

· 论著 ·

结合 SMOTE 技术与优化算法的支持向量机在慢性心衰不良结局预测中的应用*

李晓桐^{1,2} 程 璠³ 田 晶^{4,5} 闫晶晶³ 张岩波^{3,5,6△} 韩清华^{2,4△}

【摘要】 目的 应用优化算法的支持向量机(support vector machine, SVM)结合合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)预测慢性心衰患者不良结局,提高分类模型预测性能。方法 顺序入选 2014 年 1 月至 2017 年 12 月,山西省两所三级甲等医院心内科确诊为慢性心力衰竭的 1183 例住院患者,收集患者的病历资料。基于原始训练集构建 logistic 回归(logistic regression, LR)与支持向量机模型,同时结合 SMOTE 算法构建 LR、SVM、遗传算法支持向量机(genetic algorithm support vector machine, GA-SVM)和粒子群支持向量机模型(particle swarm support vector machine, PSO-SVM),通过灵敏度(sensitivity, SEN)、准确度(accuracy, ACC)、特异度(specificity, SPE)、*G*-means、*F*-measure、ROC 曲线下面积(area under receiver operating characteristic curve, AUC)等指标综合评价各模型的性能。结果 相较于对原始数据进行直接分类,应用 SMOTE 技术均衡化数据集后,模型性能明显提高。均衡化训练集构建 LR、SVM、GA-SVM 和 PSO-SVM 模型结果表明,GA-SVM 和 PSO-SVM 在 SPE、ACC 指标低于 LR; SEN、*G*-means、*F*-measure 和 AUC 均优于 LR。GA-SVM 和 PSO-SVM 的综合效果显著高于 SVM(SEN、*G*-means、*F*-measure 指标表现均优于 SVM)。结论 基于均衡化数据集构建 GA-SVM 或 PSO-SVM 模型可提高 SVM 对于心衰后的预测性能。

【关键词】 SMOTE 支持向量机 遗传算法优化 粒子群算法优化 慢性心力衰竭

【中图分类号】 R541.4 **【文献标识码】** A **DOI** 10.11783/j.issn.1002-3674.2024.06.001

Application of SMOTE Technique and Optimization Algorithm Support Vector Machine in Predicting Adverse Outcome of Chronic Heart Failure

Li Xiaotong, Cheng Fan, Tian Jing, et al (Department of Physiology, School of Basic Medicine, Shanxi Medical University, Taiyuan 030001)

【Abstract】 **Objective** Support vector machine(SVM) of optimization algorithm combined with SMOTE technique was used to predict the adverse outcome of patients with chronic heart failure and improve the prediction performance of classification model. **Methods** From January 2014 to December 2017, 1183 inpatients diagnosed with chronic heart failure in the cardiology department of two Third-class hospitals in Shanxi Province were enrolled in this study. The medical records of the patients were collected. Construct logistic regression(LR) and support vector machine model based on the original training set, and combine SMOTE algorithm to construct LR, SVM, genetic algorithm support vector machine(GA-SVM) and particle swarm support vector machine(PSO-SVM). The classification performance of each model was comprehensively evaluated by sensitivity(SEN), accuracy(ACC), specificity(SPE), *G*-means, *F*-measure, area under receiver operating characteristic curve(AUC) and other indicators. **Results** Compared with classifying the original data directly, SMOTE technique was applied to equalize the data set, and the model performance was significantly improved. The results of equalization training set to construct LR, SVM, GA-SVM and PSO-SVM models show that GA-SVM and PSO-SVM are lower than LR in SPE and ACC indicators, and SEN, *G*-means, *F*-measure and AUC are better than LR. The comprehensive effect of GA-SVM and PSO-SVM is significantly higher than that of SVM(SEN, *G*-means and *F*-measure are better than SVM). **Conclusion** The GA-SVM or PSO-SVM model based on the equalization dataset can improve the prediction performance of SVM for the prognosis of heart failure.

