

Journal of System Simulation

Volume 36 | Issue 7

Article 6

7-15-2024

Effective Position Intelligent Decision Method Based on Model Fusion and Generative Network

Liqiang Guo

Naval Submarine Academy, Qingdao 266199, China, javis019_ai@126.com

Liang Ma

Naval Submarine Academy, Qingdao 266199, China

Hui Zhang

Naval Submarine Academy, Qingdao 266199, China

Jing Yang

Naval Submarine Academy, Qingdao 266199, China

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Effective Position Intelligent Decision Method Based on Model Fusion and Generative Network

Abstract

Abstract: Military intelligence technology is currently the most dynamic frontier and the inevitable trend for the development of unmanned equipment in the future. Aiming at the dual requirements of reliability and real-time performance of unmanned platform autonomous decision-making in complex environments and the shortcomings of existing combat simulation technology based on rule reasoning in terms of dynamics and flexibility, a research method of principle analysis and experimental verification is adopted. Based on the shooting experiment dataset of an unmanned platform, the effective position recognition link of attack decision-making is transformed into a binary classification problem with imbalanced categories in the field of machine learning. The effective position intelligent decision-making model with high real-time performance and flexibility is constructed by using correlation analysis, feature engineering, and model fusion technology. Based on the imbalanced classification architecture of ICGANStacking, directional expansion of minority class samples is proposed to achieve data enhancement and model performance improvement. The experimental results show that the recall rate of the proposed method has increased by 4.1%, the accuracy by 0.4%, and the F1 value by 1.5%, and the AUC value reaches 90.9%, which can meet the real-time performance and reliability requirements of the unmanned platform in performing combat tasks.

Keywords

military intelligence, unmanned platform, model fusion, generative adversarial network, imbalance classification

Authors

Liqiang Guo, Liang Ma, Hui Zhang, Jing Yang, Lianfeng Li, and Yaqi Zhai

Recommended Citation

Guo Liqiang, Ma Liang, Zhang Hui, et al. Effective Position Intelligent Decision Method Based on Model Fusion and Generative Network[J]. Journal of System Simulation, 2024, 36(7): 1573-1585.

基于模型融合和生成网络的有效阵位智能决策方法

郭力强¹, 马亮¹, 张会¹, 杨静¹, 李连峰², 翟雅琪¹

(1. 海军潜艇学院, 山东 青岛 266199; 2. 中国人民解放军 32114 部队, 黑龙江 牡丹江 157000)

摘要: 军事智能技术是当前最具活力的前沿领域和未来无人装备发展的必然趋势。针对无人平台在复杂环境下自主决策可靠性和实时性的双重需求和现有基于规则推演的作战仿真技术在动态性和灵活性方面的不足, 采用原理分析与实验验证的研究方法, 在某型无人平台射击实验数据集的基础上, 围绕攻击决策的有效阵位识别环节, 将其转换为机器学习领域类别不平衡的二分类问题, 综合采用相关性分析、特征工程、模型融合技术构建高实时性和灵活性的有效阵位智能决策模型, 并提出基于 *ICGAN-Stacking* 不平衡分类架构对少数类样本进行定向扩充, 实现数据增强和模型性能提升。实验结果表明: 所提方法召回率提升了 4.1%、精确度提升了 0.4%、F1 值提升了 1.5%、AUC 值达到 90.9%, 能够满足无人平台执行作战任务实时性和可靠性需求。

关键词: 军事智能; 无人平台; 模型融合; 生成对抗网络; 不平衡分类

中图分类号: TP181 文献标志码: A 文章编号: 1004-731X(2024)07-1573-13

DOI: 10.16182/j.issn1004731x.joss.22-1265

引用格式: 郭力强, 马亮, 张会, 等. 基于模型融合和生成网络的有效阵位智能决策方法[J]. 系统仿真学报, 2024, 36(7): 1573-1585.

Reference format: Guo Liqiang, Ma Liang, Zhang Hui, et al. Effective Position Intelligent Decision Method Based on Model Fusion and Generative Network[J]. Journal of System Simulation, 2024, 36(7): 1573-1585.

Effective Position Intelligent Decision Method Based on Model Fusion and Generative Network

Guo Liqiang¹, Ma Liang¹, Zhang Hui¹, Yang Jing¹, Li Lianfeng², Zhai Yaqi¹

(1. Naval Submarine Academy, Qingdao 266199, China; 2. PLA 32114 Troops, Mudanjiang 157000, China)

Abstract: Military intelligence technology is currently the most dynamic frontier and the inevitable trend for the development of unmanned equipment in the future. Aiming at the dual requirements of reliability and real-time performance of unmanned platform autonomous decision-making in complex environments and the shortcomings of existing combat simulation technology based on rule reasoning in terms of dynamics and flexibility, a research method of principle analysis and experimental verification is adopted. Based on the shooting experiment dataset of an unmanned platform, the effective position recognition link of attack decision-making is transformed into a binary classification problem with imbalanced categories in the field of machine learning. The effective position intelligent decision-making model with high real-time performance and flexibility is constructed by using correlation analysis, feature engineering, and model fusion technology. Based on the imbalanced classification architecture of *ICGAN-Stacking*, directional expansion of minority class samples is proposed to achieve data enhancement and model performance improvement. The experimental results show that the recall rate of the proposed method has increased by 4.1%, the accuracy by 0.4%, and the F1 value by 1.5%, and the AUC value

收稿日期: 2022-10-24 修回日期: 2022-11-22

基金项目: 国家自然科学基金(62273352)

第一作者: 郭力强(1992-), 男, 硕士生, 研究方向为武器装备智能决策技术。E-mail: javis019_ai@126.com

reaches 90.9%, which can meet the real-time performance and reliability requirements of the unmanned platform in performing combat tasks.

Keywords: military intelligence; unmanned platform; model fusion; generative adversarial network; imbalance classification

0 引言

以空中无人机、地面无人车、水下无人潜航器为代表的无人平台已经成为现代军事装备体系中的重要力量，正在推动传统的作战形态和作战模式发生巨大变革。从作战概念看，无人集群化作战、跨域协同作战^[1-2]等新型作战样式相继提出；从作战任务看，无人平台任务领域开始由后勤保障向主攻主战方向扩展；从作战主体看，无人平台逐步代替部分有人平台成为决定战争胜负的关键力量。典型的代表包括“Valkyrie” UAV、“Manta” LDUUV、“Talon” UGV^[3]等。

与有人平台相比，无人平台在隐蔽性、灵活性、生产成本以及作战风险方面具有明显优势，在大多数情况会布放至未知战场执行高危任务。由于无人平台的任务行为需要依靠平台自主决策完成，这就要求其需要具备在复杂和不确定环境下自主可靠决策和高效执行任务的能力。传统战术行为决策主要采用基于规则推理或仿真实验，存在以下2点突出问题：①对战场环境存在的不确定性信息的处理能力不足，导致决策结果的准确性受到影响；②基于仿真实验的方法因“组合爆炸”问题，导致计算的时间和空间复杂度呈指数级增长，得到优化解所需时间较长，难以满足无人平台执行作战任务实时性和可靠性需求。

随着人工智能技术的发展，基于数据驱动的智能决策技术为上述问题的解决带来了新的思路。美国国防部在最新版《2017~2042美国无人系统综合路线图》^[4]中也将人工智能和机器学习作为提高无人系统自主性的首要支撑因素。在战术级智能决策方面，典型的研究成果是美国空战人工智能系统Alpha AI^[5]，其成功验证了利用机器学习的方法建立实时战术行为智能模型是有效可行的。因

