 CE 损失函数训练时, 模型会更注重困难样本, 这种隐式加权方案对于使用干净数据进行训练是可取的, 但可能会导致对标签噪声的过拟合.

在 MAE 损失函数中, 梯度中并不存在$\frac{1}{f_{y(i)}(x(i);\theta)}$, 每个样本的权重一致, 这使其对噪声具有鲁棒性. 但是这可能会导致收敛时间显著增加. 此外, 没有隐式加权方案来关注困难样本, 训练过程中涉及的随机性可能会使学习变得困难, 导致分类准确率可能会受到影响.

为了利用 MAE 提供的噪声鲁棒性和 CE 的隐式加权方案的优点, 引入了L_q损失函数, 如式 (12) 所示:

$$L_q\left(f(x(i)),e_j\right)=\frac{(1-f_j(x(i))^q)}{q} \tag{12}$$

其中, q是取值在 0–1 之间的系数, 用以平衡损失函数的标签噪声鲁棒性和学习能力, 当q趋于 0 的时候, L_q退化为 CE 损失函数, 当q等于 1 时, L_q退化为 MAE 损失函数.

为了避免L_q损失函数的非对称特性导致被污染样本梯度过大, 提出了截断损失函数, 通过收紧模型损失的下界进一步改善标签噪声的鲁棒性, 如式 (13) 所示:

$$L_{\text{trunc}}\left(f(x(i)),e_j\right)=\begin{cases}L_q(k), & f_j(x(i))\leqslant k\\ L_q(f(x(i)),e_j), & f_j(x(i))>k\end{cases} \tag{13}$$

其中, k为阈值, 取值范围在 0–1 之间. 当k趋近于 0 时, 截断损失函数会变为L_q损失函数, 当k取值增大时, 可以限制样本的梯度不会过大.

引入样本动态加权机制后的动态截断损失函数如式 (14) 所示:

$$L_{\text{weight}}=\sum_{i=1}^{n}w(i)L_q(f(x(i);\theta),y(i))-L_q(k)\sum_{i=1}^{n}w(i) \tag{14}$$

其中, $w(i)$表示某个样本的权重, 可以在训练中控制疑似被污染的样本的比重. 在每个训练周期中, 将依据每个样本的训练损失对$w(i)$进行更新, 再对模型参数θ进行更新.

2.3 模型实现过程

针对所提出的疾病风险预测任务中的标签噪声鲁棒学习算法, 本节给出模型的具体实现过程, 涉及离线训练和在线预测两个部分. 离线训练方法如算法 1 所示, 在线预测方法如算法 2 所示.

算法 1. 离线训练方法

输入: 带噪训练集$D=\{x(i),y(i)\}_{i=1}^{N}$, 最大迭代次数$T$, 阈值$k$
输出: 最优模型参数θ^*

1) 初始化: 对于所有样本, $w(i)^{(0)}=1$
2) 根据下式更新模型参数θ:

$$\theta^{(0)}=\arg\min_\theta\sum_{i=1}^{n}w(i)^{(0)}L_q(f(x(i);\theta),y(i))-L_q(k)\sum_{i=1}^{n}w(i)^{(0)}$$

3) 当目前迭代次数小于最大迭代次数T时, 依次取出样本 $(x(i), y(i))$, 计算其预测类别$\hat{y}(i)$, 并根据下式更新样本权重w:

$$w^{(t)}=\arg\min_w\sum_{i=1}^{n}w(i)L_q\left(f\left(x(i);\theta^{(t-1)}\right),y(i)\right)-L_q(k)\sum_{i=1}^{n}w(i)$$

4) 根据下式更新模型参数θ:

$$\theta^{(t)}=\arg\min_\theta\sum_{i=1}^{n}w(i)^{(t)}L_q(f(x(i);\theta),y(i))-L_q(k)\sum_{i=1}^{n}w(i)^{(t)}$$

5) 输出最优模型参数θ^*

离线训练方法首先输入带噪训练集, 对参数进行初始化, 随后对模型进行训练, 最后更新模型参数, 输出最优的模型参数.

算法 2. 在线预测方法

输入: 医学数据集的批次数据$D_{\text{batch}}=\{x(i),y(i)\}_{i=1}^{N_{\text{batch}}}$
输出: 疾病风险等级$\hat{y}(i)$以及预防干预措施

1) 数据预处理
2) 计算模型输出$\hat{y}(i)$并预测人群类别
3) 根据预测类别给出预防干预措施

在线预测方法首先输入带噪训练集, 并对数据进行预处理, 然后计算预测类别, 最后根据预测类别给出相应的预防干预措施.