【Key words】 SMOTE; Support vector machine; Genetic algorithm optimization; Particle swarm optimization; Chronic heart failure

慢性心力衰竭(chronic heart failure, CHF)是心血管疾病的终末期表现和主要死亡原因^[1],全球有超过 6430 万心衰患者^[2]。疾病的严重性和复杂性以及院

外管理的缺失导致心衰患者预后差,再住院率和病死率高^[3]。准确的预后预测有助于制定治疗决策,改善心衰不良预后。机器学习技术的提出和发展有助于构建高性能的心衰预后评估模型^[4]。支持向量机(support vector machine, SVM)是一类按监督学习方式对数据进行二元分类的广义线性分类器,其决策边界是对学习样本求解的最大边距超平面^[5-8],擅长解决复杂的中小规模的非线性问题,近年来在医学研究中被广泛使用且表现良好^[9]。其中,SVM 的核函数类型选取与超参数的确定对拟合模型的效果影响较大。遗传算法(genetic algorithms, GA)和粒子群优化算法(par-

* 基金项目:国家自然科学基金项目(82103958);山西省卫生健康委员会资助项目(2021RC03)

1.山西医科大学基础医学院生理学系(030001)

2.山西医科大学细胞生理学教育部重点实验室

3.山西医科大学公共卫生学院流行病与卫生统计学教研室

4.山西医科大学第一医院心内科

5.重大疾病风险评估山西省重点实验室

6.山西中医药大学

△通信作者:韩清华, E-mail: syhqh@sohu.com;张岩波, E-mail: sx-mzyb@126.com

particle swarm optimization, PSO) 在 SVM 模型优化中表现出巨大潜力,能够提高模型的预测精度^[10-11]。机器学习算法中,结局事件属于“少数类事件”,在构建预后预测模型时标签变量的两个类别数量相差大,影响预测模型性能。合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)^[12]作为一种数据生成算法,被用来解决类别不平衡问题,可避免分类器过度拟合,改善预测偏倚,提高模型的性能。本研究使用 SVM、GA-SVM、PSO-SVM 和 logistic 模型对基于 SMOTE 技术均衡化数据进行拟合,比较各个模型的性能,更好的实现慢性心衰患者不良结局预测,提高模型的临床应用价值。

资料与方法

1. 数据来源

本研究收集了 2014—2017 年山西省心血管病医院和山西医科大学第一医院心内科确诊为慢性心力衰竭的 1183 例住院患者的病例信息。纳入排除标准参考课题组相关研究^[13],见表 1。收集患者首次住院的病历资料,包括:患者的一般情况(年龄、性别、吸烟史等),生命体征(身高、体重、心率、血压等),症状(心悸、胸憋、气促等),心衰病因(冠心病、瓣膜病等),合并症(心律失常、糖尿病、肾功能不全等),实验室检查指标(血常规、肝功能、肾功能等),辅助检查(心脏彩超、静态心电图、动态心电图等),治疗措施(药物治疗、手术治疗等)。其中相关检查指标为入院 24 h 内的检查指标,在临床医师的指导下进行双份数据核查录入,本文中不良结局为死亡,时间为住院期间。本课题组人员经由心内科临床医师进行专业培训。使用 EpiData 软件进行数据双录入,第三人核对录入信息,确保数据真实准确。

表 1 纳入排除标准

纳入标准	排除标准
年龄 ≥ 18 岁;	近 2 个月发生急性心血管事件;
有典型的 CHF 症状和/或体征;	并发其他危及生命的疾病,预期
纽约心脏协会(NYHA)心功能	生存时间 < 1 年;
分级 II ~ IV 级;	拒绝参加本项目的患者
近 1 个月接受心力衰竭药物及	
其他治疗措施的患者	

2. 统计学分析

(1) 统计描述与单因素分析

本研究对正态分布数值型变量采用均值±标准差进行统计描述,非正态分布数值型变量采用中位数(四分位数间距)进行描述。定性资料采用绝对值进行统计描述。采用 *t* 检验、卡方检验或秩和检验对数值型变量和分类变量进行组间差异分析,检验水准 $\alpha=0.05$ 。