此，本文以某型无人平台有效阵位决策为例，综合采用特征工程、集成学习、模型融合和生成对抗网络等技术，围绕实现无人平台从带有噪声的观测信息中进行快速精准有效阵位决策的智能方法展开研究。

1 数据相关性分析

1.1 实验数据集解读

实验数据集为某型无人平台射击实验采集数据，特征包括观测目标态势信息(存在误差噪声)、武器装备性能信息、设定射击诸元信息等18个字段，标签为武器攻击效果 H (实际打击结果)。定义 $H \in \{0, 1\}$ ，其中，0代表武器未能命中目标，当前阵位不是有效射击阵位，建议无人平台不采取攻击行为；1代表武器能够命中目标，当前阵位是有效射击阵位，建议无人平台按射击参数采取攻击行为。如表1和图1所示，实验数据集总共60 000条数据，正样本数量为13 855，负样本数量为46 145，正负样本比例为1:3.33，武器命中目标占比约为23.06%，具有一定的类别不平衡特点。

表1 实验数据集信息

Table 1 Experimental dataset information

| 样本数量 | 特征维度 | 正样本数 | 负样本数 | 不平衡比例 | 平均耗时 |
|--------|------|--------|--------|-------|------------|
| 60 000 | 18 | 13 855 | 46 145 | 3.33 | 2 min 26 s |

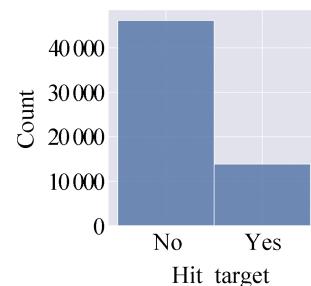


图1 标签取值分布情况柱状图
Fig. 1 Histogram of label distribution

1.2 皮尔逊相关系数计算

观测目标态势信息包括观测射击距离 D_g^- 、目标舷角 Q_m^- 、目标初始航速 V_{m0}^- 、目标规避航速 V_{m1}^- 、目标报警距离 A_m^- 、目标是否采取对抗 T_{bait}^- 字段; 武器装备性能信息包括使用武器型号 T_{type}^- 、武器初始航速 V_{w1}^- 、武器搜索航速 V_{w2}^- 、武器跟踪航速 V_{w3}^- 、武器有效航程 L_{pro}^- 、武器自导作用距离 d_s^- 字段; 设定射击诸元信息包括射击提前角系数 k 、展开航程系数 K 、射击展开散角 α 、解算鱼雷射击提前角 φ 、解算射击间隔 L_p^- 、解算展开航程 L_d^- 字段。

为探索标签在不同特征上的分布情况, 将离散型字段进行哑变量处理后计算特征与标签的皮尔逊相关系数^[6], 对其结果进行降序排序。

结合图2分析可知, 特征武器有效航程 L_{pro}^- 、自导作用距离 d_s^- 、目标不采取对抗 $T_{bait}^-=0$ 、展开航程系数 $K=0.7$ 与标签 H 表现出弱正相关性关系; 射距 D_g^- 、目标初始航速 V_{m1}^- 、展开航程系数 $K=1$ 、目标采取对抗 $T_{bait}^-=1$ 与标签 H 呈一定的负相关性趋势, 其余特征字段的影响并不明显。因此, 初步判断该数据集决策边界复杂程度高, 现有特征所包含的信息量不足, 有必要对数据关联度信息进行深入挖掘。

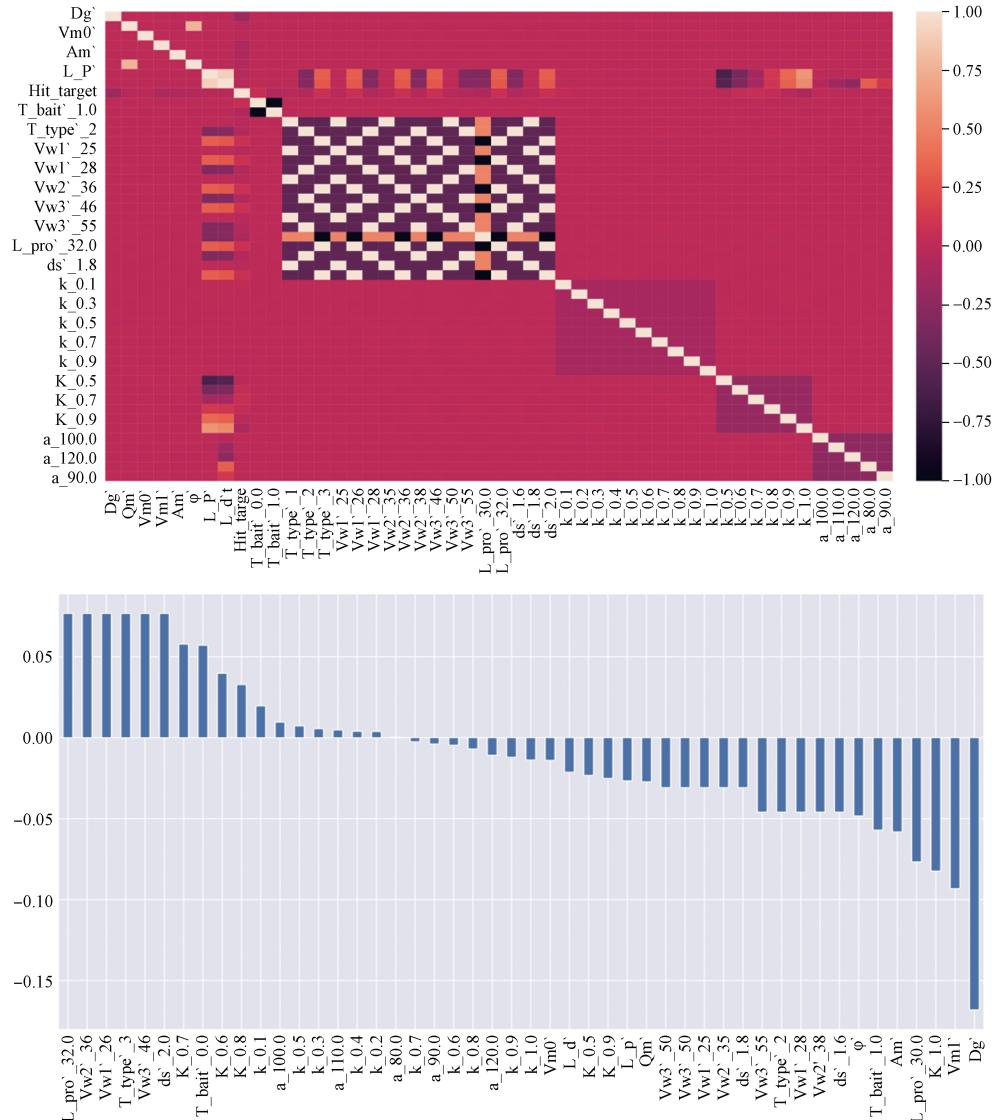


图2 特征与标签相关性分析图

Fig. 2 Analysis of feature and label correlation

<http://www.china-simulation.com>

1.3 基准模型与结果解释

为实现观测信息存在误差情况下有效阵位决策，机器学习建模目标有2个：①对有效阵位进行快速准确识别，②找出影响决策的重要特征，辅助无人平台进行占位策略调整或制定航路规划方案。因此，作为算法后续调优和提升的基准模型(baseline model)，不仅要达到一定的分类精度，同时还需要具备一定的可解释性，能够较为明显地表述特征是如何影响标签取值变化的。考虑到逻辑回归(logistic regression, LR)^[7]的线性方程能够通过自变量系数大小判断特征的重要性，决策树(decision tree, DT)^[8]可以根据建模过程树节点的分支规则对特征重要性进行直观的呈现，选择逻辑回归和决策树算法进行建模，并围绕模型最终输出结果进行结果解读。