3 实验结果及分析

本节以脑卒中筛查数据集为例, 对所提出算法在不同标签噪声比例下的可行性和有效性进行了验证.

3.1 实验设置

3.1.1 实验数据集

实验数据集采用中国医学科学院医学信息研究所发布的脑卒中筛查数据集 (https://med.ckcest.cn/details.html?id=40545951025254 46&classesEn=scientific_data), 数据量总计 862 424 条, 覆盖了国内的 6 个省份, 41 家基地医院, 共有 16 个属性, 具体如表 1 所示.

表 1 数据集的属性

信息类型	所包含字段
基本信息	年龄、性别、民族、婚姻状况、职业、受教育程度、城乡类型、省份
生活习惯信息	吸烟、缺乏体育锻炼
疾病信息	高血压、房颤、血脂异常、糖尿病
家族史信息	脑卒中家族史
体格信息	体重明显超重

在数据集中, 将脑卒中风险划分为了以下 3 个等级: 第 1 级代表低危, 脑卒中风险较低, 低危人群相应的预防干预措施为正常体检. 第 2 级代表中危, 脑卒中风险较高, 中危人群需定期体检以及控制好相关危险因素. 第 3 级代表高危, 脑卒中风险极高, 需及时去医院进行进一步检查, 咨询专业医生的建议.

以上 3 个脑卒中风险等级在数据集中的占比情况如表 2 所示.

随机标签噪声通过人工注入, 实验中通过随机置换参考标签实现, 即选取一定比例的标签随机替换至其他类别, 噪声的比例范围是 5%–40%[17].

表 2 数据集的标签分布情况

脑卒中风险等级	数量	比例 (%)
低危	612 819	71.07
中危	124 103	14.39
高危	125 322	14.54

3.1.2 超参数设置

本文中所提出的 DNN 结合动态截断损失函数算法通过 Python 中的 PyTorch 和 Scikit-learn 实现, 所有实验均在配置 Windows 10 操作系统的计算机上实现, 具体硬件涉及: Intel i5 处理器, 8 GB 内存和 1 024 GB 存储空间. 实验相关的超参数设置如表 3 所示, 其余未提及参数均为默认值.

表 3 模型超参数

模块	参数	设置
模型	层大小	20
	激活函数	ELU
	q	0.7
	k	0.5
优化器	测试集比例	0.2
	优化算法	Adam
	批次大小	128
	学习率	1×10^{-4}
	学习周期数	20

3.1.3 实验对比算法

本节分别开展了无标签噪声下和有标签噪声下脑卒中风险预测的对比实验.

在无标签噪声的脑卒中风险预测实验中, 基准模型包括深度神经网络、决策树、随机森林、LightGBM、XGBoost、CatBoost. 深度神经网络在医疗预测领域有着广泛的应用[18]. 决策树算法在医疗分析与预测领域应用十分广泛[19]. 随机森林是一种高性能的疾病风险预测模型[20]. LightGBM 由于其准确率高、模型训练效率高而被广泛用于医疗领域[21]. XGBoost 已广泛应用于疾病诊断以及疾病发生风险等方面, 具有较高的效率和准确率[22]. CatBoost 不需要复杂的调优就可达到很强的预测效果, 能够较好地应用于医疗诊断领域[23].

在存在标签噪声的脑卒中风险预测实验中, 采用的对比算法有深度神经网络、LightGBM、XGBoost、CatBoost、DNN-Truncated、DNN-mixup. Mixup 是一类数据增强方法, 通过平滑特征和带噪标签降低被污染样本的梯度以抑制标签噪声的负面影响.

3.2 无标签噪声下的实验结果及分析

在无标签噪声的情况下, 采用决策树、随机森林、LightGBM、XGBoost、CatBoost 和深度神经网络进行对比实验. 实验结果如表 4 所示, 实验的评价指标包括准确率, 加权精确率, 加权召回率, 加权 $F1$ 分数和 Kappa 系数. 从表 4 的实验结果可以看出, 以上算法的准确率都超过了 94%, 均已达到实际应用的要求, 其中, 决策树和随机森林的性能指标相对欠佳, LightGBM、XGBoost、CatBoost 和 DNN 的性能指标更为突出, 准确率、加权精确率、加权召回率均超过了 98.70%, 加权 $F1$ 分数超过了 0.987 0, Kappa 系数超过了 0.971 0, 可以正确识别各类风险等级, 达到了良好的分类效果. 这可能是由于决策树未使用集成学习的方式, 单个树模型的预测能力相对较弱, 可能会受到异常值的影响. 而集成学习方式会参考多个决策树的结果, 降低了异常值带来的影响. 随机森林通过随机采样与随机选择特征构建多个决策树, 而 LightGBM、XGBoost、CatBoost 都是基于梯度提升的方式进行学习, 沿着梯度下降的方向减小损失函数, 可以得到更精确的模型. 根据以上的实验结果, 可以看出 LightGBM、XGBoost、CatBoost 和 DNN 算法都可以实现脑卒中早期预测, 后续将以这几种算法为基准模型开展进一步实验.

