

基于 DE-AMSARO-Stacking 的煤与瓦斯突出预警方法^{*}刘宝玉¹ 宋佳铃² 周 旭¹

(1. 华北理工大学理学院 唐山 063210; 2. 华北理工大学人工智能学院 唐山 063210)

摘 要: 煤与瓦斯突出是煤矿开采中极具破坏性的地质灾害之一,高效的突出预警对保障矿区安全生产至关重要。针对传统 Stacking 模型的超参数优化效率低且易陷入局部最优和基学习器依赖人工选择,提出了一种融合改进人工兔群优化算法(ARO)与差分进化算法(DE)的改进 Stacking 预警模型。加入精英记忆池与多策略自适应选择机制得到 AMSARO 算法用于参数寻优,DE 算法动态优化权重实现基学习器选择,并同步进行特征选择,两者结合 Stacking 集成方法构建 DE-AMSARO-Stacking 煤与瓦斯突出预警模型。采用 8 个不同的基准函数进行测试,实验表明 AMSARO 算法比(ARO)算法及其他改进算法具有更快的收敛速度和寻优精度;采用山西某矿 50 组原始数据扩充后的 500 组样本数据集进行瓦斯预警实验,结果表明,DE-AMSARO-Stacking 模型的预测性能优于单一模型和不同优化算法的对比模型,为煤与瓦斯突出预警提供了更高效的方法。

关键词: 煤与瓦斯突出;预警;Stacking;差分进化算法;基学习器选择;改进人工兔群优化算法;参数寻优

中图分类号: TP181;TD713;TN911.23 **文献标识码:** A **国家标准学科分类代码:** 520.30;520.20

Coal and gas outburst early warning method based on DE-AMSARO-Stacking

Liu Baoyu¹ Song Jialing² Zhou Xu¹

(1. College of Science, North China University of Science and Technology, Tangshan 063210, China;

2. College of Artificial Intelligence, North China University of Science and Technology, Tangshan 063210, China)

Abstract: Coal and gas outburst is one of the highly destructive geological hazards in coal mining operations, and efficient outburst early warning is crucial for ensuring the safe production of mining areas. To resolve traditional Stacking models' issues of inefficient hyperparameter optimization, local optima traps, and manual base learner selection, this paper develops an improved Stacking early warning model with modified artificial rabbit optimization (ARO) and differential evolution (DE) algorithms. The AMSARO algorithm—incorporating an elite memory pool and a multi-strategy adaptive selection mechanism—is applied for parameter optimization. The DE algorithm dynamically optimizes weights to realize base learner selection while performing feature selection synchronously. Combining these two algorithms with the Stacking ensemble method, the DE-AMSARO-Stacking coal and gas outburst early warning model is constructed. Eight different benchmark functions are adopted for testing, and experimental results show that the AMSARO algorithm achieves faster convergence speed and higher optimization accuracy compared with the ARO algorithm and its improved variants. Experiments are conducted on a dataset of 500 samples expanded from 50 sets of original data collected from a coal mine in Shanxi Province. The results indicate that the DE-AMSARO-Stacking model outperforms single models and comparative models based on different optimization algorithms in prediction performance. This research provides a more efficient approach for coal and gas outburst early warning.

Keywords: coal and gas outburst; early warning; Stacking; differential evolution algorithm; base learner selection; improve the artificial rabbit optimization algorithm; parameter optimization

0 引 言

煤矿开采是能源产业的重要组成部分,在全球地位举

足轻重。但开采中伴随的煤与瓦斯突出,始终是煤矿安全生产的重大隐患。该现象由煤层中的瓦斯气体压力与力学特性之间的不平衡引发,表现为在极短的时间内向周围抛

出大量的煤岩与瓦斯,既威胁矿工的生命安全,也严重影响矿山生产效率和经济效益^[1]。因此,煤与瓦斯突出的预警与防控成为煤矿安全生产中的研究焦点。

传统的煤与瓦斯突出预测方法有以瓦斯地质分析、单指标及综合指标等方法为主的常规静态预测技术;瓦斯动态指标法及监测预警方法^[2];突出防治的地球物理监测预警方法,包括微震、声发射、电磁辐射、地质雷达和震动波 CT 等技术手段^[3]。这些方法虽然在一定程度上能够提供矿井中瓦斯和煤层的基础信息,但由于煤层和瓦斯分布不均匀、矿井环境复杂,准确性和实时性存在较大局限,难以满足现代化煤矿对灾害预警的高精度需求。

随着人工智能技术的发展,机器学习模型为煤与瓦斯突出预警提供了新的解决方案。Liu 等^[4]采用粗糙集理论和支持向量机(support vector machine, SVM)建立预测模型,可有效预测瓦斯突出危险性等级;Wu 等^[5]构建了改进的 GASA-BP 预测模型,能更准确、快速地实现煤与瓦斯突出预测;陈利成等^[6]提出将多重插补和随机森林(random forest, RF)填补应用于填补缺失参数,并分别将填补前后的数据输入 SVM、ELM、RF 3 种机器学习算法进行训练,构建 9 种耦合模型;林海飞等^[7]通过引入 6 种特征选择方法及 6 种有监督机器学习算法构建了 42 种瓦斯突出危险等级预测模型,采用准确率等指标筛选出精度及稳定度高的 4 种机器学习算法和 3 种特征参数组合,所构建的协同预测模型精度较高,可为煤与瓦斯突出危险等级预测提供一种新思路。

近年来,集成学习因能融合多模型优势,提升泛化能力,逐渐被应用于瓦斯突出预警任务中,Ru 等^[8]使用 RF 模型获得了良好的预测性能;阎馨等^[9]为实现对煤与瓦斯突出的快速、准确和动态预测,考虑多种影响因素,提出了基于 AdaBoost 和 LR 的预测方法,过程稳定、准确性高、时间消耗短;Zheng 等^[10]研究了基于 XGBoost 可解释性的突出预测中各指标的贡献率,对煤矿安全生产具有重要意义。然而,现有集成模型多依赖单一学习器或简单组合策略,在高维非线性的突出特征空间中,仍存在预测精度不足、鲁棒性较弱等问题。

Stacking 作为一种先进的集成学习框架,通过基学习器特征提取与元学习器融合决策的双层结构,充分挖掘不同模型的互补性,显著提升预测性能。Guo 等^[11]提出的基于 XGBoost-GR-Stacking 的瓦斯突出风险预警模型在对比模型中取得了最高的精度和最佳的拟合效果;王超等^[12]构建的 BO-Stacking 集成学习模型具有良好的预测性能和稳定性,为瓦斯突出预测提供了一种新方法;王琳等^[13]通过集成 LSSVM 等基模型得到 7 种瓦斯含量预测模型,结果表明 Stacking-LSSVM-Adaboost-DBN 模型拥有较高预测精度,可为矿井瓦斯灾害防治提供一定依据。但现有 Stacking 模型在瓦斯预警问题中的应用仍存在两大核心缺陷:一是基学习器选择依赖人工经验,多为全选或随机选,易引入冗余模型,且 K 折交叉验证中忽略模型差异性,无法真实反映基学习器的贡献度;二是超参数优化效率低,传

统网格搜索、随机搜索等方法不仅计算成本高,还易陷入局部最优,难以适配突出预警的高维特征空间。

针对上述问题,本文提出一种融合差分进化(differential evolution, DE)与自适应多策略人工兔群优化(adaptive multi-strategy artificial rabbit optimization, AMSARO)的 Stacking 模型,旨在实现煤与瓦斯突出的高精度预警。首先引入 DE 算法以集成准确率最高和基学习器间差异性最大为目标动态优化基学习器权重,选择对集成贡献最大的前 3 个基学习器组合并协同进行特征选择,最终输出加权预测结果,最大限度地发挥每个基学习器的优势,进一步增强模型的性能。然后提出混合策略改进的人工兔优化算法(artificial rabbit optimization, ARO)对 Stacking 基学习器进行参数寻优,显著提升了算法的全局搜索能力、收敛速度与鲁棒性。