按照7:3的比例将实验数据集随机划分为训练集和测试集，以AUC(area under the curve)^[7]作为超参数调优指标，使用5折交叉验证和网格搜索优化模型超参数，通过创建机器学习流^[9]的方式将数据重编码、模型训练、交叉验证、网格搜索过程进行封装。模型训练和测试结果如表2所示。

由表2可知，决策树模型的判别效力明显强于逻辑回归，说明仅依靠线性决策边界难以实现标签有效的判别。因此，针对该结构化数据的二分类问题，在模型选择上应以决策树模型为基础，

构建基于集成算法^[7]和模型融合技术^[7]的强学习器，并利用特征衍生的方法进一步提升数据集质量，从而提升最终模型的分类效能。

表2 基准模型训练结果

| 模型 | Table 2 Baseline model training results % | | | | |
|----|---|------|------|------|------|
| | 准确率 | 召回率 | 精确率 | F1 | AUC |
| LR | 训练集 61.5 | 62.3 | 32.6 | 42.8 | 67.0 |
| | 测试集 62.1 | 62.7 | 33.1 | 43.3 | 67.1 |
| DT | 训练集 81.5 | 48.8 | 62.9 | 54.9 | 80.8 |
| | 测试集 81.5 | 42.1 | 65.8 | 51.4 | 80.1 |

如图3所示，以柱状图的形式可视化展示逻辑回归方程自变量系数值对应的前10个正相关特征字段与后10个负相关特征字段，其中武器展开航程 L_d^- 、展开航程系数 $K=0.7$ 与标签 H 呈明显正相关，目标是否对抗 T_{bait}^- 、射距 D_g^- 、展开航程系数 $K=1$ 与标签 H 呈明显的负相关。

如图4所示，以树状图形式对决策树模型的样本分类规则进行直观的呈现。分析可知，目标舷角 Q_m^- 、射距 D_g^- 、展开航程系数 K 三个特征字段对标签 H 取值区分度的累计结果最大。

综合上述皮尔逊相关性系数指标和基于Baseline模型结果解释的方法对特征对标签的重要性进行分析，认为特征 D_g^- 、 Q_m^- 、 T_{bait}^- 、 T_{type}^- 、 K 与标签 H 关联度较高，后续将其作为关键特征进行工程化海量特征衍生。

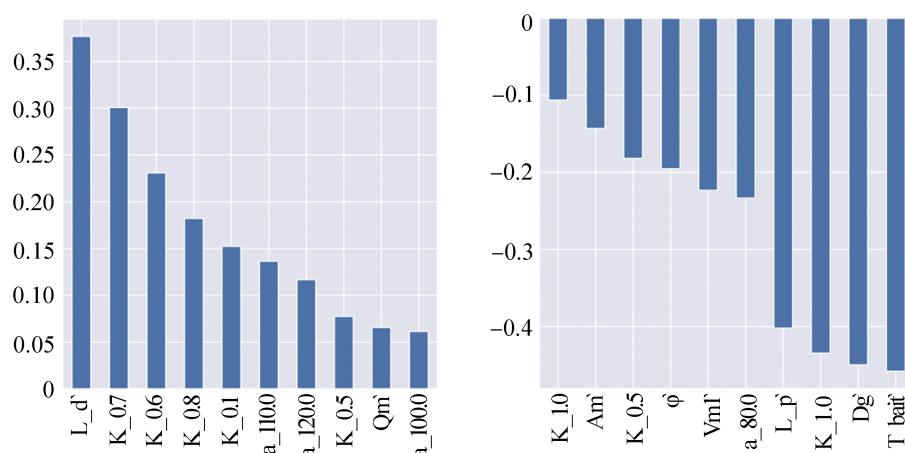


图3 逻辑回归模型自变量系数值柱状图
Fig. 3 Histogram of logistic regression model independent variable coefficient values

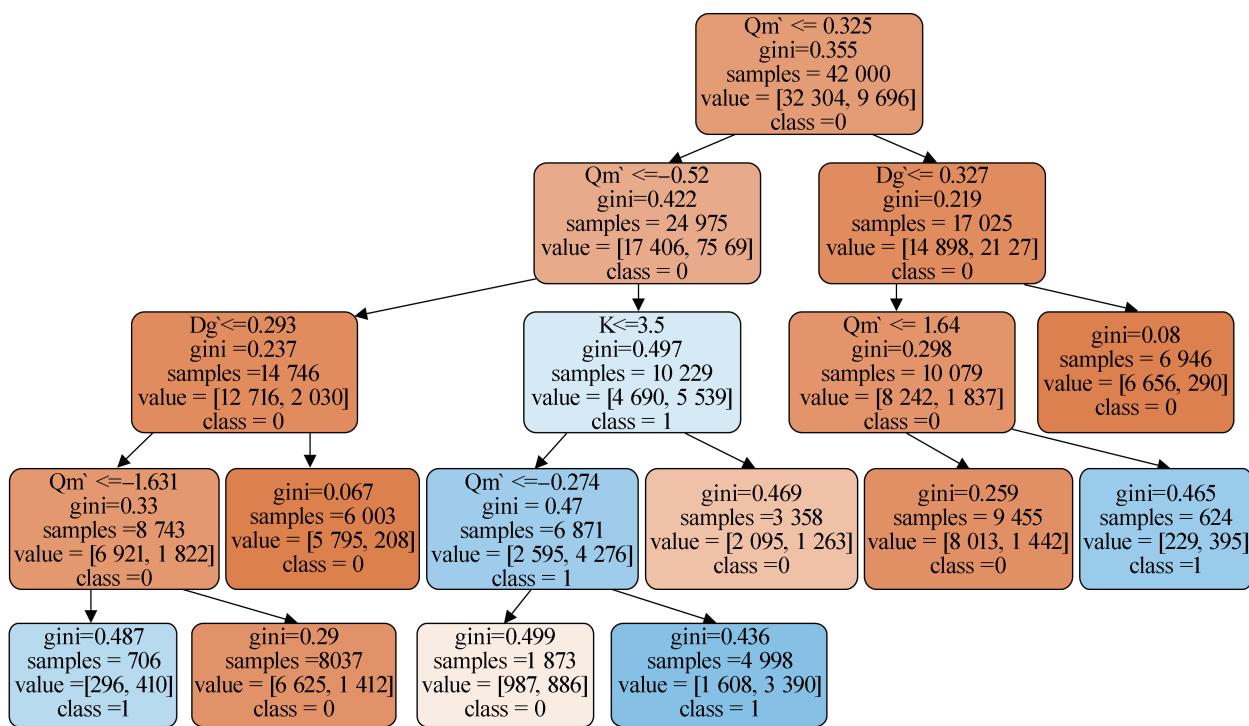


图4 决策树样本分类规则树状图

Fig. 4 Tree diagram of decision tree sample classification rule

2 理论概述

2.1 特征衍生与筛选

特征衍生利用既有数据进行新特征的创建，实现数据信息的重新排布，提供更多捕捉数据规律的维度以增强数据质量。总体来看，特征衍生有两类方法，一种是仅依据数据集特征的数据规律进行无监督的特征衍生，另外一种是将数据集标签情况也纳入考虑的有监督的特征衍生。在特征衍生完成后需要围绕创建特征综合运用方差过滤、方差分析^[10]、卡方检验^[10]和互信息法^[11]等混合策略进行特征筛选，剔除无效特征并挑选有效特征，从而提高模型整体训练效率与结果。

