

DOI:10.3969/j.issn.1003-5060.2023.11.021

基于代价敏感神经网络集成模型的 类别不平衡问题研究

张俊杰, 曹丽

(合肥工业大学 数学学院, 安徽 合肥 230601)

摘要:在解决类别不平衡问题的过程中,传统分类模型往往偏向对大类别样本的学习,影响模型分类效果。基于此,文章从数据采样、模型选择 2 方面入手,给出代价敏感神经网络集成(cost-sensitive neural network ensemble, CSNN_Ensemble)模型。首先通过随机下采样,得到多组训练数据集;其次对每组训练数据集训练 BP 神经网络,并结合代价矩阵构造多个代价敏感神经网络;最后以代价敏感神经网络为基学习器构造并行集成模型,并以投票的方式进行最终决策。实验结果表明,该模型在 F_1 值、AUC 值和期望总体代价 3 种性能方面表现优越,并具有一定的鲁棒性。

关键词:类别不平衡;随机下采样;代价敏感神经网络(CSNN);集成模型;Friedman 检验
中图分类号:TP181 **文献标志码:**A **文章编号:**1003-5060(2023)11-1573-07

Research on class imbalance problem based on cost-sensitive neural network ensemble model

ZHANG Junjie, CAO Li

(School of Mathematics, Hefei University of Technology, Hefei 230601, China)

Abstract: In the process of solving the problem of class imbalance, the traditional classification model tends to prefer the learning of large class samples, which affects the classification effect of the model. Based on this, from the aspects of data sampling and model selection, a cost-sensitive neural network ensemble (CSNN_Ensemble) model is proposed. Firstly, several training data sets are obtained by random under-sampling method. Secondly, back propagation (BP) neural networks are trained separately for each training data set, and several cost-sensitive neural networks are constructed by considering the cost matrix. Finally, the cost-sensitive neural networks are used to construct the parallel ensemble model, and the final decision of the model is made by voting. The results of the experiment show that the model has excellent performance in F_1 value, AUC value and expected total cost, and has good robustness.

Key words: class imbalance; random under-sampling; cost-sensitive neural network (CSNN); ensemble model; Friedman test

类别不平衡问题是指数据集的各个类别的样本数差异明显,即某些类别的样本数远小于其他类别的样本数。类别不平衡问题普遍存在于各个领域,如疾病检查、软件测试、病毒入侵、信用欺诈

等。传统的分类模型偏向对大类别样本的学习而忽略小类别样本的学习;但是在疾病诊断等领域,小类别样本通常才是关注的重点,因此类别不平衡数据问题成为数据挖掘领域热点问题之一。针

收稿日期:2022-03-09;修回日期:2022-03-18

基金项目:国家自然科学基金资助项目(41972304)

作者简介:张俊杰(1991—),男,河南开封人,合肥工业大学硕士生;

曹丽(1984—),女,江苏盱眙人,博士,合肥工业大学副教授,硕士生导师。

对该问题,目前常用的解决方法主要集中在数据采样、模型选择和性能评估等方面。

在数据采样方面,上采样和下采样是处理类别不平衡问题的常用方法。然而上采样容易增加噪声样本的比例,导致模型出现过拟合;下采样容易丢失重要样本,导致模型出现欠拟合。因此文献[1]对上采样方法进行了改进,提出 SMOTE 方法,但是该方法容易产生噪声样本,影响模型的性能。

在模型选择方面,解决类别不平衡问题常采用集成模型,如 SMOTEBoost 模型^[2]。该模型在每次迭代过程中通过 SMOTE 方法合成新小类别样本,改变样本类别分布,以增加再迭代时模型对小类别样本的学习次数。类似的集成模型还有 RUSBoost 模型^[3]和 CUSBoost 模型^[4]。但这些串行模型的训练样本选择与上一轮模型的学习效果直接相关,并非独立采样,一旦当前模型的误差小于阈值,则当前模型学习停止,容易导致早停,影响集成模型效果。还有学者从代价敏感的角度解决类别不平衡问题,解决方法大致可分为类依赖代价矩阵法和样本依赖代价矩阵法。类依赖代价矩阵法主要有代价敏感神经网络^[5]、Hard-Ensemble 模型^[5]和 Soft-Ensemble 模型^[5]。样本依赖代价矩阵法主要有样本依赖代价敏感学习决策树算法^[6]和样本依赖代价敏感学习 Adaboost 算法^[7]。