1 相关理论基础

1.1 Stacking 集成方法

Stacking 是一种集成学习策略^[14-15],通过两层学习器协同工作实现模型性能提升:第 1 层为基学习器层,由多个同质或异质基学习器组成,对原始训练数据进行独立学习并输出预测结果;第 2 层为元学习器层,将所有基学习器的预测结果作为新特征,通过元学习器输出最终预测,从而构造出比单一模型性能更好的强学习器。Stacking 集成学习算法流程如图 1 所示。




图 1 Stacking 集成学习算法流程

Fig. 1 Flowchart of the Stacking ensemble learning

步骤 1)将原始数据集划分为训练集和测试集,并对训练集进行 K 折交叉验证,即将训练集均匀划分为 K 个大小相等的子集。

步骤 2)每次训练时,用 1 个子集作为测试集,剩余 K-1 个子集合并作为训练集。将每个基学习器在 K 折交叉验证中输出的测试集预测结果按样本顺序拼接,得到元学习器的输入特征,即训练集。所有基学习器分别对原始测试集进行预测,每折的预测结果进行平均,拼接后作为元学习器的测试集。

步骤 3)将新的训练集和测试集输入元学习器,得到最终预测结果。

1.2 DE 算法

DE 算法^[16]由 Storn 和 Price 于 1995 年提出,是一种简单且高效的启发式搜索算法。该算法的核心由变异、交叉、选择 3 个顺序阶段组成。

在算法开始时,需要随机生成一个包含 N 个个体的初始种群,假设优化问题的维度为 D ,则每个个体可以表示为一个 D 维向量。

变异操作通过引入种群中个体之间的差异来生成新的变异体:

$$\mathbf{V}_i = \mathbf{X}_3 + F \times (\mathbf{X}_1 - \mathbf{X}_2) \quad (1)$$

式中: $\mathbf{X}_1$ 、 $\mathbf{X}_2$ 和 $\mathbf{X}_3$ 从种群中随机选择 3 个不同的个体; F 称为缩放因子,是控制变异幅度的参数,通常在 $[0, 2]$ 范围。

交叉操作通过将变异体 $\mathbf{V}_i$ 和目标个体 $\mathbf{X}_i$ 的基因进行组合,生成试验个体 $\mathbf{u}_i$, 对于每个维度 j :

$$\mathbf{u}_{i,j} = \begin{cases} \mathbf{v}_{i,j}, & \text{rand}(0,1) \leq CR \text{ or } j = \text{rand}(1,D) \\ \mathbf{x}_{i,j}, & \text{其他} \end{cases} \quad (2)$$

式中: $\text{rand}(0,1)$ 是 $[0, 1]$ 之间的随机数; $\text{rand}(1,D)$ 是一个在 $[1, D]$ 范围内的随机整数,确保至少有一个维度来自变异体; CR 是交叉频率,通常在 $[0, 1]$ 范围内。

选择操作用于决定试验个体 $\mathbf{u}_i$ 是否能够替代目标个体 $\mathbf{x}_i$ 。通过比较它们的适应度值,如果试验体的适应度优于目标个体,则用试验体替代目标个体:

$$\mathbf{X}_i^{t+1} = \begin{cases} \mathbf{u}_i, & f(\mathbf{u}_i) \leq f(\mathbf{X}_i) \\ \mathbf{X}_i, & \text{其他} \end{cases} \quad (3)$$

式中: $f(x)$ 是目标适应度函数; t 表示当前迭代次数。

2 ARO 算法及其改进

2.1 ARO 算法

人工兔群优化算法是一种新型群体智能优化算法,由 Wang 等^[17]于 2022 年提出,其灵感来自于兔子在自然环境中的生存策略,主要包括“绕道觅食”与“随机藏匿”两种行为模式。

初始化:

$$\mathbf{P} = \mathbf{lb} + \text{rand} \cdot (\mathbf{ub} - \mathbf{lb}) \quad (4)$$

式中: $\mathbf{ub}$ 和 $\mathbf{lb}$ 是解空间的上、下界; rand 是 $[0, 1]$ 间的随机数。

1) 绕道觅食策略

兔子在觅食过程中,常会以扰乱食物来源获取足够的食物。据此,ARO 算法将迂回觅食行为定义为搜索个体参考种群中随机选取的其他个体位置来更新自身位置,并添加扰动。

$$\mathbf{X}_i(t+1) = \mathbf{X}_j(t) + R \cdot (\mathbf{X}_i(t) - \mathbf{X}_j(t)) + \text{round}(0.5 \cdot (0.05 + r_1)) \cdot r_2 \quad (5)$$

$$R = (e - e^{\frac{(-1)}{T}}) \cdot \sin(2\pi r_3) \cdot c \quad (6)$$

式中: $\mathbf{X}$ 为个体的位置; $i, j = 1, 2, \dots, N, i \neq j$; N 是种群规模; r_1 、 r_2 和 r_3 分别代表为 $[0, 1]$ 间的随机数; t 是当前迭代次数; T 是最大迭代次数; R 代表移动步长; $k = 1, 2, \dots, d$; d 是问题的维数; c 的取值为 0 或 1, round 为四舍五入取整函数。

2) 随机隐藏策略

兔子为躲避捕食者,通常会在巢穴周围开挖不同的洞进行躲藏。因此在 ARO 算法中,每次迭代时,每个个体会沿搜索空间的各个维度在自身周边生成若干候选位置,并从候选位置中随机选取一个更新自身状态。

$$\mathbf{X}_i(t+1) = \mathbf{X}_i(t) + R \cdot (r_4 \cdot H \cdot g \cdot \mathbf{X}_i(t) - \mathbf{X}_i(t)) \quad (7)$$

$$H = \frac{T-t+1}{T} \cdot r_5 \quad (8)$$

式中: H 是隐藏参数,迭代进程中从 1 开始随机线性递减到 $1/T$; r_4 和 r_5 分别是 $[0, 1]$ 间的随机数; g 的取值为 0 或 1。

ARO 算法通过模拟兔子在不同能量状态下的行为选择,实现了全局探索与局部开发的动态平衡。具体而言,算法引入能量因子 $A(t)$ 来控制两种行为的切换:

$$A(t) = 4 \cdot \left(1 - \frac{1}{T}\right) \cdot \ln \frac{1}{r_6} \quad (9)$$

式中: t 是当前迭代次数; T 是最大迭代次数, $r \sim U(0, 1)$ 。当 $A(t) > 1$ 时,个体执行“绕道觅食”策略以增强探索能力;反之则执行“随机藏匿”策略以提升局部开发能力。

2.2 ARO 算法的改进

虽然 ARO 算法引入能量因子 $A(t)$ 来控制两种行为的切换机制在一定程度上增强了算法的适应性,但在面对复杂、多峰或非平稳优化问题时,仍存在以下不足:

1) 搜索策略单一,原算法仅依赖两种固定行为模式,缺乏多样性,难以适应复杂搜索环境;

2) 缺乏历史信息利用机制,算法未对历史优质解进行有效记录与复用,导致搜索效率受限;

3) 策略选择缺乏自适应性,行为切换仅依赖能量因子,未考虑个体状态、种群分布或搜索阶段的变化,适应性较弱。

为此,本文设计并提出 AMSARO 算法,该算法在保留 ARO 原始生物启发机制的基础上,融合多种搜索策略,引入策略自适应选择机制与精英记忆池,显著提升了算法的全局搜索能力、收敛速度与鲁棒性。整体流程分为 4 个主要阶段:初始化与预处理、自适应策略选择、边界处理与选择、全局信息更新与终止判断。这 4 个阶段协同工作,构成一个具有自适应性、多样性和记忆能力的优化系统。