(2) 预后模型构建方案

对原始数据进行随机划分,其中 1/2 为训练集,1/4 为验证集,1/4 为测试集。使用 logistic 和 SVM 对原始训练集进行拟合,基于原始测试集评价模型的预测效果。然后利用 SMOTE 技术合成少数类样本,使用 logistic、SVM、GA-SVM、PSO-SVM 对均衡化训练集进行拟合,通过均衡化的验证集数据对模型核函数参数 *g* 和惩罚参数 *c* 进行优化。基于均衡化的测试集分别评价模型的预测效果,并进行预测性能比较。

① 遗传算法优化支持向量机

GA-SVM 基于遗传算法,将遗传算法与支持向量机相结合,利用遗传算法优化 SVM 中与分类性能相关的参数 *g* 和 *c*。算法流程图如 1 所示。

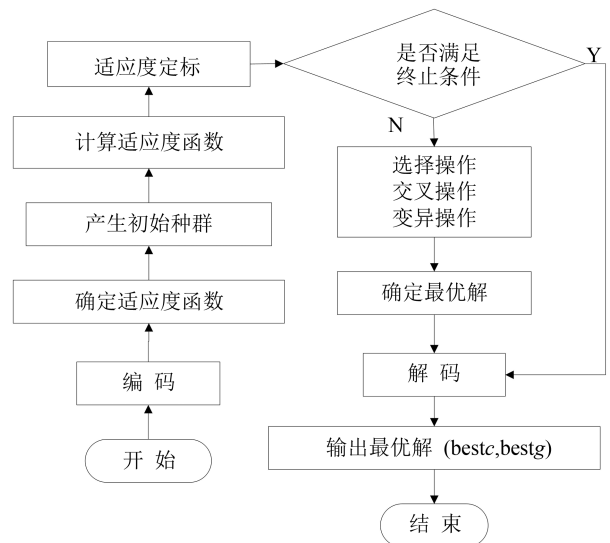


图 1 GA 优化 SVM 参数的算法流程图

② 粒子群算法优化支持向量机

PSO-SVM 从鸟群捕食的行为中得到启发,在解空间中初始化一群粒子。空间中每个粒子的位置对应一个问题的解。粒子通过更新自己的位置来寻找最优解。利用遗传算法优化 SVM 中与分类性能相关的参数 *g* 和 *c*,方法如图 2 所示。

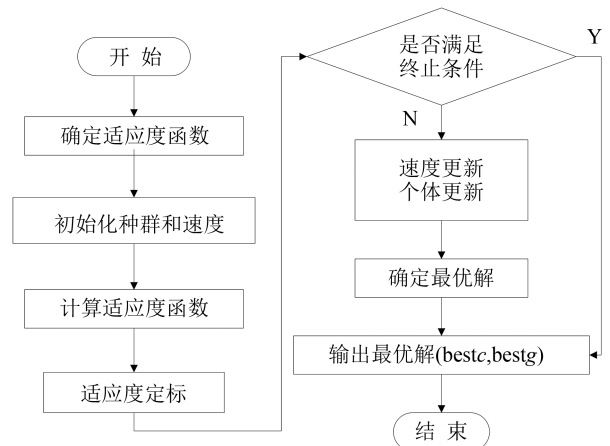


图 2 PSO 优化 SVM 参数的算法流程图

(3)模型评价

本研究中的数据为不平衡数据,对于不平衡数据的分类问题,常用的评价指标有灵敏度(sensitivity, SEN)、准确度(accuracy, ACC)、特异度(specificity, SPE)、G-means、F-measure、ROC 曲线下面积。

结 果

1.患者基本情况和单因素分析

本研究共纳入慢性心衰患者 1183 例,其中男性 791 例(66.9%),女性 392 例(33.1%),住院后

死亡患者 72 例,与存活患者比例为 1:15.43。以是否死亡分组,经单因素分析,最终 15 项指标纳入模型,结果见表 2 与表 3。

2.预后模型构建

结果如表 3 所示,多项式核函数中体现少数类识别率的指标灵敏度、AUC 和 G-means 分别为 0.333、0.642 和 0.570,相较于其他核函数较低,故排除。线性核函数的灵敏度和 G-means 与 Sigmoid 核和径向基核相近,而准确度、特异度、AUC 和 F-measure 值高于 Sigmoid 核和径向基核。因此,本研究选用线性核函数。