在性能评估方面,当大类别样本量远大于小类别样本量时,例如当类别比例为 1:99 时,若将全部样本判定为大类别样本,则准确率达到 99%,但是此时的准确率已无参考意义和评估价值。因此,在类别不平衡问题中通常使用如下的性能评估标准:精准率 P 、召回率 R 、 $P-R$ 曲线、 F_1 值以及 ROC 曲线等。文献[8]将 $P-R$ 曲线和 ROC 曲线做对比,在数据类别不平衡的条件下,ROC 曲线的性能评估优于 $P-R$ 曲线,但 ROC 曲线不能很好反映误分类代价情况。

针对上述问题,本文提出代价敏感神经网络集成(cost-sensitive neural network ensemble, CSNN-Ensemble)模型。首先通过多次随机下采样方式,每个基学习器学习不同的训练样本,防止样本丢失;其次考虑误分类代价,用代价敏感神经网络作为基学习器,实现更佳的性能;然后结合并行集成学习的思想,降低基学习器之间的关联性;最后通过 UCI 上 9 组二分类数据集进行几种集成模型的对比实验,结果表明该模型具有

一定的有效性和实用性。

1 代价敏感神经网络原理

代价敏感学习是根据不同误分类产生的不同代价,寻找使得模型的期望损失代价最小的机器学习方法;在代价敏感学习过程中,代价矩阵至关重要,决定着模型的性能。假设数据集共有 n 种类别,代价矩阵是由误分类代价所构成的矩阵,用 $(C_{i,j})_{n \times n}$ 表示代价矩阵,其中 $C_{i,j}$ 表示第 i 类误分为第 j 类的代价。特别地,规定 $C_{i,i}=0$ 。基于代价敏感原理,本文沿用文献[9]给定的代价矩阵的 3 种类型:

类型 1 存在唯一的 c ,当 $j=c$ 时,有 $C_{i,j}>h$,并且对所有 $j \neq i, C_{i,j \neq c}=h$;对 $j \neq c$ 和 $C_c=h$,定义 $C_i=C_{i,c}$ 。

类型 2 对所有 $j \neq i$,有 $C_{i,j}=h_i \geq 1.0$;定义 $C_i=h_i$ 。

类型 3 对所有 $j \neq i, C_{i,j} \geq 1.0$;定义 $C_i = \sum_{j=1}^n C_{i,j}$ 。

3 种类型中的 C_i 表示第 i 类代价。

代价敏感神经网络是在 BP 神经网络的基础上,通过阈值移动法,使输出层神经元的概率阈值偏向误分类代价低的类,进而降低误分类代价高的类的误分率。该方法保留了 BP 神经网络使用交叉熵损失函数的训练过程,而在结果输出部分引入代价矩阵,进行代价敏感化修正。具体来说,假设 O_i 表示普通神经网络输出层中属于第 i 类的真实概率, O_i' 表示代价敏感神经网络输出层中属于第 i 类的代价敏感概率。此时代价敏感神经网络输出结果为 $\arg\max_{i \in \{1, \dots, n\}} O_i'$, O_i' 的计算公式如下:

$$O_i' = \eta \sum_{j=1}^n O_i C_{i,j} \quad (1)$$

其中, η 为归一化参数。

2 代价敏感神经网络集成模型原理

集成学习的基本思想是将多个独立的、单一的基学习器按照某种结合策略有机地结合起来,从而获得更准确的预测模型。目前主要的集成学习范式有提升(Boosting)和装袋(Bagging)2 种。Boosting 集成范式采用串行模式,每轮训练集的选择与上一轮基学习器的学习效果相关,且基学习器以加权组合的方式构造集成模型。Bagging 集成范式采用并行模式,各个基学习器之间独立存在,模型相对简单,能提高稳定性差的基学习器

的预测精度。

本文采用 Bagging 集成范式构造代价敏感神经网络集成模型。首先对原始数据集中大类别样本 N 进行多次有放回的随机下采样,分别与小类别样本 M 合并,构造 m 个训练数据集;其次对每个训练数据集分别训练 BP 神经网络,引入代价矩阵 $(C_{i,j})_{n \times n}$ 后,构造 m 个代价敏感神经网络;最后对所构造出的 m 个代价敏感神经网络进行并行组合。CSNN-Ensemble 模型的算法流程如图 1 所示,算法步骤如下:

- 1) 输入小类别样本 M 、大类别样本 N 、基学习器数量 m 以及代价矩阵 $(C_{i,j})_{n \times n}$;
- 2) 使用有放回的独立随机下采样方法,从 N 中采样得到 m 个样本子集 N_k ,使 N_k 的样本量与 M 的样本量相等,且 $N_k \subset N, k=1,2,\dots,m$;
- 3) 将 m 个下采样子集 N_k 分别与 M 合并,训练出 m 个神经网络 H_k ;
- 4) 对每个 H_k ,分别引入代价矩阵,将其概率值与之相对应的误分为其他类的代价相乘并求和,归一化计算后得到代价敏感神经网络 H_k' ;
- 5) 输出集成模型 $H(x) = \text{sgn}(\sum_{k=1}^m H_k'(x))$ 。

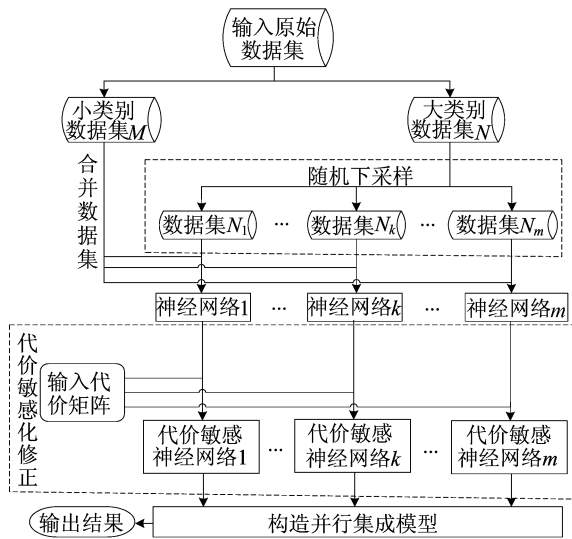


图 1 CSNN-Ensemble 模型的算法流程

CSNN-Ensemble 模型以代价敏感神经网络作为基学习器,模型相对简单、复杂度低,且采用并行组合策略,能够降低模型的方差,增加模型鲁棒性。

3 实证分析

3.1 性能评估方法介绍

对于分类问题,分类准确率常常作为最重要

的评价指标,但是在类别不平衡数据中,因为这种评价方法通常对大类别样本偏袒严重,而忽略对小类别样本的识别率,所以分类准确率对于类别不平衡数据往往不太合理。因此,本节将混淆矩阵介绍 F_1 值、ROC 曲线和代价曲线作为模型性能度量方法。混淆矩阵形式见表 1 所列。

表 1 混淆矩阵

指标	预测为正例	预测为负例
实际为正例	T_P	F_N
实际为负例	F_P	T_N

精准率 P 、召回率 R 和假正例率 R_{FP} 定义分别如下:

$$P = \frac{T_P}{T_P + F_P} \quad (2)$$

$$R = \frac{T_P}{T_P + F_N} \quad (3)$$

$$R_{FP} = \frac{F_P}{F_P + T_N} \quad (4)$$

其中,召回率也称为真正例率 R_{TP} 。

F_1 值计算公式如下:

$$F_1 = 2PR / (P + R) \quad (5)$$

ROC 曲线是以假正例率 R_{FP} 为横坐标、真正例率 R_{TP} 为纵坐标绘制而成。定义 ROC 曲线下方面积为 AUC 值,模型分类性能的优劣与 AUC 值的大小成正比。代价曲线是一种考虑了误分类代价的分类性能度量方法;它是以前例概率 $P_C(+)$ 为横轴,以归一化代价 N_{EC} 为纵轴绘制而成。 $P_C(+)$ 和 N_{EC} 定义如下:

$$P_C(+) = \frac{P(+|+)C(-|+)}{P(+|+)C(-|+) + P(-|+)C(+|-)} \quad (6)$$

$$N_{EC} = \frac{R_{FN}P(+|+)C(-|+) + R_{FP}P(-|+)C(+|-)}{P(+|+)C(-|+) + P(-|+)C(+|-)} \quad (7)$$

其中: $P(+)$ 、 $P(-)$ 分别为样本中正、负例的概率; $C(-|+)$ 为正例误判为负例的代价; $C(+|-)$ 为负例误判为正例的代价;假反例率 $R_{FN} = 1 - R_{TP}$ 。根据式(6)、式(7),将归一化代价化简为:

$$N_{EC} = (1 - R_{FP} - R_{TP})P_C(+) + R_{FP} \quad (8)$$

由式(8)可知,归一化代价和正例概率代价是一种线性关系,且 ROC 曲线上的每个点 (R_{FP}, R_{TP}) 对应一条归一化代价直线。连接归一化代价直线的最小值点所形成的曲线即为代价曲线。定义代价曲线下方的面积为期望总体代价,模型分类性能的优劣与期望总体代价的大小成反比。