1) 初始化与预处理

初始化阶段的目标是为算法提供高质量的初始种群与基础参数设置,为后续迭代搜索奠定良好基础。首先在搜索空间中随机生成初始种群:

$$\mathbf{X}_i = \mathbf{lb} + \text{rand}(0,1) \cdot (\mathbf{ub} - \mathbf{lb}), i = 1, 2, \dots, N \quad (10)$$

式中: $\mathbf{lb}$ 和 $\mathbf{ub}$ 分别为搜索空间的下界与上界; N 为种群规模。在此基础上, 进行反向学习增强^[18]处理, 引入反向学习机制生成反向解, 以提高初始种群质量:

$$\mathbf{X}_{\text{opp},i} = \mathbf{lb} + \mathbf{ub} - \mathbf{X}_i \quad (11)$$

合并原始种群与反向种群, 将所有个体按适应度降序排列, 选取前 N 个精英个体构成初始种群, 从而有效提升初始解的质量与分布广度, 增强算法初期的探索能力。同时, 初始化一个容量为 m 的精英记忆池 $\mathbf{M}$, 用于存储迭代过程中的历史最优解。该池用于在后续策略中引导搜索方向, 提升算法对优质区域的利用效率。

2) 自适应策略选择机制^[19]

为提升算法在不同搜索阶段的适应性, AMSARO 引入 4 种互补的搜索策略, 并为每种策略分配一个自适应权重。该权重根据策略在迭代过程中的成功率进行动态调整, 从而实现策略选择的智能化与自适应化。策略选择采用轮盘赌机制, 即根据各策略的累积概率进行选择。策略权重更新公式为:

$$\mathbf{W}_k^{\text{new}} = 0.9 \cdot \mathbf{W}_k^{\text{old}} + 0.1 \cdot \text{SuccessRate}_k \quad (12)$$

式中: SuccessRate_k 为策略 k 在最近若干迭代周期内成功引导个体改进的频次占比。该自适应权重更新机制使算法能够动态识别并强化当前搜索阶段最具潜力的策略, 从而在探索与开发之间实现更精准的平衡。每个个体在每一代中根据所选策略执行相应的位置更新操作。具体如下:

(1) 增强型 ARO 策略: 该策略在原始 ARO 的基础上引入精英引导机制与多样性扰动操作, 分别对应“绕道觅食”与“随机藏匿”两种行为, 兼顾全局探索与局部开发, 有效维持种群活力。

绕道觅食(探索):

$$\mathbf{X}_{\text{new}} = \mathbf{X}_j + R \cdot (\mathbf{X}_i - \mathbf{X}_j) + \delta \cdot (\mathbf{X}_{\text{elite}} - \mathbf{X}_i) \quad (13)$$

式中: $R = L \cdot c$, $L = (e - e^{(t/T)^2}) \cdot \sin(2\pi r)$; δ 为精英引导系数。用于增强对优质区域的搜索。

随机藏匿(开发):

该机制在局部区域内引入高斯扰动, 增强局部搜索的多样性。

$$\mathbf{b} = \mathbf{X}_i + H \cdot \mathbf{X}_i, H = \frac{T-t+1}{T} \cdot N(0,1) \quad (14)$$

$$\mathbf{X}_{\text{new}} = \mathbf{X}_i + R \cdot (r \cdot \mathbf{b} - \mathbf{X}_i) \quad (15)$$

(2) 差分进化策略: 通过差分向量构造与交叉操作, 产生具有较大跳跃幅度的新解, 显著增强算法跳出局部极值能力。AMSARO 引入该策略以增强算法的探索能力。

异操作:

$$\mathbf{V} = \mathbf{X}_{r_3} + F \cdot (\mathbf{X}_{r_1} - \mathbf{X}_{r_2}) \quad (16)$$

交叉操作:

$$U_j = \begin{cases} V_j, & \text{rand} < CR \text{ 或 } j = j_{\text{rand}} \\ X_{i,j}, & \text{其他} \end{cases} \quad (17)$$

增强机制, 以一定概率用精英记忆池中的个体替换 $\mathbf{X}_{r_3}$, 以引导搜索朝向更优区域。

(3) 记忆引导策略: 通过引入精英记忆池中的历史最优解, 对当前个体实施定向引导, 加速种群向优质区域聚集, 从而提升收敛速度与精度。

$$\mathbf{X}_{\text{new}} = \alpha \cdot \mathbf{X}_i + (1 - \alpha) \cdot \mathbf{X}_{\text{elite}} + \boldsymbol{\eta} \quad (18)$$

式中: $\alpha \sim U(0,1)$; $\mathbf{X}_{\text{elite}} \in \mathbf{M}$; $\boldsymbol{\eta} \sim N(0, \sigma^2)$ 为高斯扰动项, 用于保持个体多样性。

(4) 反向学习策略: 通过在当前解的反向空间进行搜索, 扩大潜在解区域覆盖范围, 有效提升算法在搜索初期的探索效率及后期的收敛稳定性。该策略在搜索初期更倾向于反向探索, 后期则逐步向当前最优解靠拢, 实现探索与开发的平滑过渡。

$$\alpha = 0.3 + 0.4 \cdot (1 - \frac{t}{T}) \quad (19)$$

$$\mathbf{X}_{\text{new}} = \alpha \cdot (\mathbf{lb} + \mathbf{ub} - \mathbf{X}_i) + (1 - \alpha) \cdot \mathbf{X}_{\text{best}} \quad (20)$$

总体而言, 所集成的 4 类策略各自具备独特的搜索优势, 协同作用下可显著提升算法的全局寻优性能与收敛可靠性。

3) 边界处理与选择机制

当个体某一维分量越过搜索边界时, 算法不采用简单截断, 而是执行随机重置策略:

$$x_{i,d} = \begin{cases} \mathbf{lb}_d + U(0,1) \cdot (\mathbf{ub}_d - \mathbf{lb}_d), & x_{i,d} < \mathbf{lb}_d \\ \mathbf{ub}_d - U(0,1) \cdot (\mathbf{ub}_d - \mathbf{lb}_d), & x_{i,d} > \mathbf{ub}_d \end{cases} \quad (21)$$

为平衡搜索连续性与种群多样性, AMSARO 在边界校正和个体更新环节建立“修复-选择-更新”协同机制。首先, 对越界个体拒绝简单截断, 采用随机重置拉回边界邻近区域, 避免“边界堆积”并保留向边界最优区域进化的可能; 其次, 通过贪婪选择机制仅接受目标函数值优于父代的新解, 确保种群适应度单调非降, 防止劣质解干扰; 最后, 精英池按“最差替换”准则更新, 以新解替换池内最劣个体并同步重排, 维持记忆池高质量与代表性, 为后续记忆引导策略提供可靠先验信息。

4) 全局信息更新与终止条件

为保障进化自洽性与收敛效率, AMSARO 将全局信息维护与终止判断融入迭代主循环: 每代先比对当前种群与历史全局最优, 发现更优解立即更新最优位置与适应度并重置停滞计数器, 确保搜索方向精准; 每 10 代按成功更新率重分配策略权重让优异策略获更高调用概率, 实现搜索资源自适应调度; 当迭代达预设上限或全局最优连续多代未改善, 终止算法输出最优解, 兼顾解的质量与计算成本。

2.3 AMSARO 性能测试结果与分析

测试函数是评估算法在全局搜索能力和收敛速度方面的重要工具, 为系统评估 AMSARO 算法的综合优化性能, 本文选取含单峰、多峰的 8 个经典测试函数探究不同算法在寻优任务中的性能表现, 其数学表达式如表 1 所示。