(1) 交叉组合特征衍生

交叉组合特征衍生的基本思想是将离散型字段在不同取值水平之间进行交叉组合，从而创建新字段。由于交叉组合后衍生的特征数量是参与交叉组合的特征字段取值水平之积，因此交叉组合特征衍生一般只适用于取值数量较少的离散型

字段，否则会导致衍生特征矩阵过于稀疏，从而无法为模型提供有效的训练信息。

(2) 多项式特征衍生

多项式特征衍生借鉴了支持向量机(support vector machine, SVM)^[12]核函数的思想，通过计算特征自身数据的阶次项和交叉项的方式创建新字段。通常情况下多项式特征衍生适用于连续型字段，同时伴随着阶数的增长还需要对衍生特征采用一定的预处理方法来消除数值绝对值爆炸或者衰减所造成的影响。

(3) 分组统计特征衍生

分组统计特征衍生的基本思想是先选择某个特征作为关键特征，然后以关键特征的不同取值作为分组依据并计算其他特征的统计量。通常选取离散型字段作为关键特征，统计量可以是均值、方差、偏度、峰度等针对连续变量的统计指标，也可以是中位数、众数、分位数等针对离散变量的统计指标。同时可以将标签在特征上的分组统计结果作为新创建特征，借助K折交叉验证执行

目标编码。另外，在上述分组统计结果的基础上还可以进一步围绕关键特征和衍生特征采用四则运算或组内归一化的方法再次进行特征衍生。

2.2 模型融合

模型融合是一种通过训练多个强评估器，并以某种规则将其融合起来的集成技术，能够在集成模型的基础上进一步提高分类精度。模型融合的本质思想是通过拓展模型的假设空间，降低算法陷入局部最优解的风险，从而提升模型整体的泛化能力。在分类任务中，常用的模型融合方法有投票法(Voting)、堆叠法(Stacking)和混合法(Blending)。

(1) Voting

投票法 Voting 是根据少数服从多数的规则进行融合结果输出，其中基于分类标签类别的投票法被称为硬投票(hard voting)，基于给定阈值下预测概率均值的投票法被称为软投票(soft voting)。在上述投票方法的基础上，还可以通过加权融合的方式，借助交叉验证和优化器进一步拓展 Voting 的性能提升空间。从理论上讲，在保证基学习器相互独立的情况下，当基学习器分类准确率普遍达到 80% 左右时，Voting 准确率约有 15% 的提升^[13]。此时，每个分类器的最佳权重系数为 $w_i = \log(p_i / 1 - p_i)$ ，其中， p_i 为第个 i 分类器的分类精度。

(2) Stacking & Blending

Stacking 是由 Wolper^[14]提出的一种包含多层学习结构的并行模型融合策略，其中第一层的学习器称为基学习器，第二层学习器称为元学习器。Stacking 通过组合同质或异质的基学习器的方式来增强多样性，以原始特征作为第一层基学习器的输入，将输出的预测结果作为次级元学习器的输入特征，最终由元学习器输出最终预测结果。

在给定原始数据集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ 上，Stacking 的交叉训练流程可以分为以

以下几个阶段：

- 1) 将原始数据集分割为训练集 D_{train} 和测试集 D_{test} 。假设基学习器层包含 K 个基学习器， $K=1, 2, \dots, k$ ，可将 D_{train} 等分为 K 份，记作 $D_1 \sim D_k$ 。
- 2) 依次取 $D_1 \sim D_k$ 作为各基学习器的验证集，余下子数据集作为各基学习器的训练集。经 K -fold 交叉验证后，将所有基学习器交叉验证的结果纵向堆叠形成预测集 $Z = \{z_1, z_2, \dots, z_k\}$ 。
- 3) 使用全部训练集 D_{train} 对所有基学习器进行训练，为模型测试做准备。

- 4) 将所有基学习器的预测集 Z 横向拼接，形成新特征矩阵，与原训练集 D_{train} 标签合并成新数据集 D_{new} ，并放入元学习器进行训练。

由 Stacking 训练过程可知：为防止数据的重复学习，Stacking 元学习器的训练数据并不是直接由基学习器的训练集构成，而是采用内部交叉训练的机制，这样各基学习器在训练时都保留了一份子集作为预测集，并将 k 个预测集的结果合并为元学习器的输入特征。如图 5 所示，通过这种内部交叉训练的方式实现数据从输入到输出的转化，提高了验证集结果的可信度，同时采用训练元学习器的方式来融合基学习器结果，使得融合模型朝损失函数最小化的方向进行训练，减小加权融合过程带来的模型过拟合风险，但同时也增大了融合模型训练的复杂度和运算成本。

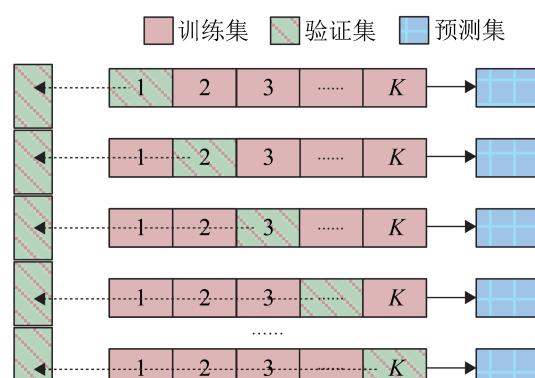


图 5 Stacking 内部 K -折交叉训练过程
Fig. 5 Stacking internal K -fold cross training process

Blending在Stacking的基础上,通过将训练集提前划分成训练集和验证集的方式,将基学习器层验证集的预测结果直接输入元学习器层,改进了Stacking内部交叉训练操作,大幅度降低了模型训练的运算量。但是由于人为减少了训练数据使用量,可能会带来一定的过拟合风险。

(3) 多粒度级联森林

多粒度级联森林gcForest是一种以树模型为基础构件的深度集成算法,主要由多粒度扫描(multi-grained scanning)和级联森林结构(cascade forest)两个部分组成。在特征处理阶段,借鉴了卷积神经网络(convolutional neural network, CNN)^[15]滑动卷积核进行特征提取的思想,通过多粒度扫描使用滑动窗口实现原始数据特征的增强。在模型训练阶段,以完全随机森林和随机森林为模块组成级联层,将增强特征与原始特征串联作为下一级联层模型的训练数据,并采用Stacking策略构建逐层训练的级联森林结构。因此,基于非微基学习器的gcForest算法对结构化数据具有良好的表征学习能力,具有超参数少、分类速度快、准确率较高的特点^[16]。

2.3 生成对抗网络

生成对抗网络(generative adversarial networks, GAN)^[17]是近年来深度学习技术在数据生成领域所取得的一个突破,该模型由Goodfellow等利用生成模型和判别网络模型在“博弈”中达到最优化的思想来构建的无监督学习模型。在GAN之前,传统的变分自编码器^[18]等深度生成式模型通常以最小化真实与生成样本的绝对误差作为其优化目标,在此种优化目标的驱动下,模型对于样本的生成会过于注重真实性,往往不能保证生成样本的多样性。在GAN中,生成器本身并不与实际数据产生接触,而是通过判别器的指导,进行自身网络参数的更新,以实现生成数据到真实数据分布的逼近,这种机制使得GAN的生成数据在满足真实性的基础上还保持着多样性特征。