3.2 实验结果分析

本文选出 UCI 数据集中 9 组二分类数据作测试验证,数据信息见表 2 所列。

数据集	样本量	属性	类别分布
Letter	20 000	16C	789/19 211
Credit	30 000	1B 23C	6 636/23 364
Balance	625	4C	49/576
ILPD	583	1B 9C	167/416
Heart	270	13C	120/150
Wpbc	198	30C	47/151
Wdbc	569	30C	212/357
South-German	1 000	20N	300/700
Messidor	1 151	3B 16C	540/611

注:B表示布尔型;C表示连续型;N表示整数型。

有个别数据集中含有多种类别样本,选择其中一个样本量少的类为小类别样本,其余类别合

并成大类别样本。

在二分类问题中,3 种代价矩阵类型没有区别,且都可以用第 3 种类型进行表示^[5],因此本文使用第 3 种类型代价矩阵训练 CSNN-Ensemble 模型,对数据标准化处理后作为输入数据进行模型验证。

在 9 组数据集中,分别将 GBDT 模型、Random-Forest 模型、Easy-Ensemble 模型、Bagging 模型、Adaboost 模型与 CSNN-Ensemble 模型做对比,并采用 10 折交叉验证方式验证模型的有效性。

其中:Easy-Ensemble 模型^[10]的基学习器为 Adaboost 模型;Bagging 模型的基学习器为 BP 神经网络模型;Adaboost 模型的基学习器为决策树模型。通过对比 6 种模型的 F_1 值、ROC 曲线和代价曲线完成性能评估。6 种模型的 ROC 曲线和代价曲线如图 2、图 3 所示; F_1 值、AUC 值和期望总体代价的 10 折交叉验证结果见表 3~表 5 所列。