表 1 测试函数的数学表达式

Table 1 Mathematical expressions of test functions

函数名称	函数表达式	最优值
F_1 Sphere	$f(x) = \sum_{i=1}^n x_i^2$	0
F_2 Zakharov	$f(x) = \sum_{i=1}^n x_i^2 + \left(\frac{1}{2} \sum_{i=1}^n i x_i\right)^2 + \left(\frac{1}{2} \sum_{i=1}^n i x_i^2\right)^4$	0
F_3 Rosenbrock	$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (1 - x_i)^2]$	0
F_4 Schwefel2.21	$f(x) = \max_i \{ x_i , 1 \leq i \leq N \}$	0
F_5 Schwefel2.22	$f(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	0
F_6 Ackley	$f(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	0
F_7 Griewank	$f(x) = \frac{1}{4\,000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	0
F_8 Rastrigin	$f(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	0

为进一步验证和分析,同时更全面地评估优化算法在不同场景下的表现,构建了每个测试函数的三维曲面与等高线联合视图,右侧同步绘制 AMSARO 与原始 ARO 算法及其他改进算法 IARO^[20]、QARO^[21]、MARO^[22]和基于自适应调整策略的灰狼优化算法(improvements-Grey Wolf Optimization, IGWO)^[23] 6 种算法在对数坐标下的平均收敛曲线,以更加深入地观察函数的形状和特征,实验数据以迭代次数为横轴,目标函数

寻优值为纵轴进行呈现。实验在 30 维场景下独立运行 30 次,种群规模 30,最大迭代次数为 300 次。实验结果如图 2 所示。实验结果表明,综合 8 个测试函数的统计结果,AMSARO 算法的适应度迭代曲线展现出明显的收敛速度快的优势,说明通过自适应多策略选择与精英记忆引导,AMSARO 在收敛速度、求解精度及稳定性方面均显著优于原始 ARO 算法及其他对比算法,具备解决复杂高维优化问题的潜力。






图 2 AMSARO 优化算法与其他算法在不同测试函数上的性能对比

Fig. 2 AMSARO vs other algorithms: Performance on different test functions

实验过程中,还重点记录了 3 个关键性能指标:最小值、平均值以及解的标准差,并依据这些指标对算法的表现进行综合评价。其中,最小值和平均值用于评估算法的优化效果和收敛特性,而标准差则用于衡量算法的鲁棒性和重复性表现,结果如表 2 所示。AMSARO 在收敛精度上显著优于其他 5 种算法,可以更精确地逼近理论最优值。对于单峰测试函数 $F_1 \sim F_4$ 的寻优,在平均值、标准差、最小值上均

表现优异,算法表现得很稳定,AMSARO 算法的寻优结果均优于其他 5 种优化算法,在单峰 F_5 测试函数上虽有所波动,但差距不大;在多峰函数 $F_6 \sim F_8$ 上,AMSARO 算法收敛精度相较于其他算法各项表现均位居第 1;同时,MARO 算法也表现出了不错的寻优能力。总体而言,在 8 个测试函数中,AMSARO 算法均展现出最优或逼近最优的性能,证明了其优异的收敛精度和稳定性。

表 2 不同优化算法在 8 种测试函数上的寻优结果

Table 2 Optimization results of different algorithms on eight test functions

函数	指标	AMSARO	ARO	MARO	QARO	IARO	IGWO
F_1	平均值	1.00×10^{-211}	6.12×10^{-32}	1.38×10^{-190}	1.22×10^{-38}	1.10×10^{-40}	5.48×10^{-82}
	标准差	$0.00 \times 10^{+00}$	2.18×10^{-31}	$0.00 \times 10^{+00}$	6.58×10^{-38}	5.43×10^{-40}	1.01×10^{-81}
	最小值	$0.00 \times 10^{+00}$	7.83×10^{-42}	$0.00 \times 10^{+00}$	2.33×10^{-57}	2.96×10^{-56}	4.81×10^{-85}
F_2	平均值	1.70×10^{-295}	7.53×10^{-02}	1.34×10^{-173}	8.31×10^{-03}	7.35×10^{-13}	1.59×10^{-58}
	标准差	$0.00 \times 10^{+00}$	2.00×10^{-01}	$0.00 \times 10^{+00}$	3.35×10^{-02}	3.96×10^{-12}	8.57×10^{-58}
	最小值	$0.00 \times 10^{+00}$	8.03×10^{-16}	$0.00 \times 10^{+00}$	1.40×10^{-13}	1.56×10^{-34}	4.16×10^{-67}
F_3	平均值	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$
	标准差	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$
	最小值	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$
F_4	平均值	4.44×10^{-16}	1.51×10^{-15}	4.44×10^{-16}	4.44×10^{-16}	4.44×10^{-16}	4.00×10^{-15}
	标准差	$0.00 \times 10^{+00}$	1.63×10^{-15}	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$	$0.00 \times 10^{+00}$
	最小值	4.44×10^{-16}	4.44×10^{-16}	4.44×10^{-16}	4.44×10^{-16}	4.44×10^{-16}	4.00×10^{-15}
F_5	平均值	$2.70 \times 10^{+01}$	$2.77 \times 10^{+01}$	$2.61 \times 10^{+01}$	$2.62 \times 10^{+01}$	$2.84 \times 10^{+01}$	$2.88 \times 10^{+01}$
	标准差	2.74×10^{-01}	6.12×10^{-01}	2.93×10^{-01}	5.79×10^{-01}	3.13×10^{-01}	2.72×10^{-01}
	最小值	$2.65 \times 10^{+01}$	$2.69 \times 10^{+01}$	$2.54 \times 10^{+01}$	$2.53 \times 10^{+01}$	$2.76 \times 10^{+01}$	$2.81 \times 10^{+01}$
F_6	平均值	1.70×10^{-295}	7.53×10^{-02}	1.34×10^{-173}	8.31×10^{-03}	7.35×10^{-13}	1.59×10^{-58}
	标准差	$0.00 \times 10^{+00}$	2.00×10^{-01}	$0.00 \times 10^{+00}$	3.35×10^{-02}	3.96×10^{-12}	8.57×10^{-58}
	最小值	$0.00 \times 10^{+00}$	8.03×10^{-16}	$0.00 \times 10^{+00}$	1.40×10^{-13}	1.56×10^{-34}	4.16×10^{-67}
F_7	平均值	5.00×10^{-106}	8.41×10^{-18}	3.43×10^{-104}	1.46×10^{-26}	2.70×10^{-22}	3.20×10^{-43}
	标准差	2.69×10^{-105}	4.38×10^{-17}	1.56×10^{-103}	3.41×10^{-26}	5.96×10^{-22}	3.34×10^{-43}
	最小值	$0.00 \times 10^{+00}$	1.80×10^{-21}	$0.00 \times 10^{+00}$	1.99×10^{-30}	1.09×10^{-27}	2.06×10^{-44}
F_8	平均值	3.09×10^{-123}	1.27×10^{-13}	5.17×10^{-89}	2.09×10^{-15}	2.01×10^{-16}	7.81×10^{-31}
	标准差	1.39×10^{-122}	2.99×10^{-13}	2.78×10^{-88}	5.42×10^{-15}	4.42×10^{-16}	4.21×10^{-30}
	最小值	$0.00 \times 10^{+00}$	1.01×10^{-18}	$0.00 \times 10^{+00}$	5.05×10^{-20}	5.50×10^{-22}	4.85×10^{-38}

3 煤与瓦斯突出预警模型

3.1 基学习器选择池

构建 Stacking 模型的关键是选取第 1 层和第 2 层学习器。第 1 层基学习器应尽可能强大和多样,以覆盖问题的范围和问题域内尽可能多的异常。因此,本研究选择多种典型机器学习模型作为候选,包括:逻辑回归(logistic regression, LR)、随机梯度下降(stochastic gradient descent,SGD)、决策树(decision tree,DT)、RF、自适应提升(AdaBoost)、极端随机树(extra trees,ET)、SVM、高斯朴素贝叶斯(Gaussian naive Bayes,GNB)、K 近邻(K near neighbour, KNN)、多层感知器(multi-layer perceiver, MLP)、极端梯度提升机(XGBoost)、轻量梯度提升机(LightGBM)、梯度提升机(gradient boosting machine, GBM),涵盖“树模型、线性模型、集成模型、SVM、神经网络”等,确保选择池中候选模型的多样性。