GAN包含生成器G与判别器D两个基础网络。生成器G建立一个从服从任意分布 P_{noise} 的噪声 z 到合成样本 $G(z)$ 的变换映射,判别器D建立一个从真实样本或合成样本到其被判别为真或假概率的[0,1]区间映射。生成器的任务是学习真实样本 x 的分布,生成符合该样本分布 P_{data} 的合成样本 $G(z)$,以达到迷惑判别器的目的,而判别器D的任务是尽量识别出输入是来源于真实样本 x 还是合成样本 $G(z)$,先通过学习真实样本标签来更新自身参数,再通过输出结果对生成器G进行参数调整。

如图6所示,GAN通过生成器与判别器网络的交替对抗训练使得两个网络参数不断地得到优化,当两个网络达到纳什均衡状态时,模型的训练完成。理想状态下,此时生成器G输出满足 P_{data} 分布,判别器D无法对 $G(z)$ 与真实样本 x 做出识别。

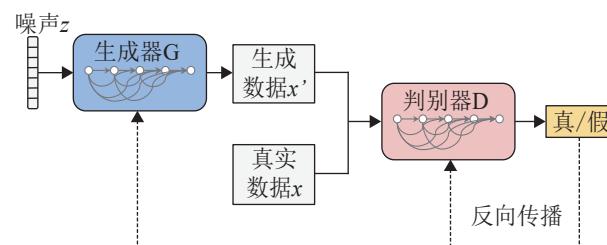


图6 GAN模型结构
Fig. 6 GAN model structure

文献[19]引入转置卷积^[20]操作将生成对抗思想与CNN相结合,提出深度卷积生成对抗网络(deep convolutional generative adversarial networks, DCGAN)^[20],在图像和语音等高维数据的生成上表现出巨大的潜力。为弥补原始GAN随机生成数据的缺点,文献[21]提出条件式生成对抗网络(conditional generative adversarial networks, CGAN),通过在生成器G和判别器D中加入约束条件 y 来指导数据的生成过程。如加入类别标签等有效信息就可以使CGAN按照指定条件标签类型生成数据,完成数据的定向增强。

3 实验设计及分析

实验在 Windows 环境下进行，使用 JupyterLab 3.10 IDE 和 Python 3.9 Kernel，调用 Scikit-Learn 库版本为 1.02。CPU 配置为 Intel Xeon (R) Gold 6248R 处理器，核心数 24，主频 3.00 GHz，内存 64 GB，显卡为 NVIDIA RTX A6000，显存 48 GB。

3.1 海量特征衍生与筛选

完成实验数据集的校验清洗和重编码后，进行工程化海量特征衍生与筛选。

首先，将关联度最高的 5 个关键特征，区分离散型和连续型变量类别，分别执行交叉组合特征衍生和多项式特征衍生，其中，交叉组合衍生特征方差方差阈值为 1、多项式两两组合的最高阶数为 3，而后执行卡方检验剔除显著度不足 0.01 的特征，再使用互信息法剔除大于互信息指数均值 0.1 倍的特征，最后保留两种方法筛选特征的交集，共挑选出 228 个特征。

其次，执行分组统计特征衍生，将字段 D_g^- 、 Q_m^- 、 T_{bait}^- 、 T_{type}^- 、 K 作为关键特征来进行分组统计特征衍生，共创建 1130 个特征。组合使用方差分析和互信息法，将两种方法挑选出来的特征取交集最终筛选出来 429 个特征。同时围绕关键特征和衍生特征，采用目标编码和组内四则运算或归一化的方法再次进行特征衍生和筛选，最终输出 457 个有效特征。

最后，将上述三种方法创建的衍生特征与经过重编码的原始特征进行拼接，构建 729 个特征的衍生实验数据集。

3.2 模型融合效果评估

Voting 的提升效果取决于基学习器的选择和权重分配，而 Stacking 和 Blending 的提升效果主要由基学习器层和元学习器的设计方式共同决定。

面向低维空间的元学习器选择，应突出模型的训练效率；在基学习层构建方面，由于融合模型基于高维假设空间思想，所以在保证基学习器稳定的前提下，应尽可能增加算法的多样性，以提高基学习器相互的独立性，有利于降低预测结果与真实标签的方差，提升融合模型整体的泛化能力。比如，混合使用树模型、线性模型、集成模型等。因此，采用原理分析与实验评估的方式，从分类算法中选择计算效率高的模型作为元学习器，并以兼顾多样性和稳定性为策略，对基学习层的构建方式进行优化配置。

由表 3 分析可知，不同类型分类器的主要差异在于模型精度、训练速度和内存消耗 3 个方面。综合衡量算法的精度、用时和泛化能力，首先，将线性模型中训练耗时过长的 SVM、非线性模型中分类精度有限的 KNN 从备选模型队列剔除。然后，使用 Optuna^[30] 框架下的 TPE(tree-structured parzen estimator)^[31] 贝叶斯优化算法和 5 折交叉验证进行模型超参数调整，并根据混淆矩阵结果对其余分类算法的性能进行评估。

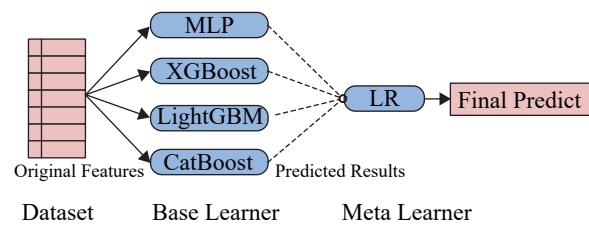
根据表 4 实验结果可知，非线性模型中的 MLP 和集成模型中 XGBosot、LightGBM、CatBoost 的性能最优。因此，将上述 4 种模型配置为 Voting 的基学习器(按最佳权重系数分配)，以及 Stacking、Blending 的基学习器层，并对其超参数进行精细调整。同时选择结构简单、运算速度快的线性模型 LR 作为元学习器，完成图 7 所示融合模型的构建。

与 Baseline 模型的训练流程基本相同，在划分完毕的训练集和测试集上，选择 AUC 作为超参数调优指标，使用机器学习流将数据重编码、模型训练、5 折交叉验证和 Optuna 优化过程进行整体封装，Voting、Stacking 和 Blending 融合模型以及 gcForest 深度集成模型的训练和测试结果如表 5 和图 8 所示。