表 2 单因素分析结果

变量	死亡 $n(\%) / M(P_{75}-P_{25})$	存活 $n(\%) / M(P_{75}-P_{25})$	P
中性粒细胞绝对值($\times 10^9$)	4.97(2.71)	4.10(1.80)	<0.001
白细胞($\times 10^9$)	7.85(3.18)	6.50(2.30)	<0.001
血糖(mmol/L)	5.71(2.97)	5.25(1.76)	0.009
肌酐(umol/L)	88.40(55.78)	82.60(27.60)	0.009
尿酸(umol/L)	413.50(245.04)	394.00(117.00)	0.001
高密度脂蛋白胆固醇(mmol/ml)	0.90(0.27)	0.98(0.28)	0.001
NT-proBNP(ng/L)	4507.29(17818.54)	1127.00(2848.36)	<0.001
射血分数(%)	38.00(20.00)	49.00(20.00)	<0.001
QTC(ms)	450.00(61.00)	431.00(46.00)	<0.001
节段性室壁运动异常	58.00(9.10%)	582.00(90.90%)	<0.001
NYHA IV级	31.00(12.60%)	216.00(87.40%)	<0.001
低血压(<90 mmHg)	5.00(23.80%)	16.00(76.20%)	0.003
低血红蛋白(<110 g/L)	15.00(17.60%)	70.00(82.40%)	<0.001
低钠血症(<138 mmol/L)	29.00(10.40%)	249.00(89.60%)	0.001
慢性阻塞性肺疾病	29.00(17.70%)	135.00(82.30%)	<0.001

表 3 不同核函数类型的 SVM 模型的评价指标比较

评价指标	核函数类型[Median(Q_L, Q_U)]			
	多项式核	线性核	Sigmoid 核	径向基核
SEN	0.333(0.278,0.389)	0.611(0.500,0.667)	0.611(0.500,0.667)	0.611(0.556,0.667)
ACC	0.902(0.892,0.916)	0.807(0.787,0.835)	0.791(0.776,0.811)	0.780(0.760,0.804)
SPE	0.928(0.939,0.950)	0.826(0.799,0.846)	0.791(0.776,0.811)	0.788(0.773,0.815)
AUC	0.642(0.591,0.692)	0.710(0.663,0.751)	0.702(0.654,0.745)	0.707(0.675,0.742)
G-means	0.570(0.553,0.614)	0.696(0.659,0.730)	0.698(0.645,0.733)	0.695(0.658,0.723)
F-measure	0.305(0.271,0.364)	0.270(0.242,0.300)	0.258(0.232,0.289)	0.253(0.227,0.275)

同一均衡化验证集上 9 种不同 g 和 c 组合的平均预测效果见表 4。利用 5 折交叉验证,重复 10 次。结果显示,当 g 和 c 取值范围分别为 $[0.01, 50]$ 与 $[0.1, 100]$ 时,平均准确度最高。确定 g 和 c 的取值范围后,GA 本身参数仍设置为 $cv = 5, sizepop = 20, maxgen = 100, crossover = 0.4, mutation = 0.01$ 。采用 5 折交叉验证进行最佳参数搜索得到 c 为 87.707 和 g 为 1.107。详见图 3。

表 4 相同验证集中 GA 优化 SVM 参数的准确度比较

(g, c)	平均准确度 (%)	(g, c)	平均准确度 (%)
$([0.01, 10], [0.1, 10])$	88.84	$([0.01, 50], [0.1, 100])$	90.32
$([0.01, 10], [0.1, 50])$	89.41	$([0.01, 100], [0.1, 10])$	88.82
$([0.01, 100], [0.1, 50])$	89.09	$([0.01, 10], [0.1, 100])$	90.31
$([0.01, 100], [0.1, 100])$	90.18	$([0.01, 50], [0.1, 10])$	88.78
		$([0.01, 50], [0.1, 50])$	89.12