3.2 DE 基学习器选择

现有的 Stacking 算法研究中依靠人们经验的基分类器选择方法很难在众多的基分类器中选择出最优的基分类器组合,为了突破这一局限,本研究将 Stacking 集成方法与 DE 优化方法结合使用,侧重于从模型集成方面进行研究,利用混淆矩阵的皮尔森相关系数法度量基分类器间混淆矩阵的差异性,以集成准确率最高及基分类器间差异性最大为目标,动态优化所有基学习器的权重^[24],得到一个最优权重向量组合,该向量的每个分量对应一个基学习器的重要性权重,权重越高表示该个体对集成的贡献越大^[25]。选择排名靠前的 N 个学习器作为最优基分类器组合,最后每个基分类器根据不同权重加权求和,如图 3 所示。具有最佳权重的基学习器对集成的贡献更大,正确预测瓦斯突出的可能性更高。

定义适应度函数为:

$$f(\mathbf{w}) = -\{r_1 \text{Acc}(\mathbf{V}_{\text{stack}}(\mathbf{w}, \mathbf{F}_{\text{meta}})) + r_2 [1 - \overline{\text{sim}}(\mathbf{M}_{\text{sel}})]\} \quad (22)$$




图 3 DE 优化算法流程

Fig. 3 DE optimization algorithm flow chart

$$r_1 > 0, r_2 > 0, r_1 + r_2 = 1 \quad (23)$$

式中: r_1, r_2 为性能与差异性的权重系数, 本文设定 $r_1 = 0.8, r_2 = 0.2$; w 表示基模型权重向量, 维度等于基模型数量, 每个元素 $w_i \in [0, 1]$, 表示第 i 个模型在集成中的权重; F_{meta} 为基模型在交叉验证下生成的二级特征矩阵; M_{sel} 为基模型。

3.3 AMSARO 参数优化

超参数需在模型训练之前手动设置,选择不当易导致煤与瓦斯突出预测模型过拟合、欠拟合或收敛缓慢,从而限制其泛化能力和预测精度。参数优化的一般方法有网格搜索、随机搜索、贝叶斯优化等,通常与交叉验证相结合,适用于单参数优化,但在多参数优化中因组合爆炸问题表现不佳。因此,本研究选择 AMSARO 来优化 Stacking 预警模型的超参数,具体流程如图 4 所示。为了充分体现煤




图 4 AMSARO 优化算法流程

Fig. 4 AMSARO optimization algorithm flowchart

与瓦斯突出预警各环节之间的关联,搭建如图 5 所示的 DE-AMSARO-Stacking 模型。




图 5 DE-AMSARO-Stacking 框架
Fig. 5 DE-AMSARO-Stacking framework

4 实验与分析

4.1 数 据

1)数据来源与描述

选取文献[26]中山西某矿 3# 煤层及矿井相关资料整理而来的 50 组数据进行分析,该数据包含 13 个影响因素,分别是煤的破坏类型 x_1 、煤的瓦斯放散初速度 $x_2(\Delta p)$ 、煤的坚固性系数 $x_3(f)$ 、煤层瓦斯含量 x_4 (单位为 $\text{m}^3 \cdot \text{t}^{-1}$)、3 组 K_1 瓦斯解吸量 $x_5 \sim x_7$ (单位为 $\text{mL} \cdot (\text{g} \cdot \text{min}^{0.5})^{-1}$)、3 组钻屑量 $x_8 \sim x_{10}$ (单位为 $\text{kg} \cdot \text{m}^{-1}$)、与地质构造带的距离 x_{11} (单位为 m)、煤的埋深 x_{12} (单位为 m)、煤厚 x_{13} (单位为 m)。并以现场打钻时是否发生喷孔、顶钻及代表突出的动力现象作为是否具有突出危险性的依据,未采取措施认为没有突出危险性,用 0.1 表示;打 12~15 组泄压钻孔代表突出危险性一般,用 0.6 表示;打 20 组及以上泄压钻孔代表突出危险性严重,用 1 表示^[27]。为了便于进一步分析处理,将原始数据中突出危险依次编码为 0(无突出危险),1(一般突出危险),2(严重突出危险)。

2)数据预处理

(1)样本类平衡

在原始数据中,严重突出危险样本远少于无突出或一般突出样本,数据的不均衡直接影响分类预测的准确性,因此采用随机过采样方法实现不同标签样本量的均衡。

(2)数据扩充

使用 CTGAN 方法学习原始数据样本的内部分布信息,从而得到与小样本分布一致的生成样本,然后将生成样本添加到原样本中共 500 组以达到数据增强的作用。

(3)归一化处理

由于各影响因素的数据间存在单位不统一的问题,为了消除不同量纲的影响,提高计算效率,把数据限制在需要的一定范围内,对所有因素进行归一化处理,本文中利用极值化方法。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (24)$$

式中: x 为原始数据点; $x_{\min}$ 为数据集中的最小值; $x_{\max}$ 为数据集中的最大值; x' 为归一化后的数据点。

3)样本数据相关性

为了判断生成数据分布与原始数据是否相似,采用皮尔逊相关系数对生成数据和原始数据的相关性进行评价。由图 6 可知,生成数据各属性之间的相关性和原始数据各属性的相关性非常接近,说明生成数据能够很好地表达原始数据的分布特征。数据质量较高,可用于后续的特征筛选、模型训练等进一步分析。


4)评价指标

本研究将煤与瓦斯突出等级分为 I、II、III 这 3 类。以下指标可以更直观的观察模型的性能。


准确率表示正确预测的样本占总样本的比例。

$$\text{Accuracy} = \frac{\sum_{i=1}^3 N_{ii}}{\sum_{i=1}^3 \sum_{j=1}^3 N_{ij}} \quad (25)$$

精确率是指预测为某一水平的所有样本中真阳性所占的比例。它反应了模型预测的准确性以及它们在多大程度上满足实际需求。不同瓦斯突出等级的精度应分别计算。



(a) 原始数据
(a) Original data



(b) 生成数据
(b) Generated data

图 6 原始数据与生成数据相关性

Fig. 6 Correlation between original data and generated data

$$\text{Precision}_i = \frac{N_{ii}}{\sum_{k=1}^3 N_{ik}} \quad (26)$$

召回率是指某一水平的真正正数在该水平所有原始样本中的占比。它反映了模型正确识别相关样本并满足实际需求的能力。不同瓦斯突出等级的召回率应分别计算。

$$\text{Recall}_i = \frac{N_{ii}}{\sum_{k=1}^3 N_{ik}} \quad (27)$$

为了兼顾准确率和召回率, F1 分数是一个有效的评价指标。

$$F1 = \frac{2 \times \text{Precision}_i \times \text{Recall}_i}{(\text{Precision}_i + \text{Recall}_i)} \quad (28)$$

4.2 基学习器评估与选择

1) 基学习器评估

为了避免基学习器选择浪费在无效模型上, 先对候选池中的模型单独训练进行初步筛选, 确保进入后续步骤的模型至少具备基础的预测能力。评估维度包括交叉验证均值准确率、交叉验证标准差、预测集准确率、精确率、召回率、F1 分数, 为后续 DE 算法储备更适合煤与瓦斯突出预警任务的基学习器, 同时降低 DE 搜索的复杂度。