表3 分类算法原理分析
Table 3 Principle analysis of classification algorithm

| 算法 | 原理 | 优点 | 缺点 |
|----------|---|---------------------------------------|-----------------------------|
| LR | 将目标函数值映射到 Sigmoid 函数, 通过极大似然函数进行分类 | 可解释性好, 训练速度快 | 处理非线性和不平衡样本问题能力弱 |
| KNN | 计算样本之间的距离后进行分类 | 模型结构简单, 计算复杂度低 ^[22] | 处理高维特征能力不足 |
| SVM | 通过核函数将样本映射到高维空间, 采用超平面进行分类 | 对高维小样本数据学习能力较强 | 模型精度过分依赖核函数, 计算量过大 |
| MLP | 在前馈网络结构基础上, 应用反向传播算法和激活函数构造的人工神经网络模型 | 能够处理非线性问题、鲁棒性较强 ^[23] | 受离散值影响较大, 可解释性低 |
| DT | 根据信息增益方向进行自上而下分类的树结构模型 | 模型分类规则具有可解释性 | 处理缺失数据能力弱、容易过拟合 |
| RF | 基于 Bagging 理论和 CART 树的集成模型 ^[24] | 处理高维数据能力强, 对噪声和异常值有较好的容忍性 | 处理小样本数据和低维数据能力弱、可解释性差 |
| AdaBoost | 采用自适应增加预测错误样本权重的方式实现 Boosting | 模型结构简单, 使用灵活, 抗过拟合能力强 ^[25] | 易受噪声干扰, 训练耗时长 |
| GBDT | 采用梯度下降的思想对残差进行优化 ^[26] | 可以灵活地处理多种类型特征 | 难以并行化处理, 计算复杂度高 |
| XGBoost | 在 GBDT 基础上对损失函数进行二阶泰勒展开并添加正则项 | 支持并行计算, 内置交叉验证, 模型泛化能力强 | 调参困难, 内存消耗大 ^[27] |
| LightGBM | 采用直方图、梯度单边采样算法和带深度限制的分支策略 ^[28] | 训练效率高, 内存消耗少 | 对噪声较为敏感 |
| CatBoost | 以对称二叉树为基模型, 采用防止梯度估计偏差的排序提升方法 ^[29] | 离散型特征, 调参成本低, 模型精度高, 预测快 | 离散型特征的处理消耗大量的内存和时间 |

| 表4 分类模型性能评估结果 | | | | | | |
|---|-----------|-------|-------|-------|-------|--|
| Table 4 Classification model performance evaluation results | | | | | | |
| 模型 | 准确率 | 召回率 | 精确率 | F1 | AUC | |
| LR | 训练集 0.823 | 0.500 | 0.651 | 0.566 | 0.859 | |
| | 测试集 0.825 | 0.503 | 0.659 | 0.570 | 0.856 | |
| MLP | 训练集 0.839 | 0.545 | 0.695 | 0.611 | 0.884 | |
| | 测试集 0.839 | 0.546 | 0.694 | 0.611 | 0.882 | |
| DT | 训练集 0.816 | 0.536 | 0.686 | 0.490 | 0.831 | |
| | 测试集 0.814 | 0.531 | 0.612 | 0.568 | 0.825 | |
| RF | 训练集 0.828 | 0.626 | 0.629 | 0.627 | 0.872 | |
| | 测试集 0.825 | 0.655 | 0.613 | 0.633 | 0.870 | |
| AdaBoost | 训练集 0.836 | 0.537 | 0.685 | 0.602 | 0.880 | |
| | 测试集 0.835 | 0.532 | 0.686 | 0.599 | 0.878 | |
| GBDT | 训练集 0.841 | 0.528 | 0.771 | 0.606 | 0.877 | |
| | 测试集 0.840 | 0.524 | 0.708 | 0.602 | 0.883 | |
| XGBoost | 训练集 0.805 | 0.803 | 0.553 | 0.655 | 0.892 | |
| | 测试集 0.803 | 0.787 | 0.552 | 0.649 | 0.889 | |
| LightGBM | 训练集 0.798 | 0.821 | 0.541 | 0.653 | 0.893 | |
| | 测试集 0.794 | 0.810 | 0.537 | 0.646 | 0.889 | |
| CatBoost | 训练集 0.832 | 0.696 | 0.623 | 0.657 | 0.893 | |
| | 测试集 0.829 | 0.693 | 0.616 | 0.652 | 0.890 | |

图7 Stacking 和 Blending 基学习器层和元学习器配置
Fig. 7 Stacking and Blending base learner layer and meta-learner configuration

| 表5 融合模型性能评估结果 | | | | | | |
|--|-----------|-------|-------|-------|-------|--|
| Table 5 Performance evaluation results of fusion model | | | | | | |
| 模型 | 准确率 | 召回率 | 精确率 | F1 | AUC | |
| Voting | 训练集 0.824 | 0.736 | 0.596 | 0.658 | 0.892 | |
| | 测试集 0.821 | 0.732 | 0.591 | 0.654 | 0.888 | |
| Stacking | 训练集 0.843 | 0.601 | 0.684 | 0.640 | 0.894 | |
| | 测试集 0.840 | 0.595 | 0.674 | 0.632 | 0.891 | |
| Blending | 训练集 0.845 | 0.598 | 0.690 | 0.641 | 0.894 | |
| | 测试集 0.837 | 0.579 | 0.672 | 0.622 | 0.888 | |
| gcForest | 训练集 0.836 | 0.509 | 0.698 | 0.588 | 0.873 | |
| | 测试集 0.837 | 0.515 | 0.701 | 0.594 | 0.874 | |

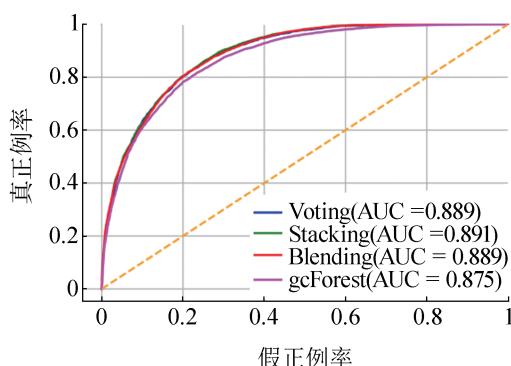


图8 融合模型ROC曲线
Fig. 8 ROC curves of fusion model

综上分析可知，融合模型在测试集上的结果发生了不同程度的变化。其中，Stacking融合模型的预测效果最好，准确率为84.0%、召回率为59.5%、精确率为67.4%、F1-Score为63.2%、AUC达到89.1%，单个样本的决策时间为1.3 s。实验结果表明：综合使用特征工程、集成学习和模型融合等方法后，构建的有效阵位智能决策模型能够在输入观测信息存在误差的情况下，输出可靠的决策结果。使用Stacking融合模型后，虽然一定程度上提升了模型分类精度。但是数据集类别的不平衡特点对召回率、精确率、F1-Score等评估指标的影响依旧存在。因此，需要对不平衡样本的分类方法进行研究。

3.3 ICGAN-Stacking架构

传统的CGAN生成器G和判别器D结构都是由多个全连接层相连组成。由于全连接层存在参数多、表达能力弱、计算速度慢等缺点，因此使用卷积层和转置卷积层对CGAN进行改进，以提升CGAN对高维衍生数据集的表达能力，并加快模型训练收敛速度，提出ICGAN模型。

如图9所示，ICGAN的设计思路主要包括以下几个方面：

(1) 在模型输入阶段，先使用轻量级的Embedding层对约束条件y(标签)进行小幅度升维，再使用全连接层将其升维至满足输入卷积层维

度729。

(2) 判别器D的设计参考了卷积核为3的VGG^[32]架构，生成器G使用转置卷积进行特征图逆向运算，同时为防止CGAN训练过程中出现梯度消失问题，在生成器G和判别器D的结构中选择LeakyReLU^[33]激活函数，同时通过调整步长和填充来替代池化操作带来的信息损失。

(3) 综合衡量训练Batch大小和计算速度，没有对网络采取Batch Normalization^[34]操作，而在判别器D最后输出的全连接层中使用Dropout^[35]操作防止网络出现过拟合。

(4) 对生成器G和判别器D使用Adam^[36]优化算法进行损失函数的反向传播，设置学习率 $lr=0.0001$, $\beta_1=0.9$, $\beta_2=0.999$ 。

在Stacking融合模型前引入ICGAN实现对数据集中的少数类样本进行定向扩充，从而调节数据偏态程度，降低样本不平衡性对分类模型性能的影响。因此，将ICGAN和Stacking进行整合，创建更加适用于无人平台有效阵位智能决策的ICGAN-Stacking模型架构。