表 4 无标签噪声下的测试集准确率比较

算法	准确率 (%)	加权精确率 (%)	加权召回率 (%)	加权 $F1$ 分数	Kappa 系数
决策树	94.41	94.26	94.41	0.939 2	0.876 3
随机森林	96.19	96.12	96.19	0.959 3	0.915 4
LightGBM	98.75	98.89	98.75	0.987 8	0.973 4
XGBoost	98.73	98.87	98.73	0.987 6	0.972 9
CatBoost	98.73	98.87	98.73	0.987 5	0.972 8
DNN	98.70	98.81	98.70	0.987 2	0.971 6

3.3 有标签噪声下的实验结果及分析

本节评估所提出算法和各个基准模型的标签噪声鲁棒性, 在不同噪声比例下的识别准确率如表 5 所示.

表 5 不同噪声比例下的测试集准确率比较 (%)

算法	5	10	15	20	25	30	35	40
DNN	96.44	94.05	91.63	89.32	87.00	84.58	82.20	80.09
LightGBM	96.15	93.61	90.98	88.27	85.74	83.30	80.60	78.03
XGBoost	96.19	93.51	91.01	88.33	85.65	83.33	80.70	77.90
CatBoost	96.13	93.58	91.07	88.42	85.64	83.23	80.56	78.01
DNN-mixup	77.24	77.55	76.98	76.91	76.99	76.24	76.12	75.05
本文算法	96.00	96.00	96.00	96.00	96.00	96.00	96.00	96.00

从表 5 的实验结果可以看出, 本文所提出的动态截断损失函数的性能在不同比例的标签噪声影响下

均能保持稳定. 随着标签噪声比例的增加, DNN、LightGBM、XGBoost 和 CatBoost 算法的性能出现明显下降; 在 40% 的标签噪声影响下, 树模型的准确率低于 80%, DNN 模型的准确率为 80.09%, 难以实现准确的脑卒中早期风险预测. 本文所提出算法优于传统算法, 在不同的标签噪声比例下准确率一直保持稳定, 没有受到标签噪声的影响. 与表现最好的树模型相比, 本文算法在 10%–40% 的噪声比例下分别取得了 2.39%、4.93%、7.58%、10.26%、12.67%、15.3%、17.97% 的性能提升. 与 DNN 相比, 本文算法在 5% 的噪声比例下与其性能接近, 在 10%–40% 的噪声比例下分别取得了 1.95%、4.37%、6.68%、9%、11.42%、13.8%、15.91% 的性能提升. 这与L_q损失函数中结合了 MAE 的鲁棒性相关, 以及k取值有上下界, 使得损失函数的取值也有上下界, 影响了对标签噪声的鲁棒性.

Mixup 模型的性能稳定但是效果不理想, 其原因可能是对二元数据进行平滑无法产生可靠的样本, 难以降低标签噪声的影响.

3.4 超参数调节实验

为了分析所提出算法对超参数变化的敏感性, 本节进行超参数调节实验, 对q参数需要进行调节. 动态截断损失函数中q的取值会影响模型对标签噪声鲁棒性的强弱, 过高的q会导致损失函数逐渐趋近于 MAE 损失函数, 准确率变低; 过低的q会导致损失函数逐渐趋近于 CE 损失函数, 鲁棒性变差, 因此需要对q进行调节实验.

在噪声比例为 0、20% 和 40% 下分析了不同的q值对 $F1$ 分数和损失的影响. 从图 2 可以看出, q值的取值对 $F1$ 分数的影响不大, 但是会影响模型的收敛速度, 表明所提出算法对超参数的敏感性较弱, 易于部署.

同时, 从图 3 可以看出, q值的取值对测试损失的影响不大, 不同q值下的测试损失走势基本相同, 表明所提出算法对超参数的敏感性较弱, 易于部署.