通过对比表 3 候选模型单独训练指标及图 7 可视化情况, 整体从交叉验证均值、准确率、F1 分数等核心指标来看, RF、LightGBM、GB、XGBoost、ET 这 5 个模型表现最优, CV 均值 ≥ 0.93 , 准确率 ≥ 0.89 , $F1 \geq 0.888$; DT、KNN、MLP、SVM、LR 的 CV 均值在 0.89~0.93 之间, 准确率在 0.84~0.88 之间, $F1 \geq 0.839$, 处于中等水平; 而 SGD、AdaBoost、GNB 表现较弱, CV 均值 ≤ 0.855 , 准确

率 ≤ 0.79 , $F1 \leq 0.783$, 同样从代表模型稳定性的交叉验证标准差来看, GB、ET、LightGBM 的标准差较小, 说明模型在不同数据集上的预测结果波动小, 泛化能力更稳定。而 AdaBoost、GNB 和 SGD 的标准差较大, 对数据分布变化敏感, 实际应用中预测结果可能不稳定。综合以上, SGD 和 AdaBoost、GNB 为该预警任务下的弱势模型, 予以剔除。

2) 基于 DE 优化权重的基学习器选择

性能最优的单个分类器集成效果并不一定是最佳的。在选择 Stacking 模型的基学习器时, 不仅要关注单一模型的预测性能, 还要考虑模型之间的差异性以及对集成模型的贡献, 以选择合适的基学习器提升模型性能。

为了满足模型轻量化原则, 将所选基学习器阈值设置为 3, 则最后确定最优的基分类器组合为 RF、SVM、XGBoost, 如表 4 所示, 考虑到 Stacking 第 2 层元学习器的核心任务是处理基学习器的输出, 复杂模型会增加过拟合风险, 因此选择 LR 这一简单稳定的模型作为元学习器。

4.3 特征选择

DE 特征选择可视为一个二进制优化问题, 特征选择的取值为 0 或 1。假设 DE 算法种群中每个个体的位置为 $\mathbf{X}_i = \{x_{i1}, x_{i2}, \dots, x_{in}\}$, 在算法中将个体的运动范围限制在 $[0, 1]$, 即 $x_{i,j} \in [0, 1]$, 则个体位置可以表示为一个矢量。将连续空间中的个体位置转化成长度为 d 的二进制位置 $\mathbf{X}'_i = \{x'_{i1}, x'_{i2}, \dots, x'_{in}\}$, 其中 $x'_{i,j} \in \{0, 1\}$, d 为特征个数。每个 $x'_{i,j}$ 表示一个特征, 值为 0、1 分别表示该特征未被选择和该特征被选择。个体的二进制位置 $\mathbf{X}'_i$ 可以由式 (29) 得到:

表 3 候选模型单独训练指标

Table 3 Individual training metrics of candidate models

模型	交叉验证均值	交叉验证标准差	准确率	精确率	召回率	F1 分数
LR	0.890 0	0.031 024	0.840 0	0.844 353	0.854 978	0.839 461
SGD	0.832 5	0.043 732	0.790 0	0.802 791	0.851 307	0.783 487
DT	0.920 0	0.018 708	0.880 0	0.883 890	0.888 612	0.878 747
RF	0.940 0	0.020 000	0.920 0	0.923 162	0.923 529	0.918 965
AdaBoost	0.855 0	0.060 519	0.720 0	0.735 477	0.802 567	0.706 571
ET	0.952 5	0.016 583	0.890 0	0.895 384	0.900 786	0.889 316
SVM	0.930 0	0.023 184	0.850 0	0.853 877	0.863 344	0.848 124
GNB	0.735 0	0.055 565	0.710 0	0.680 989	0.702 381	0.662 596
KNN	0.922 5	0.024 238	0.870 0	0.874 366	0.881 914	0.869 562
MLP	0.915 0	0.025 495	0.860 0	0.860 901	0.863 492	0.857 531
XGBoost	0.932 5	0.018 708	0.900 0	0.902 408	0.903 253	0.898 598
LightGBM	0.942 5	0.016 956	0.900 0	0.902 408	0.903 253	0.898 598
GB	0.940 0	0.014 577	0.890 0	0.893 149	0.895 752	0.888 693




图 7 候选模型单独训练指标可视化

Fig. 7 Visualization of individual training metrics for candidate models

表 4 不同基模型权重

Table 4 Different base model weights

基模型	权重	基模型	权重
LR	0.012 680 98	KNN	0.019 294 76
DT	0.046 790 86	MLP	0.109 499 68
RF	0.376 652 59	XGBoost	0.893 820 12
ET	0.075 994 96	LightGBM	0.301 271 92
SVM	0.407 055 26	GB	0.259 071 82

$$\mathbf{x}'_{i,j} = \begin{cases} 1, & \text{rand} < \mathbf{x}_{i,j} \\ 0, & \text{其他} \end{cases} \quad (29)$$

式中： $\mathbf{x}_{i,j}$ 表示 DE 种群中第 i 个个体在连续空间中第 j 维的数值； rand 为 $[0,1]$ 之间的随机数。

通过二进制掩码 $\mathbf{x}$ 动态筛选特征，评估不同子集的效果。如表 5 所示，特征 2,3,4,7,9,11,12,13 被选中构成一个特征子集，特征 1,5,6,8,10 表示未被选中。

表 5 一组特征选择解

Table 5 A set of feature selection solutions

变量	$\mathbf{x}'_{i,1}$	$\mathbf{x}'_{i,2}$	$\mathbf{x}'_{i,3}$	$\mathbf{x}'_{i,4}$	$\mathbf{x}'_{i,5}$	$\mathbf{x}'_{i,6}$	$\mathbf{x}'_{i,7}$	$\mathbf{x}'_{i,8}$	$\mathbf{x}'_{i,9}$	$\mathbf{x}'_{i,10}$	$\mathbf{x}'_{i,11}$	$\mathbf{x}'_{i,12}$	$\mathbf{x}'_{i,13}$
$\mathbf{X}'$	0	1	1	1	0	0	1	0	1	0	1	1	1

为了评估所提方法的有效性,对比表 6 中 DE 优化后的基学习器子集与全候选集、随机子集的性能,同时测试了单个机器学习模型在预测煤与瓦斯突出方面的性能。可以得出筛选基学习器的各项指标均高于单个学习器,准确率较 RF 提升 2.66%,较 XGBoost 提升 6%,且显著优于其他随机子集和全候选集。

表 6 DE 优化后不同基学习器组合性能对比
Table 6 Performance comparison of different base learner combinations after DE optimization

基学习器	准确率	精确率	召回率	F1 分数
RF	0.926 7	0.925 9	0.925 6	0.925 2
SVM	0.933 3	0.933 0	0.932 4	0.931 9
XGB	0.893 3	0.892 6	0.892 6	0.890 8
RF+SVM+XGB	0.953 3	0.954 2	0.953 4	0.953 8
AdaBoost+GNB+LightGBM	0.920 0	0.923 8	0.923 8	0.923 8
LR+KNN+LightGBM	0.946 7	0.948 4	0.945 7	0.946 9
RF+SVM+MLP	0.926 7	0.926 4	0.925 9	0.925 0
全候选集	0.933 3	0.934 4	0.942 0	0.936 7

通过 DE 优化算法实现基学习器选择,既避免了人工选择的主观性,又通过多样性保障与性能最优的双重约束,确保基学习器能有效支撑 Stacking 模型的预测能力提升。如表 7 所示,DE 算法选择的基学习器组合性能最优,准确率较 AHP-Stacking 选择提升 2.67%、较 AHC-Metropolis-Stacking 选择提升 0.67%,验证了 DE 算法在性能和多样性平衡上的优势。对比算法虽能筛选出有效组合,但因仅考虑单一维度,没有结合集成性能动态优化,导致效果低于 DE 的双目标优化。