如图10所示，将预处理后的衍生数据训练集中的特征和标签分别作为真实样本x和约束条件y对ICGAN进行训练，测试集保持不变；将少数类标签输入到训练完毕的ICGAN模型中，实现数据的定向扩充；将扩充生成的数据与原始数据集进行混合，形成所需要的平衡数据集后输入Stacking融合模型进行训练，并按照混淆矩阵结果对模型分类效果进行评估。ICGAN训练过程损失变化如图11所示，生成器G和判别器D均在损失值为0.5左右附近达到了收敛。

为验证ICGAN-Stacking架构的不平衡样本分类性能效果，设置调整后的正负样本比例为1:1.5，分别使用SMOTE-Stacking、CGAN-Stacking、ICGAN-Stacking不平衡分类架构进行少数类样本定向生成和模型训练。迭代训练50次后的结果如表6所示。

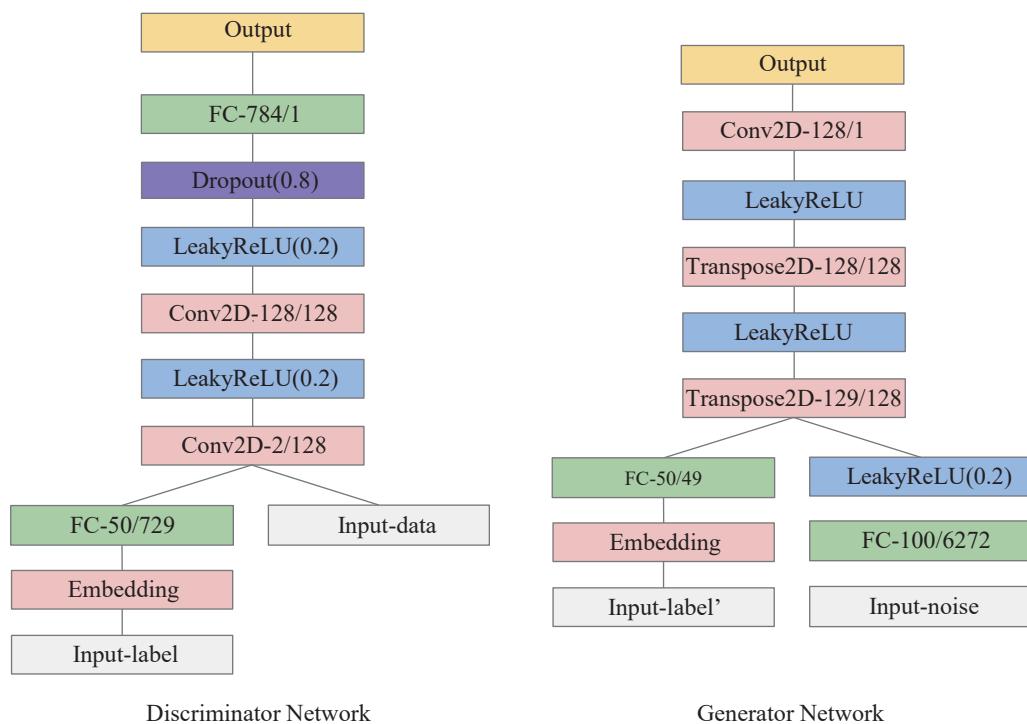


图9 ICGAN模型结构
Fig. 9 ICGAN model structure

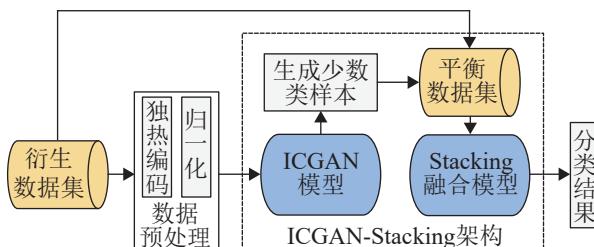


图10 ICGAN-Stacking 不平衡分类架构
Fig. 10 ICGAN-Stacking imbalanced classification architecture

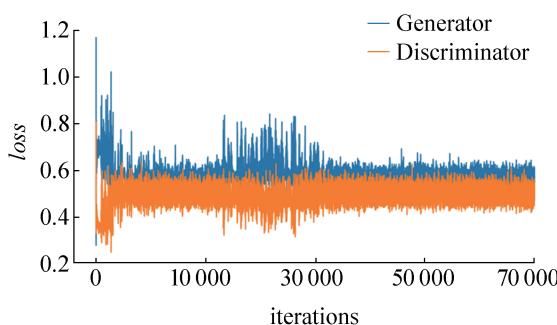


图11 ICGAN训练过程损失变化
Fig. 11 ICGAN training process loss variation

表6 不平衡分类架构性能评估结果
Table 6 Performance evaluation results of imbalanced classification architecture

| 模型 | 准确率 | 召回率 | 精确率 | F1 | AUC |
|----------------|-------|-------|-------|-------|-------|
| Stacking | 0.843 | 0.603 | 0.680 | 0.640 | 0.894 |
| | 0.839 | 0.603 | 0.674 | 0.631 | 0.891 |
| SMOTE-Stacking | 0.891 | 0.895 | 0.889 | 0.892 | 0.964 |
| | 0.830 | 0.666 | 0.625 | 0.645 | 0.886 |
| CGAN-Stacking | 0.877 | 0.827 | 0.860 | 0.843 | 0.952 |
| | 0.831 | 0.638 | 0.651 | 0.644 | 0.891 |
| ICGAN-Stacking | 0.872 | 0.847 | 0.835 | 0.841 | 0.951 |
| | 0.833 | 0.644 | 0.678 | 0.646 | 0.909 |

分析可知，3种不平衡分类架构均产生了一定程度的过拟合，其中SMOTE-Stacking过拟合程度较高，AUC值降低至88.6%，主要是因为基于距离度量的SMOTE^[37]算法合成样本很大概率上是噪声样本，所以无法克服不平衡样本分类问题。相比较而言，ICGAN-Stacking架构分类性能提升效果最好，召回率提升了4.1%、准确率提升了0.4%、F1值提升了1.5%、AUC值达到90.9%。实

验结果表明：ICGAN-Stacking 架构相比于传统的仿真决策模型，在态势瞬息万变的战场上，具有高效、灵敏的决策速度，能够满足无人平台从带有噪声的观测信息中进行快速精准有效阵位决策的需求。此外，该方法在其他攻防战术行为决策上，也具有相似的通用性和可迁移性。

在工程运用中，可以将ICGAN-Stacking 作为预训练模型嵌入无人平台指控系统，替代基于规则推演的仿真模型。当无人平台探测到目标后，综合观测目标态势信息、武器装备性能信息、设定射击诸元信息进行有效阵位决策。若判断当前阵位是有效阵位，则无人平台执行攻击行为；若判断当前阵位非有效阵位，则执行占位机动调整。经任务部署和数据采集后，通过动态数据变化适应环境变化，从而赋予模型高效决策和线上自学能力。

4 结论

本文为实现无人平台从带有噪声的观测信息中进行快速精准有效阵位决策，将其转换为机器学习领域类别不平衡的二分类问题，综合采用特征工程、模型融合和生成对抗网络等方法构建高效灵活的智能决策模型。考虑到复杂战场环境对无人平台攻击决策的影响还表现在观测信息时序性缺失、实时博弈对抗等方面，下步计划将不完全时序信息的预测方法纳入研究。