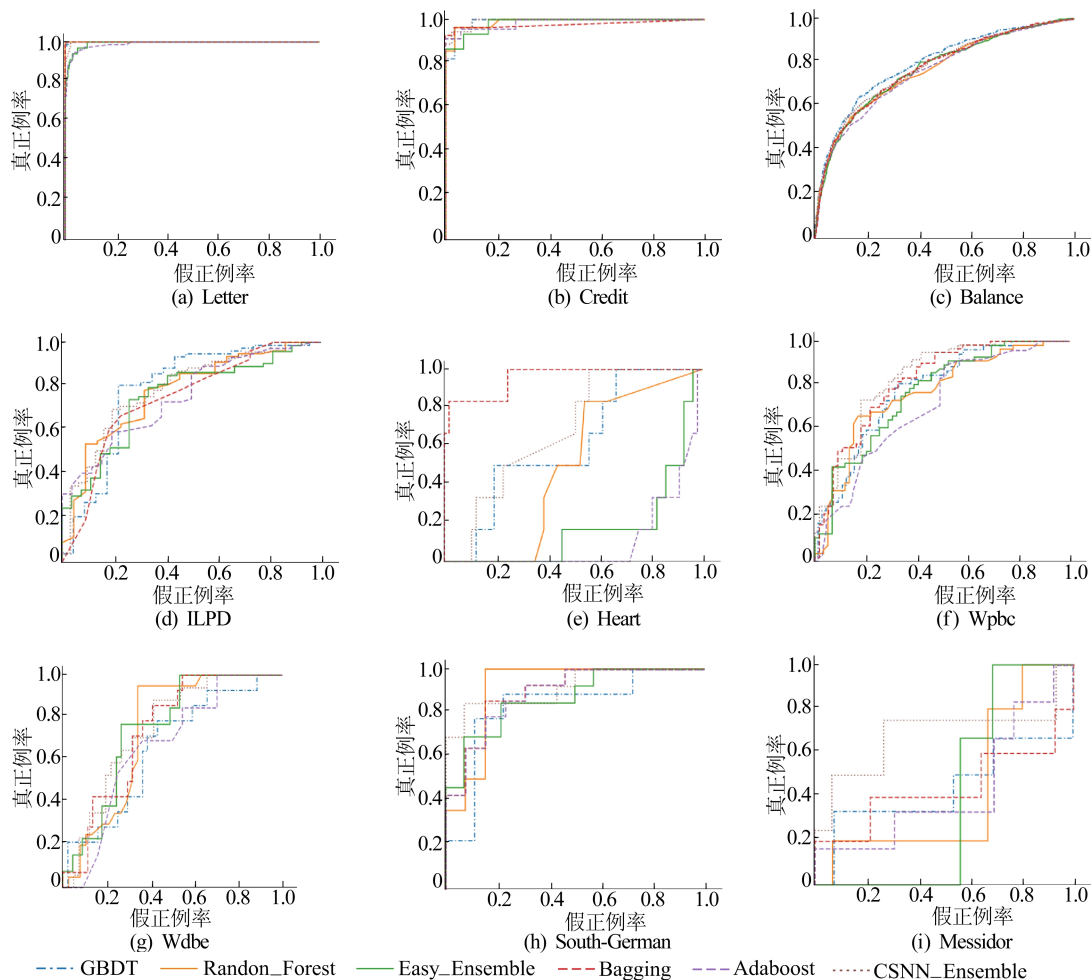


图 2 6 种模型在 9 组数据集中的 ROC 曲线

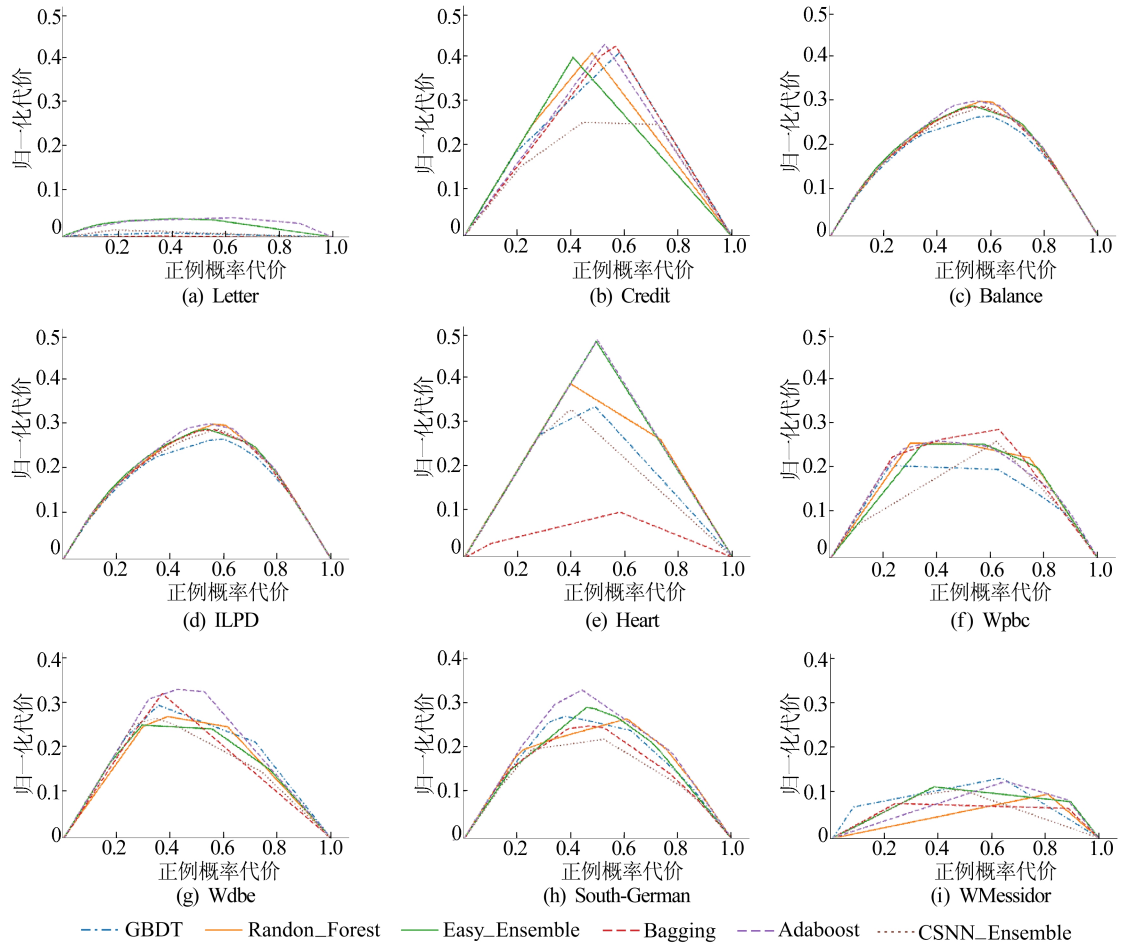


图 3 6 种模型在 9 组数据集集中的代价曲线

表 3 6 种模型在 9 组数据集集中的 F_1 值

数据集	GBDT	Random-Forest	Easy-Ensemble	Bagging	Adaboost	CSNN-Ensemble	均值
Letter	0.940±0.009	0.967±0.004	0.689±0.029	0.940±0.013	0.808±0.002	0.781±0.017	0.854±0.103
Credit	0.476±0.011	0.473±0.012	0.524±0.009	0.458±0.014	0.431±0.016	0.498±0.009	0.477±0.030
Balance	0±0	0±0	0.063±0.011	0±0	0±0	0.199±0.047	0.044±0.074
ILPD	0.319±0.058	0.353±0.050	0.541±0.038	0.157±0.086	0.413±0.070	0.554±0.032	0.390±0.138
Heart	0.776±0.084	0.785±0.066	0.797±0.044	0.782±0.094	0.796±0.062	0.797±0.052	0.789±0.008
Wpbc	0.137±0.099	0.062±0.089	0.315±0.137	0.289±0.168	0.230±0.140	0.417±0.108	0.242±0.118
Wdbc	0.951±0.027	0.947±0.026	0.938±0.030	0.935±0.032	0.933±0.021	0.959±0.021	0.944±0.009
South-German	0.848±0.018	0.839±0.021	0.767±0.045	0.806±0.023	0.824±0.023	0.837±0.019	0.820±0.028
Messidor	0.702±0.035	0.666±0.031	0.662±0.038	0.733±0.028	0.618±0.034	0.770±0.024	0.692±0.050

表 4 6 种模型在 9 组数据集集中的 AUC 值

数据集	GBDT	Random-Forest	Easy-Ensemble	Bagging	Adaboost	CSNN-Ensemble	均值
Letter	0.999±0	1.000±0	0.991±0.004	0.999±0	0.988±0.004	0.999±0	0.996±0.005
Credit	0.782±0.007	0.764±0.008	0.768±0.008	0.775±0.007	0.763±0.008	0.776±0.007	0.771±0.007
Balance	0.644±0.049	0.457±0.044	0.274±0.079	0.885±0.086	0.142±0.049	0.707±0.088	0.518±0.258