为了体现 DE 筛选基学习器的优越性,选取了 AHP^[28]和 AHC-Metropolis^[29]两种基学习器选择方法进行对比,

表 7 不同基学习器选择算法比较
Table 7 Comparison of different base learner selection methods

选择方法	基学习器组合	准确率	精确率	召回率	F1 分数
DE-Stacking	RF+SVM+XGB	0.946 7	0.946 0	0.947 8	0.946 5
AHP-Stacking	LR+RF+SVM	0.920 0	0.918 4	0.920 5	0.919 2
AHC-Metropolis-Stacking	DT+MLP+LR	0.940 0	0.939 5	0.928 8	0.932 5

4.4 Stacking 模型超参数设置

本研究选择 AMSARO 来优化 Stacking 预警模型的超参数,设定适应度函数为 1 与模型的准确率之差,函数值越小,表示模型性能越优异,即模型能够更加准确的对煤与瓦斯突出进行预警。单个机器学习模型的参数设置如表 8 所示。

表 8 AMSARO 优化后单一模型的超参数设置
Table 8 Hyperparameter settings of single models after AMSARO optimization

模型	超参数	取值
RF	n_estimators	280
	max_features	0.14
SVM	C	99.64
	kernel	Poly
	gamma	1.442
	degree	2
XGBoost	n_estimators	317
	learning_rate	0.182

为了验证 DE-AMSARO-Stacking 模型的预测性能,与 WOAmM、MSHBA、IGWO、ARO 等不同算法优化后的 Stacking 模型进行对比,预测效果如表 9 所示,在测试集上通过精确率、准确率、召回率、F1 分数 4 项核心指标评估模型性能。实验中 Stacking 模型的基学习器均为经 DE 算法筛选的 RF、SVM、XGBoost 组合与共同的特征子集,元学习器为 LR,确保仅参数优化算法为唯一变量。

表 9 不同优化算法优化后模型的预测效果
Table 9 Prediction performance of models optimized by different algorithms

模型	精确率	准确率	召回率	F1 分数
DE-WOAmM-Stacking	0.940 0	0.939 6	0.939 1	0.938 9
DE-MSHBA-Stacking	0.946 7	0.946 9	0.946 9	0.946 9
DE-IGWO-Stacking	0.926 7	0.928 5	0.933 5	0.929 6
DE-ARO-Stacking	0.933 3	0.938 2	0.942 1	0.939 3
DE-AMSARO-Stacking	0.973 3	0.972 6	0.974 7	0.973 4

从 4 项指标的综合表现来看,AMSARO 对 Stacking

模型的超参数优化效果最优,其优化后的模型在所有评估指标上均显著领先于其他算法,且与 IGWO 的性能差距超过 4%,验证了 AMSARO 在复杂超参数空间搜索中的优越性,使用 AMSARO 进行参数优化,提高了 Stacking 的模型的性能。

4.5 消融实验

由于 DE 在本文具有 3 部分功能:分别为基学习器选择、特征选择、对所选基学习器预测结果进行加权。为了体现各部分功能的作用大小,设计了如表 10 所示的消融实验,3 个功能分别记为 A、B、C。M0 是基础的 Stacking,其性能是所有模型中最低的,说明 A、B、C 这 3 个功能的加入确实能提升模型效果。M1、M2、M3 可以用来分析单一功能的影响,其中 B 有基础增益,A 的单一作用略强于 C,其单一作用是 3 个功能里最强的;A+B 的组合功能与 A+C 功能相当,与 B+C 相比更有优势;而同时加入 ABC 是所有模型中最好的。综合来看,3 个功能的重要性顺序为 A>C>B,基学习器选择和加权预测结果是提升模型性能的关键,特征选择的单独作用相对较弱,但和 AC 组合后效果显著。

表 10 消融实验
Table 10 Ablation experiment

模型	配置	准确率	精确率	召回率	F1 分数
M0	Stacking	0.900 0	0.917 0	0.910 7	0.905 1
M1	A-Stacking	0.946 7	0.946 0	0.947 8	0.946 5
M2	B-Stacking	0.913 3	0.919 8	0.918 0	0.917 2
M3	C-Stacking	0.940 0	0.936 8	0.937 6	0.937 2
M4	AB-Stacking	0.953 3	0.954 2	0.953 4	0.953 8
M5	BC-Stacking	0.946 7	0.948 6	0.951 7	0.949 9
M6	AC-Stacking	0.953 3	0.957 4	0.958 0	0.957 2
M7	ABC-Stacking	0.960 0	0.962 6	0.959 5	0.960 9

最后选取 FS-WOA-Stacking 模型、XGBoost-GR-Stacking 模型进行对比,如表 11 所示,本文所构建模型优势比较明显,是三者中性能最优的模型,而 XGBoost-GR-Stacking 虽然表现稍弱,但仍然能更好地满足分类任务。

表 11 其他模型对比
Table 11 Comparison of other models

模型	准确率	精确率	召回率	F1 分数
FS-WOA-Stacking	0.965 2	0.963 3	0.964 5	0.962 6
XGBoost-GR-Stacking	0.942 9	0.944 3	0.944 3	0.944 3
DE-AMSARO-Stacking	0.973 3	0.972 6	0.974 7	0.973 4

5 结 论

为解决传统 Stacking 模型在煤与瓦斯突出预警中基学习器选择主观、冗余,超参数优化效率低的问题,本文提

出 DE-AMSARO-Stacking 预警模型,得出结论如下:首先,通过构建含 13 种机器学习模型的候选池,经单独训练初筛后,以集成准确率最高和基学习器差异性最大为目标,采用 DE 算法动态优化权重,筛选出 RF、SVM、XGBoost 为最优基学习器组合,并同步完成特征选择,有效剔除冗余信息,避免人工选择主观性;其次,提出融合精英记忆池与多策略自适应选择机制的 AMSARO 算法,在 8 个经典测试函数中,其收敛精度、速度与稳定性均优于 ARO 及其他改进算法,将其用于 Stacking 模型超参数优化,模型准确率、精确率、召回率、F1 分数分别达 0.973 3、0.972 6、0.974 7、0.973 4,较 DE-IGWO-Stacking 等对比模型提升超 2%;该模型为煤与瓦斯突出预警提供高效的新方法,对矿井灾害防控具重要应用价值,有望为智慧矿山建设、深部资源安全开采提供更加强有力的技术支撑。

参考文献

[1] 王小生,尹亚红,涂军,等. 基于 PSO-KELM 的煤与瓦斯突出预测研究[J]. 能源与环保,2025,47(3):60-64.
WANG X SH, YIN Y H, TU J, et al. Research on coal and gas outburst prediction based on PSO-KLEM[J]. China Energy and Environment Protection, 2025, 47(3): 60-64.

[2] 薛生,郑晓亮,袁亮,等. 基于机器学习的煤与瓦斯突出预测研究进展及展望[J]. 煤炭学报,2024,49(2):664-694.
XUE SH, ZHENG X L, YUAN L, et al. A review on coal and gas outburst prediction based on machine learning[J]. Journal of China Coal Society, 2024, 49(2): 664-694.

[3] 王恩元,张国锐,张超林,等. 我国煤与瓦斯突出防治理论技术研究进展与展望[J]. 煤炭学报,2022,47(1):297-322.
WANG EN Y, ZHANG G R, ZHANG CH L, et al. Research progress and prospect on theory and technology for coal and gas outburst control and protection in China[J]. Journal of China Coal Society, 2022, 47(1): 297-322.

[4] LIU H B, DONG Y J, WANG F ZH. Gas outburst prediction model using rough set and support vector machine[J]. Evolutionary Intelligence, 2022, 15(4): 2445-2453.

[5] WU Y Q, GAO R L, YANG J ZH. Prediction of coal and gas outburst: A method based on the BP neural network optimized by GASA[J]. Process Safety and Environmental Protection, 2020, 133: 64-72.

[6] 陈利成,陈建宏. 基于数据填补-机器学习的煤与瓦斯突出预测效果研究[J]. 中国安全生产科学技术, 2022,18(9):69-74.