参考文献：

- [1] 司广宇, 苗艳, 李关防. 水下立体攻防体系构建技术[J]. 指挥控制与仿真, 2018, 40(1): 1-8.
Si Guangyu, Miao Yan, Li Guanfang. Underwater Tridimensional Attack-defense System Technology[J]. Command Control and Simulation, 2018, 40(1): 1-8.
- [2] 何玉庆, 秦天一, 王楠. 跨域协同: 无人系统技术发展和应用新趋势[J]. 无人系统技术, 2021, 4(4): 1-13.
He Yuqing, Qin Tianyi, Wang Nan. Cross-domain Collaboration: New Trends in the Development and Application of Unmanned Systems Technology[J]. Unmanned Systems Technology, 2021, 4(4): 1-13.
- [3] 王雅琳, 杨依然, 王彤, 等. 2019年无人系统领域发展综述[J]. 无人系统技术, 2019, 2(6): 53-57.
Wang Yalin, Yang Yiran, Wang Tong, et al. Summary of the Development of Unmanned Systems in 2019[J]. Unmanned Systems Technology, 2019, 2(6): 53-57.
- [4] 李磊, 王彤, 蒋琪. 从美军2042年无人系统路线图看无人系统关键技术发展动向[J]. 无人系统技术, 2018, 1(4): 79-84.
Li Lei, Wang Tong, Jiang Qi. Key Technology Develop Trends of Unmanned Systems Viewed from Unmanned Systems Integrated Roadmap 2017-2042[J]. Unmanned Systems Technology, 2018, 1(4): 79-84.
- [5] 周光霞, 周方. 美军人工智能空战系统阿尔法初探[C]//第六届中国指挥控制大会论文集(上册). 北京: 电子工业出版社, 2018: 66-70.
- [6] 王建丽, 张渭育. 统计学[M]. 北京: 清华大学出版社, 2010: 215-220.
- [7] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
Zhou Zhihua. Machine Learning[M]. Beijing: Tsinghua University Press, 2016.
- [8] Quinlan J R. Induction of Decision Trees[J]. Machine Learning, 1986, 1(1): 81-106.
- [9] Olson R S, Moore J H. Identifying and Harnessing the Building Blocks of Machine Learning Pipelines for Sensible Initialization of a Data Science Automation Tool [M]//Riolo R, Worzel B, Goldman B, et al. Genetic Programming Theory and Practice XIV. Cham: Springer International Publishing, 2018: 211-223.
- [10] 冯国双. 白话统计[M]. 北京: 电子工业出版社, 2018.
- [11] Peng Hanchuan, Long Fuhui, Ding C. Feature Selection Based on Mutual Information: Criteria of Max-dependency, Max-relevance, and Min-redundancy[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8): 1226-1238.
- [12] Cortes C, Vapnik V. Support-vector Networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [13] Narasimhamurthy A M. A Framework for the Analysis of Majority Voting[C]//Image Analysis. Berlin: Springer Berlin Heidelberg, 2003: 268-274.
- [14] Wolpert D H. Stacked Generalization[J]. Neural Networks, 1992, 5(2): 241-259.
- [15] Kuo C C J. Understanding Convolutional Neural Networks with a Mathematical Model[J]. Journal of Visual Communication and Image Representation, 2016, 41: 406-413.
- [16] 夏恒, 汤健, 乔俊飞. 深度森林研究综述[J]. 北京工业大学学报, 2022, 48(2): 182-196.
Xia Heng, Tang Jian, Qiao Junfei. Review of Deep Forest [J]. Journal of Beijing University of Technology, 2022, 48(2): 182-196.

- [17] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [18] Diederik P Kingma, Max Welling. Auto-encoding Variational Bayes[C]/ICLR 2014. New York, USA: ICLR, 2014.
- [19] Radford A, Metz L, Chintala S. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks[EB/OL]. (2016-01-07) [2022-07-08]. <https://arxiv.org/abs/1511.06434>.
- [20] Vincent Dumoulin, Francesco Visin. A Guide to Convolution Arithmetic for Deep Learning[EB/OL]. (2018-01-11) [2022-07-22]. <https://arxiv.org/abs/1603.07285>.
- [21] Mehdi Mirza, Osindero S. Conditional Generative Adversarial Nets[EB/OL]. (2014-11-06) [2022-07-15]. <https://arxiv.org/abs/1411.1784>.
- [22] Cover T M, Hart P E. Nearest Neighbor Pattern Classification[J]. IEEE Transactions on Information Theory, 1967, 13(1): 21-27.
- [23] Ian Goodfellow, Yoshua Bengio, Aaron Courville. Deep Learning[M]. Cambridge: MIT Press, 2016: 106-140.
- [24] Breiman L. Random Forests[J]. Machine Learning, 2001, 45(1): 5-32.
- [25] Freund Y, Schapire R E. A Decision-theoretic Generalization of on-line Learning and an Application to Boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119-139.
- [26] Friedman J H. Greedy Function Approximation: A Gradient Boosting Machine[J]. Annals of Statistics, 2001, 29(5): 1189-1232.
- [27] Chen Tianqi, Guestrin C. XGBoost: A Scalable Tree Boosting System[C]/Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, NY, USA: Association for Computing Machinery, 2016: 785-794.
- [28] Ke Guolin, Meng Qi, Finley T, et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree[C]/Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 3149-3157.
- [29] Liudmila Prokhorenkova, Gleb Gusev, Aleksandr Vorobev, et al. CatBoost: Unbiased Boosting with Categorical Features[C]/Proceedings of the 32nd International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2018: 6639-6649.
- [30] Takuya Akiba, Shotaro Sano, Toshihiko Yanase, et al. Optuna: A Next-generation Hyperparameter Optimization Framework[C]/Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York, NY, USA: Association for Computing Machinery, 2019: 2623-2631.
- [31] Yoshihiko Ozaki, Yuki Tanigaki, Shuhei Watanabe, et al. Multiobjective Tree-structured Parzen Estimator for Computationally Expensive Optimization Problems[C]/GECCO 2020-Proceedings of the 2020 Genetic and Evolutionary Computation Conference. New York, NY, USA: Association for Computing Machinery, 2020: 533-541.
- [32] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-scale Image Recognition[EB/OL]. (2015-04-10) [2022-08-03]. <https://arxiv.org/abs/1409.1556>.
- [33] Gu Jiuxiang, Wang Zhenhua, Kuen J, et al. Recent Advances in Convolutional Neural Networks[J]. Pattern Recognition, 2018, 77: 354-377.
- [34] Ioffe S, Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[C]/Proceedings of the 32nd International Conference on International Conference on Machine Learning-Volume 37. Cambridge: JMLR, 2015: 448-456.
- [35] Santurkar S, Tsipras D, Ilyas A, et al. How Does Batch Normalization Help Optimization? [C]/Proceedings of the 32nd International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2018: 2488-2498.
- [36] Diederik P Kingma, Ba J L. Adam: A Method for Stochastic Optimization[EB/OL]. (2017-01-30) [2022-07-29]. <https://arxiv.org/abs/1412.6980>.
- [37] 石洪波, 陈雨文, 陈鑫. SMOTE过采样及其改进算法研究综述[J]. 智能系统学报, 2019, 14(6): 1073-1083.
Shi Hongbo, Chen Yuwen, Chen Xin. Summary of Research on SMOTE Oversampling and Its Improved Algorithms[J]. CAAI Transactions on Intelligent Systems, 2019, 14(6): 1073-1083.