ILPD	0.711±0.051	0.735±0.049	0.738±0.022	0.733±0.034	0.732±0.057	0.738±0.028	0.731±0.009
Heart	0.864±0.053	0.906±0.027	0.890±0.031	0.898±0.042	0.894±0.040	0.908±0.038	0.893±0.015
Wpbc	0.544±0.127	0.546±0.137	0.521±0.127	0.589±0.120	0.581±0.107	0.673±0.068	0.576±0.050
Wdbc	0.993±0.006	0.990±0.007	0.988±0.009	0.982±0.099	0.985±0.011	0.994±0.007	0.989±0.004
South-German	0.783±0.019	0.778±0.027	0.766±0.049	0.751±0.038	0.752±0.035	0.783±0.036	0.769±0.014
Messidor	0.777±0.037	0.758±0.027	0.731±0.032	0.815±0.021	0.703±0.038	0.837±0.021	0.770±0.047

表 5 6 种模型在 9 组数据集中的期望总体代价

数据集	GBDT	Random-Forest	Easy-Ensemble	Bagging	Adaboost	CSNN-Ensemble	均值
Letter	0.006±0.001	0.001±0.001	0.026±0.005	0.006±0.003	0.033±0.007	0.007±0.002	0.016±0.014
Credit	0.185±0.003	0.192±0.004	0.191±0.003	0.187±0.003	0.192±0.004	0.188±0.003	0.190±0.003
Balance	0.170±0.014	0.227±0.014	0.240±0.010	0.075±0.033	0.249±0.001	0.152±0.023	0.186±0.062
ILPD	0.177±0.022	0.171±0.021	0.171±0.009	0.169±0.012	0.181±0.021	0.167±0.012	0.173±0.005
Heart	0.099±0.024	0.084±0.016	0.097±0.021	0.087±0.024	0.095±0.025	0.087±0.024	0.092±0.006
Wpbc	0.195±0.029	0.193±0.034	0.194±0.026	0.185±0.031	0.195±0.029	0.160±0.023	0.187±0.013
Wdbc	0.013±0.011	0.017±0.011	0.021±0.012	0.030±0.012	0.024±0.011	0.012±0.009	0.020±0.006
South-German	0.164±0.009	0.172±0.011	0.168±0.020	0.187±0.016	0.180±0.019	0.162±0.016	0.172±0.009
Messidor	0.164±0.013	0.179±0.011	0.188±0.010	0.154±0.009	0.199±0.008	0.143±0.011	0.173±0.019