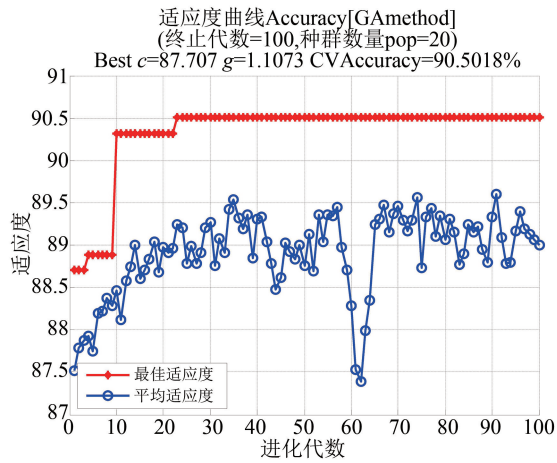


图3 基于GA参数寻优的适应度曲线

同样采用5折交叉验证,如表5所示, g 和 c 的最适取值范围分别为 $[0.01, 1]$ 与 $[0.1, 100]$ 。设置 $cv = 5$, $sizepop = 20$, $maxgen = 100$, $c1 = 1.5$, $c2 = 1.7$, $\omega = 1$,得到最佳参数 c 为100和 g 为0.965。图4表示PSO适应度曲线。

全部模型的预测结果如表6所示,经SMOTE算法处理后,训练集和验证集中的正负类样本数量达到均衡,分别为576:540和288:270。与原始数据集相比,经SMOTE处理后的数据集构建的logistic回归与SVM模型灵敏度超过55%,特异度虽下降,但综合评价指标AUC和G-means分别为0.690和0.695;0.678和0.689,相较于直接对原始数据分类,预测效果显著提高。在均衡化数据集中,GA-SVM和PSO-SVM各项指标中灵敏度、AUC、G-means与F-measure值分别为:0.667、

0.747、0.727与0.301;0.667、0.744、0.726与0.300,均优于logistic回归与SVM(0.556、0.690、0.678、0.301;0.556、0.695、0.689、0.271)。由此可知,基于参数优化的SVM分类预测性能优于SVM与传统logistic回归。其中经SMOTE处理后的训练集构建GA-SVM与PSO-SVM模型的预测性能最佳,且二者效果相当。

表5 相同验证集中PSO优化SVM参数的准确度比较

(g, c)	平均准确度 (%)	(g, c)	平均准确度 (%)
$([0.01, 1], [0.1, 10])$	88.55	$([0.01, 10], [0.1, 100])$	90.47
$([0.01, 1], [0.1, 50])$	89.43	$([0.01, 100], [0.1, 10])$	88.89
$([0.01, 1], [0.1, 100])$	90.50	$([0.01, 100], [0.1, 50])$	89.32
$([0.01, 10], [0.1, 10])$	88.89	$([0.01, 100], [0.1, 100])$	90.25
$([0.01, 10], [0.1, 50])$	89.62		




图4 基于PSO参数寻优的适应度曲线

表6 不同模型的评价指标比较

评价指标	SEN	ACC	SPE	AUC	G-means	F-measure
logistic 回归	0.222	0.943	0.993	0.594	0.469	0.320
SVM	0	0.939	1	0.496	0	NaN
SMOTE+logistic 回归 (Median(Q_L, Q_U))	0.556(0.444, 0.611)	0.850(0.831, 0.872)	0.869(0.849, 0.896)	0.690(0.649, 0.746)	0.678(0.634, 0.723)	0.301(0.265, 0.339)
SMOTE+SVM	0.556	0.809	0.824	0.695	0.689	0.271
SMOTE+GA-SVM (Median(Q_L, Q_U))	0.667(0.500, 0.720)	0.824(0.807, 0.838)	0.838(0.817, 0.853)	0.747(0.689, 0.775)	0.727(0.662, 0.773)	0.301(0.259, 0.338)
SMOTE+PSO-SVM (Median(Q_L, Q_U))	0.667(0.542, 0.722)	0.824(0.807, 0.838)	0.838(0.817, 0.850)	0.744(0.691, 0.775)	0.726(0.665, 0.773)	0.300(0.261, 0.333)