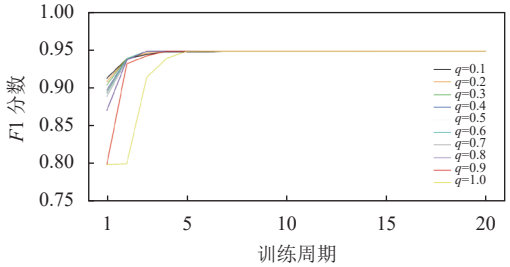

(a) 0 标签噪声比例

图 2 不同 q 值下的 $F1$ 分数

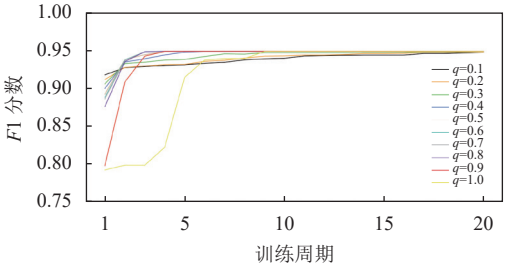

(b) 20% 标签噪声比例

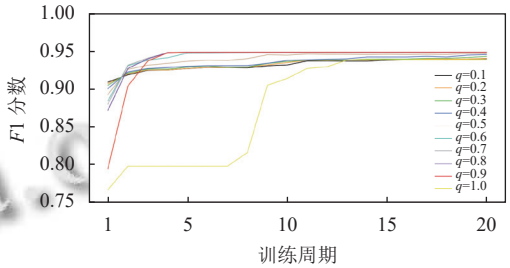

(c) 40% 标签噪声比例

图 2 不同 q 值下的 $F1$ 分数 (续)

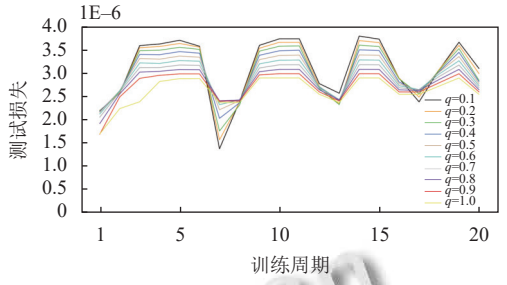

(a) 0 标签噪声比例

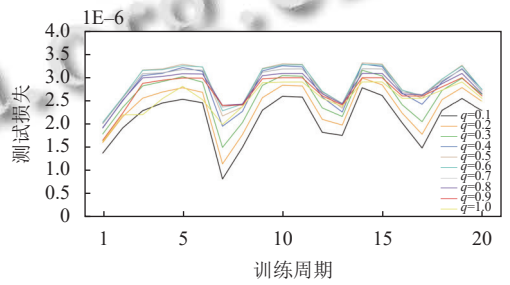

(b) 20% 标签噪声比例

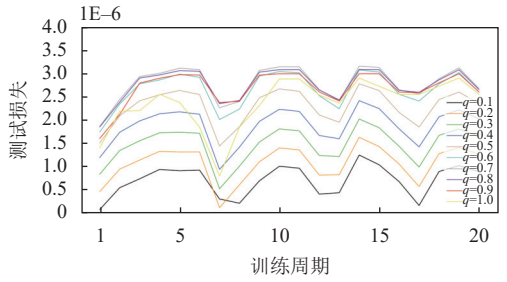

(c) 40% 标签噪声比例

图 3 不同q值下的测试损失

4 结论与展望

本文针对疾病风险预测中存在标签噪声的问题, 提出了一种基于深度神经网络和动态截断损失函数的标签噪声鲁棒学习算法. 设计了一个非对称有界的动态截断损失函数, 成功融合了传统交叉熵函数的隐式加权特性和均方差损失函数的对称特性; 构造了训练损失下界, 并引入了样本动态加权机制有效隔离了带噪样本, 提高了模型的标签噪声鲁棒性. 以脑卒中筛查数据集为例, 对本文所提出的算法进行了实验验证. 实验结果表明本文算法在各个噪声比例下都能取得理想性能, 验证了本文算法在存在标签噪声的疾病风险预测任务中的可行性和有效性.

未来将从以下两个方面继续研究: (1) 增加更多的医疗数据集进行实验验证. (2) 研究其他类型的标签噪声的特点以及处理方法, 提出有效的解决方案.

参考文献

1 张蕊, 郑黎强, 潘国伟. 疾病发病风险预测模型的应用与建立. 中国卫生统计, 2015, 32(4): 724–726.