实证结果表明,在处理类别不平衡数据问题时,Adaboost 模型在 9 组数据集中表现效果较差,而与之相比的其他 5 种模型都或多或少地表现出较强的分类性能。

F_1 值作为精准率和召回率的调和平均数, F_1 值越大,模型性能越优。从表 3 可以看出,在 F_1 值的平均值大于 0.8 的数据集中,GBDT 模型、Random-Forest 模型、CSNN-Ensemble 模型表现出相对较好的性能;而在 F_1 值的平均值小于 0.8 的数据集中,Easy-Ensemble 模型和 CSNN-Ensemble 模型的性能较优;这 2 种模型都是使用下采样方法进行数据处理,因此下采样处理类别不平衡问题是合理的。

从表 4 和表 5 可以看出,只有 Balance 数据集中 6 种集成模型结果相差较大,这可能是样本特征属性和样本量较少的原因。在 9 组数据集中,仅 CSNN-Ensemble 模型的 AUC 值和期望总体代价优于平均值。究其原因不难发现,该模型在基学习器中引入代价因子后,改变了分类阈值,使模型对样本的分类结果偏向于小类别样本。

为了进一步从整体上评价模型优劣,对 F_1 值、AUC 值、期望总体代价 3 种性能结果采用 Friedman 检验,检验结果见表 6 所列。

表 6 6 种模型在 3 种性能中的评价平均序值

模型	F_1 值	AUC 值	期望总体代价
GBDT	3.361	3.259	3.056
Random-Forest	3.472	3.222	3.278
Easy-Ensemble	3.222	4.111	4.000
Bagging	4.139	3.259	2.833
Adaboost	4.361	4.889	5.222
CSNN-Ensemble	1.889	1.593	1.722

从表 6 可以看出,CSNN-Ensemble 模型均获得了最低的平均序值。根据 3 种平均序值计算的 Friedman 检验值 τ_F 分别为 2.532、4.857、

6.098,均高于在显著性水平 $\alpha=0.05$ 下的临界值 2.449,于是拒绝“所有模型性能相同”的假设;因此 CSNN-Ensemble 模型优于其他模型。

4 结 论

在类别不平衡数据问题研究中,针对下采样方法导致的样本丢失和分类过程中存在误分类代价不等问题,本文结合代价敏感神经网络与并行集成思想,构造了 CSNN-Ensemble 模型。首先通过多次随机下采样,每个基学习器能学习不同的训练样本,防止样本丢失;然后在此基础上,构造以代价敏感神经网络为基学习器的并行集成模型,降低数据扰动对基学习器的影响。该模型以投票的方式进行决策,保证了所有基学习器的权重相同。实验结果表明 CSNN-Ensemble 模型有效提高了分类性能。然而,如何对基学习器采用加权组合的方式构造集成模型将是下一步的研究方向。

[参 考 文 献]

- [1] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16(1): 321-357.
- [2] CHAWLA N V, LAZAREVIC A, HALL L O, et al. SMOTEBoost: improving prediction of the minority class in boosting[J]. Lecture Notes in Computer Science, 2003, 2383(1): 107-119.
- [3] SEIFFERT C, KHOSHGOFTAAR T M, VAN HULSE J, et al. RUSBoost: a hybrid approach to alleviating class imbalance[J]. IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans, 2010, 40(1): 185-197.
- [4] RAYHAN F, AHMED S, MAHBUB A, et al. CUSBoost: cluster-based under-sampling with boosting for imbalanced classification[C]//2017 2nd International Conference on Computational Systems and Information Technology for Sustainable Solutions. [S. l.]: IEEE, 2017: 1-5.

- [5] ZHOU Z H, LIU X Y. Training cost-sensitive neural networks with methods addressing the class imbalance problem [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2006, 18(1): 63-77.
- [6] BAHNSEN A C, AOUADA D, OTTERSTEN B. Ensemble of example-dependent cost-sensitive decision trees [J]. *Expert Systems with Application*, 2015, 42(19): 6609-6619.
- [7] ZELENKOV Y. Example-dependent cost-sensitive adaptive boosting [J]. *Expert Systems with Application*, 2019, 135: 71-82.
- [8] DAVIS J, GOADRICH M. The relationship between precision-recall and ROC curves [C]//ICML'06: Proceedings of the 23rd International Conference on Machine Learning. New York: Association for Computing Machinery, 2006: 233-240.
- [9] TING K M. An instance-weighting method to induce cost-sensitive trees [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2002, 14(3): 659-665.
- [10] LIU X Y, WU J, ZHOU Z H. Exploratory under-sampling for class-imbalance learning [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2009, 39(2): 539-550.