- CHEN L CH, CHEN J H. Study on prediction effect of coal and gas outburst based on data imputation and machine learning[J]. Journal of Safety Science and Technology, 2022, 18(9): 69-74.
- [7] 林海飞,周捷,金洪伟,等. 基于特征选择与机器学习的煤与瓦斯突出危险等级协同预测方法[J]. 采矿与安全工程学报, 2023, 40(2): 361-370.
- LIN H F, ZHOU J, JIN H W, et al. Cooperative prediction method of coal and gas outburst risk grade based on feature selection and machine learning algorithm [J]. Journal of Mining & Safety Engineering, 2023, 40(2): 361-370.
- [8] RU Y D, LYU X F, GUO J K, et al. Real-time prediction model of coal and gas outburst [J]. Mathematical Problems in Engineering, 2020(1): 2432806.
- [9] 阎馨,吴书文,屠乃威,等. 基于逻辑回归和增强学习的煤与瓦斯突出预测[J]. 控制工程, 2021, 28(10): 1983-1988.
- YAN X, WU SH W, TU N W, et al. Prediction of coal and gas outburst based on logistic regression and reinforcement learning [J]. Control Engineering of China, 2021, 28(10): 1983-1988.
- [10] ZHENG X L, LAI W H, ZHANG L, et al. Quantitative evaluation of the indexes contribution to coal and gas outburst prediction based on machine learning[J]. Fuel, 2023, 338: 1-10.
- [11] GUO Y L, LIU H B, ZHOU X, et al. Research on coal and gas outburst risk warning based on multiple algorithm fusion[J]. Applied Sciences, 2023, 13(22): 12283.
- [12] 王超,张绍源,刘宇,等. 高维小样本下煤与瓦斯突出集成学习预测模型[J]. 矿业科学学报, 2025, 10(5): 890-899.
- WANG CH, ZHANG SH Y, LIU Y, et al. Ensemble learning model for predicting coal and gas outbursts based on high-dimensional small samples[J]. Journal of Mining Science and Technology, 2025, 10(5): 890-899.
- [13] 王琳,周捷,林海飞,等. 基于 Stacking 集成模型的煤层瓦斯含量预测研究[J]. 煤炭工程, 2024, 56(4): 125-132.
- WANG L, ZHOU J, LIN H F, et al. Coal seam gas content prediction based on Stacking integrated model[J]. Coal Engineering, 2024, 56(4): 125-132.
- [14] 李一恒,孙抗,赵来军. 基于 Stacking 集成学习的无缝钢管连轧电耗预测[J]. 电子测量技术, 2024, 47(8): 53-60.
- LI Y H, SUN K, ZHAO L J. Electricity consumption prediction for seamless steel pipe continuous rolling based on Stacking ensemble learning [J]. Electronic Measurement Technology, 2024, 47(8): 53-60.
- [15] 梁海波,马睿. 基于 Stacking 集成学习的孔隙度预测方法[J]. 电子测量与仪器学报, 2024, 38(12): 202-210.
- LIANG H B, MA R. Porosity prediction method based on Stacking ensemble learning [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(12): 202-210.
- [16] PANT M, ZAHEER H, GARCIA-HERNANDEZ L, et al. Differential evolution: A review of more than two decades of research[J]. Engineering Applications of Artificial Intelligence, 2020, 90: 103479.
- [17] WANG L Y, CAO Q J, ZHANG ZH X, et al. Artificial rabbits optimization: A new bio-inspired meta-heuristic algorithm for solving engineering optimization problems[J]. Engineering Applications of Artificial Intelligence, 2022, 114: 105082.
- [18] 苏湘粤,李永胜,朱永进. 多策略增强型蛇优化器的避障路径规划[J]. 电子测量技术, 2024, 47(16): 174-184.
- SU X Y, LI Y SH, ZHU Y J, et al. Obstacle avoidance path planning of multi-strategy enhanced snake optimizer [J]. Electronic Measurement Technology, 2024, 47(16): 174-184.
- [19] 蔡铭,李响. 基于自适应选择的多策略粒子群算法[J]. 计算机仿真, 2021, 38(3): 239-244.
- CAI M, LI X. Multi-strategy particle swarm optimization based on adaptive selection[J]. Computer Simulation, 2021, 38(3): 239-244.
- [20] 王伟,龙文. 动态透镜成像学习人工兔优化算法及应用[J]. 广西科学, 2023, 30(4): 735-744.
- WANG W, LONG W. Dynamic lens imaging learning artificial rabbits optimization algorithm and its applications[J]. Guangxi Sciences, 2023, 30(4): 735-744.
- [21] ALAMIR N, KAMEL S, HASSAN M H, et al. An effective quantum artificial rabbits optimizer for energy management in microgrid considering demand response[J]. Soft Computing, 2023, 27(21): 15741-15768.
- [22] 邹景. 人工兔优化算法的改进及其在光伏领域优化问题的应用[D]. 成都: 四川师范大学, 2024.
- ZOU J. Improvements of artificial rabbits optimization algorithm and its application in optimization problems of photovoltaic field [D]. Chengdu: Sichuan Normal University, 2024.
- [23] QIN H W, WANG L ZH, SUI M X, et al. Research on

- grey wolf optimization algorithm based on adaptive adjustment strategy[C]. Journal of Physics: Conference Series. IOP Publishing, 2022, 2395(1): 012075.
- [24] MODI A, SWAMI A. Weight optimization through differential evolution algorithm in neural network based ensemble approach[J]. International Journal of Engineering Research & Technology, 2020, 9(1): 359-364.
- [25] 谢哲欣, 李小丽, 蒋金, 等. 复杂堆叠环境下的多类相似弱纹理工件识别方法[J]. 仪器仪表学报, 2025, 46(6): 139-153.
- XIE ZH X, LI X L, JIANG J, et al. A recognition method of multi-class similar workpieces with weak texture in complex stacking environments[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 139-153.
- [26] 孙利源. 基于灰色关联分析和 PSO-SVM 的煤与瓦斯突出预测应用研究[D]. 徐州: 中国矿业大学, 2019.
- SUN L Y. Application research on the coal and gas outburst prediction based on gray correlation analysis and PSO-SVM [D]. Xuzhou: China University of Mining and Technology, 2019.
- [27] 徐耀松, 程业伟. 基于 SKPCA 与 NEAT 算法的煤与瓦斯突出危险性预测[J]. 安全与环境学报, 2021, 21(4): 1427-1433.
- XU Y S, CHENG Y W. Prediction and forecast of the SKPCA with NEAT coal and gas outburst risks[J]. Journal of Safety and Environment, 2021, 21(4): 1427-1433.
- [28] 孙彤, 陈砚桥. 基于 AHP 的 Stacking 算法基分类器选择[J]. 兵工自动化, 2022, 41(1): 39-42.
- SUN T, CHEN Y Q. Base classifiers selection for Stacking algorithm based on AHP [J]. Ordnance Industry Automation, 2022, 41(1): 39-42.
- [29] 王茂光, 冀昊悦, 王天明. 一种基于层次聚类 and 模拟退火的选择性集成算法的风控模型研究[J]. 计算机科学, 2022, 49(11): 201-207.
- WANG M G, JI H Y, WANG T M. Study on risk control model of selective ensemble algorithm based on hierarchical clustering and simulated annealing [J]. Computer Science, 2022, 49(11): 201-207.

作者简介

刘宝玉, 硕士研究生, 主要研究方向为机器学习、数据分析与智能算法设计及应用。

E-mail: liubaoyu@stu.ncst.edu.cn

宋佳铃, 本科, 主要研究方向为智能算法及其应用。

E-mail: 13833242871@163.com

周旭(通信作者), 博士, 副教授, 主要研究方向为机器学习、矿山安全数据分析与智能算法设计及应用。

E-mail: sxzhouxu@126.com