讨论

本研究采用SMOTE算法结合SVM及其优化算法模型预测CHF患者不良结局,有效解决了数据的类别不平衡问题。采用GA和PSO进行SVM的参数优化,既提高了SVM选择参数的效率和精度,又提高了模型的预测性能。在针对慢性心衰患者的病历资料进行建模和预测时,GA-SVM和PSO-SVM为处理此类数据提供了很好的解决思路。

建立心衰预后预测模型有助于对疾病进行早期干

预和治疗,然而数据的类别不平衡问题是其中的一大挑战^[14-15]。在基于原始数据集构建的模型中,灵敏度等指标偏低,特异度较高,说明模型对少数类样本的识别率远低于多数类样本。而经SMOTE算法均衡化的训练集构建logistic回归和SVM模型,虽然特异度下降,但灵敏度和综合评价指标如G-means和AUC均提升,说明用SMOTE算法均衡化训练集后,模型对两类样本的识别率趋于平衡,不再偏向于识别多数类样本。目前对不平衡的数据的处理方法主要集中在数据层和算法层^[16-17]。数据层的核心为重采样技术,包括

欠采样和过采样,过采样技术能够使样本信息得到很好的保留,因此被广泛应用^[18]。SMOTE 算法是目前较为常用的过采样技术,通过人工合成少数类样本使类别分布平衡,具有计算速度快,分类效果好的特点^[19-20]。因此,在处理不平衡数据时,可采用 SMOTE 算法。

从基于均衡化训练集构建的各模型来看,使用 GA 和 PSO 优化后各项指标均高于原始 SVM 模型。在 GA-SVM 与 PSO-SVM 模型中,灵敏度、AUC、G-means、F-measure 均高于传统 logistic 回归,而准确度和特异度与 logistic 回归相差不大。说明优化后的模型在提高少数类样本的分类能力的同时也保证了其对多数类样本的分类能力。Liang 等人^[21]在构建区分患者意识状态的模型中发现,GA-SVM 优于随机森林和神经网络。Wang 等人^[22]使用不同的数据集进行比较,结果表明 PSO-SVM 优于反向传播神经网络和高斯过程回归。传统 SVM 参数优化方法有网格法、实验法、梯度下降法^[23]等。然而这些算法由于存在多种问题已不能满足人们的需求。群智能算法在 SVM 优化方面的广泛运用进一步提高了 SVM 的预测精度^[24]。本研究通过遗传算法和粒子群算法对 SVM 线性核函数中参数 g 和 c 进行寻优,把最优参数值代入 SVM 模型中,得到 GA-SVM 和 PSO-SVM 模型,进一步提升了模型的预测效果。

但本次研究对象仅纳入山西省两所三甲医院的住院患者,存在选择偏倚。在今后的研究中可以考虑扩大研究对象的选择范围。

结 论

运用 SMOTE 算法均衡化数据集后,logistic 回归与 SVM 模型对两类样本的识别率均较高,尤其是对于少数类样本的识别率显著提高。使用 GA 和 PSO 对 SVM 模型进行优化后,模型的预测性能优于传统 logistic 回归与 SVM 模型。因此,基于 SMOTE 技术处理的数据集构建 GA-SVM 或 PSO-SVM 模型有利于处理不平衡数据,预测慢性心衰患者预后,为临床决策提供理论基础。

参 考 文 献

[1] 中国心衰中心联盟,苏州工业园区心血管健康研究院,中国心血管健康联盟.中国心衰中心工作报告(2021):心力衰竭患者的诊疗现状[J].中国介入心脏病学杂志,2022,30(5):328-336.
 [2] 杨浩杰,胡宇乐,周彦君,等.心力衰竭患者 30 天再住院现状及影响因素的研究进展[J].解放军护理杂志,2022,39(2):72-75.
 [3] 王华,李莹莹,柴珂,等.中国住院心力衰竭患者流行病学及治疗现状[J].中华心血管病杂志,2019,47(11):865-874.
 [4] Segar M, Hall J, Jhund P, et al. Machine Learning-Based Models Incorporating Social Determinants of Health vs Traditional Models for Predicting In-Hospital Mortality in Patients With Heart Failure[J].