(责任编辑 朱晓临)

(上接第 1531 页)

- [7] 陈玉美,舒张,张茂恒,等. 南京下蜀黄土记录的 250~150 ka 期间的环境演化信息 [J]. *地质科技情报*, 2014, 33(6): 55-59.
- [8] 任翌成,李徐生,韩志勇,等. 基于地磁场相对古强度变化的下蜀黄土年代序列及其古气候意义 [J]. *地球物理学报*, 2020, 63(5): 2024-2035.
- [9] HAO Q Z, GUO Z T, QIAO Y S, et al. Geochemical evidence for the provenance of middle Pleistocene loess deposits in southern China [J]. *Quaternary Science Reviews*, 2010, 29: 3317-3326.
- [10] 孟宝航,郑坤,银雪琴. 我国南方下蜀黄土的一些研究进展 [J]. *地质论评*, 2015, 61(增刊 1): 33-35.
- [11] 管后春,李运怀,刘道彬,等. 合肥盆地地下蜀黄土年龄及物源探讨 [J]. *中国地质*, 2015, 42(2): 664-675.
- [12] 凌超豪,张智,贾玉连,等. 元素地球化学揭示的长江中游鄱阳湖地区中更新世以来粉尘堆积的物源特征及其环境意义 [J]. *第四纪研究*, 2019, 39(5): 1103-1115.
- [13] 李徐生,韩志勇,杨守业,等. 镇江下蜀土剖面的化学风化强度与元素迁移特征 [J]. *地理学报*, 2007, 62(11): 1174-1184.
- [14] 李徐生,韩志勇,杨达源,等. 镇江下蜀黄土的稀土元素地球化学特征研究 [J]. *土壤学报*, 2006, 43(1): 1-7.
- [15] 杨守业,李从先,李徐生,等. 长江下游下蜀黄土化学风化的地球化学研究 [J]. *地球化学*, 2001, 30(4): 402-406.
- [16] 安徽省地质调查院. 1:5 万无为幅区域地质调查报告 [R]. 合肥:安徽省地质调查院, 2013.
- [17] 安徽省地质矿产局区域地质调查队. 安徽省地层志: 第四系分册 [M]. 合肥:安徽科学技术出版社, 1988: 36-42.
- [18] 安徽省地质调查院. 1:25 万合肥幅区域地质调查报告 [R]. 合肥:安徽省地质调查院, 2007.
- [19] LIANG M Y, GUO Z T, KAHMANN A J, et al. Geochemical characteristics of the Miocene eolian deposits in China: their provenance and climate implications [J]. *Geochemistry Geophysics Geosystems*, 2009, 10(4): Q04004.
- [20] 李楠,郝青振,张绪教,等. 东秦岭黄土物源的常量元素和微量元素地球化学证据 [J]. *第四纪研究*, 2016, 36(2): 332-346.
- [21] 曾方明. 九江下蜀黄土和红土的化学风化特征 [J]. *盐湖研究*, 2018, 26(1): 36-42.
- [22] 宋为娟. 合肥下蜀组的年代学研究 [D]. 北京:中国地质大学(北京), 2014.
- [23] RUDNICK R L, GAO S. Composition of the continental crust [M]//HOLLAND H D, TUREKIAN K K. *Treatise on Geochemistry*, Vol 3. [S. l.]: Elsevier Ltd., 2003: 1-64.
- [24] 路硕,尹功明,宋为娟,等. 合肥下蜀土地球化学特征及其古气候意义 [J]. *地质力学学报*, 2019, 25(3): 132-143.
- [25] SUN S S, MCDONOUGH W F. Chemical and isotopic systematics of oceanic basalts: implications for mantle composition and processes [J]. *Geological Society of London Special Publications*, 1989, 42(1): 313-345.
- [26] TAYLOR S R, MCLENNAN S M. The continental crust: its composition and evolution [M]. London: Blackwell, 1985: 78-84.
- [27] 冯连君,储雪蕾,张启锐,等. 化学蚀变指数(CIA)及其在新元古代碎屑岩中的应用 [J]. *地学前缘*, 2003, 10(4): 539-544.
- [28] 陈旻,陈骏,刘连文. 甘肃西峰晚第三纪红粘土的化学组成及化学风化特征 [J]. *地质力学学报*, 2001, 7(2): 73-81.
- [29] NESBITT H W, YOUNG G M. Early Proterozoic climates and plate motions inferred from major element chemistry of lutites [J]. *Nature*, 1982, 299: 715-717.
- [30] TAYLOR S R, MCLENNAN S M. The geochemical evolution of the continental crust [J]. *Reviews of Geophysics*, 1995, 33(2): 241-265.

(责任编辑 张淑艳)