2 刘雨安, 杨小文, 李乐之. 机器学习在疾病预测的应用研究进展. 护理学报, 2021, 28(7): 30–34.

3 王亚鹏, 李阳, 王家宝, 等. 噪声鲁棒的轻量级深度遥感场景图像分类检索. 中国图象图形学报, 2021, 26(12): 2991–3004. [doi: 10.11834/jig.200538]

4 佟强, 刁恩虎, 李丹, 等. 分类任务中标签噪声的研究综述. 科学技术与工程, 2022, 22(31): 13626–13635. [doi: 10.3969/j.issn.1671-1815.2022.31.003]

5 宫辰, 张闯, 王启舟. 标签噪声鲁棒学习算法研究综述. 航空兵器, 2020, 27(3): 20–26. [doi: 10.12132/ISSN.1673-5048.2020.0010]

6 王晓莉, 薛丽. 标签噪声学习算法综述. 计算机系统应用, 2021, 30(1): 10–18. [doi: 10.15888/j.cnki.csa.007776]

7 Wu PX, Zheng SZ, Goswami M, *et al*. A topological filter for learning with label noise. Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver: Curran Associates Inc, 2020. 1795.

8 Arpit D, Jastrzębski S, Ballas N, *et al*. A closer look at memorization in deep networks. Proceedings of the 34th International Conference on Machine Learning. Sydney: JMLR.org, 2017. 233–242.

9 Han B, Yao QM, Yu XR, *et al*. Co-teaching: Robust training of deep neural networks with extremely noisy labels. Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal: Curran Associates Inc., 2018. 8536–8546.

10 Rusiecki A. Trimmed robust loss function for training deep neural networks with label noise. Proceedings of the 18th International Conference on Artificial Intelligence and Soft Computing. Zakopane: Springer, 2019. 215–222.

11 Wang YS, Ma XJ, Chen ZY, *et al*. Symmetric cross entropy for robust learning with noisy labels. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 322–330.

12 Feng L, Shu SL, Lin ZY, *et al*. Can cross entropy loss be robust to label noise? Proceedings of the 29th International Joint Conference on Artificial Intelligence. 2021. 305.

13 陈庆强, 王文剑, 姜高霞. 基于数据分布的标签噪声过滤. 清华大学学报 (自然科学版), 2019, 59(4): 262–269. [doi: 10.16511/j.cnki.qhdxxb.2018.26.059]

14 陈倩, 杨旻, 魏鹏飞. 标签带噪声数据的重加权半监督分类方法. 烟台大学学报 (自然科学与工程版), 2019, 32(3): 205–209. [doi: 10.13951/j.cnki.37-1213/n.2019.03.001]

15 Karimi D, Dou HR, Warfield SK, *et al*. Deep learning with noisy labels: Exploring techniques and remedies in medical image analysis. Medical Image Analysis, 2020, 65: 101759. [doi: 10.1016/j.media.2020.101759]

16 Ghosh A, Manwani N, Sastry PS. Making risk minimization tolerant to label noise. Neurocomputing, 2015, 160: 93–107. [doi: 10.1016/j.neucom.2014.09.081]

17 Yao YY, Wang L, Zhang LM, *et al*. Learning latent stable patterns for image understanding with weak and noisy labels. IEEE Transactions on Cybernetics, 2019, 49(12): 4243–4252. [doi: 10.1109/TCYB.2018.2861419]

18 巨荣辉. 基于深度学习和医疗数据的疾病提前诊断和风险预测方法研究 [硕士学位论文]. 武汉: 华中科技大学, 2018.

19 王增辉. 决策树方法在医疗诊断及预测中的应用研究 [硕士学位论文]. 北京: 华北电力大学 (北京), 2019.

20 邰媛媛. 基于随机森林的 ICU 患者多重耐药菌感染预测模型的研究 [硕士学位论文]. 湖州: 湖州师范学院, 2022.

21 覃红键. 基于 LightGBM 算法的双高疾病风险预测系统设计与实现 [硕士学位论文]. 武汉: 中南财经政法大学, 2020.

22 齐巧娜, 刘艳, 陈霁晖, 等. 机器学习 XGBoost 算法在医学领域的应用研究进展. 分子影像学杂志, 2021, 44(5): 856–862.

23 苗丰顺, 李岩, 高岑, 等. 基于 CatBoost 算法的糖尿病预测方法. 计算机系统应用, 2019, 28(9): 215–218. [doi: 10.15888/j.cnki.csa.007054]

(校对责编: 牛欣悦)