JAMA Cardiol,2022,7(8):844-854.
 [5] Cortes C, Vapnik V. Support Vector Networks[J].Machine Learning,1995,20(3):273-297.
 [6] 周志华主编.机器学习[M].北京:清华大学出版社,2016:121-139,298-300.
 [7] 李航主编,统计学习方法[M].北京:清华大学出版社,2012:95-135.
 [8] 邢泽文.旅客同行社交网络关系预测研究[D].天津:中国民航大学,2020.
 [9] Kang M, Shin S, Zhang G, et al. Mental Stress Classification Based on a Support Vector Machine and Naive Bayes Using Electrocardiogram Signals[J].Sensors,2021,21(23):7916.
 [10] Andrade Cruz I, Chuenchart W, Long F, et al. Application of machine learning in anaerobic digestion: Perspectives and challenges [J]. Bioresour Technol,2022,345:126433.
 [11] Zhang P, Ma W, Wen F, et al. Estimating PM2.5 concentration using the machine learning GA-SVM method to improve the land use regression model in Shaanxi, China[J]. Ecotoxicol Environ Saf, 2021,225:112772.
 [12] Chawla NV, Bowyer KW, Hall LO, et al. SMOTE: Synthetic Minority Over-sampling Technique[J]. Journal of Artificial Intelligence Research,2002,16(1):321-357.
 [13] 田晶,赵晶华,张青,等.慢性心力衰竭患者满意度对预后的影响及其影响因素分析[J].中国药物与临床,2019,19(19):3269-3271.
 [14] Gu J, Pan JA, Lin H, et al.Characteristics, prognosis and treatment response in distinct phenogroups of heart failure with preserved ejection fraction[J]. Int J Cardiol,2021,323:148-154.
 [15] Pocock SJ, Ferreira JP, Gregson J, et al. Novel biomarker-driven prognostic models to predict morbidity and mortality in chronic heart failure: the EMPEROR-Reduced trial [J]. Eur Heart J, 2021, 42(43):4455-4464.
 [16] He H, Garcia EA. Learning from Imbalanced Data[J]. IEEE Transactions on Knowledge and Data Engineering,2009,21(9):1263-1284.
 [17] Rekha G, Tyagi AK, Sreenath N, et al. Class Imbalanced Data: Open Issues and Future Research Directions[C]. 2021 International Conference on Computer Communication and InformatiRes (ICC-CI), 2021.
 [18] 王超学,张涛,马春森,等.面向不平衡数据集的改进型 SMOTE 算法[J].计算机科学与探索,2014,8(6):727-734.
 [19] Fernandez A, Garcia S, Chawla NV, et al. SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary [J]. Journal of Artificial Intelligence Research, 2018, 61:863-905.
 [20] Fernandez A, Garcia S, Chawla NV, et al. Imbalanced data classification procedure based on SMOTE[J]. Total Quality Science,2020,5(2):64-71.
 [21] Liang Z, Shao S, Lv Z, et al. Constructing a Consciousness Meter Based on the Combination of Non-Linear Measurements and Genetic Algorithm-Based Support Vector Machine[J]. IEEE Trans Neural Syst Rehabil Eng,2020,28(2):399-408.
 [22] Wang L, Xue X, Zhao Z, et al. Finding the de-carbonization potentials in the transport sector: application of scenario analysis with a hybrid prediction model[J]. Environ Sci Pollut Res Int, 2020, 27(17):21762-21776.
 [23] Chapelle O, Vapnik V, Bousquet O, et al. Choosing Multiple Parameters for Support Vector Machines[J]. Machine Learning,2002,46(1):131-159.
 [24] 李素,袁志高,王聪,等.群智能算法优化支持向量机参数综述[J].智能系统学报,2018,13(1):70-84.

(责任编辑:邓妍)