

基于Optuna-RF智能模型的采矿方法优选

许杨丰¹,陈煜新²,周健²,邱贤阳²,田志刚¹

(1. 中金岭南有色金属股份有限公司凡口铅锌矿; 2. 中南大学资源与安全工程学院)

摘要:随着全球工业需求的增加,高效且可靠的采矿方法选择变得至关重要。研究通过结合先进的机器学习技术和自动化超参数优化框架,探索提升采矿方法选择的科学性和精确性。通过收集和分析多种采矿条件及技术经济指标数据,构建了一个基于Optuna的优化随机森林模型。该模型的优化过程专注于调整RF模型的4个关键超参数,旨在提高模型的预测准确率及其泛化能力。试验结果表明,优化后的RF模型在训练集和测试集的分类准确率均明显提高了,Optuna-RF模型优于未优化的RF模型。这一结果验证了自动超参数优化在提升机器学习模型泛化能力和预测精度方面的关键作用,为采矿方法的智能选择提供了一种有效的技术路径。

关键词:人工智能;采矿方法;分类预测;智能模型;自动化;超参数;随机森林;Optuna

中图分类号:TD679

文章编号:1001-1277(2025)08-0007-06

文献标志码:A

doi:10.11792/hj20250802

引言

随着全球工业需求的不断增长,矿产资源的有效开采变得越来越重要。采矿方法的选择是矿业工程中一个复杂而关键的决策过程,它不仅关系到资源的有效利用率,还涉及经济效益、环境影响及工人安全等多个维度^[1-2]。传统的采矿方法选择往往依赖于经验判断,这在处理复杂变量时可能导致出现未能达到最优决策的风险。有效的采矿方法选择需综合考虑诸多因素^[3],包括矿体的厚度、倾角、稳定性等开采技术条件,以及采场的生产能力、采矿效率和成本等技术经济指标,这些因素之间往往表现出明显的非线性关联。

近年来,人工智能技术在众多工业领域展现了其巨大潜力,尤其在处理复杂系统优化问题上表现突出^[4-5]。在采矿方法的优化选择上,人工智能技术的应用也成功展示了其卓越性能^[6-8]。例如:陈建宏等^[9]结合主成分分析和神经网络模型进行采矿方法选择,该组合模型的预测性能相较于单一神经网络有显著提升;ABDELRAOUL等^[10]采用级联前馈反向传播神经网络进行最优采矿方法选择;ÖZYURT等^[11]则开发了一种结合人工神经网络与博弈论的新型地下采矿方法选择模型。

在这一背景下,随机森林(Random Forest, RF)算法作为一种高效的集成学习技术,在众多领域中已证明其能够提供高度准确的预测结果^[12-13]。然而,

RF模型的性能依赖于其超参数的设置。为进一步提升RF模型的预测性能,本研究引入了自动超参数优化框架(Optuna)。Optuna专门设计用于自动化机器学习模型的超参数调优,通过高效的搜索策略能够极大提升模型的性能和适用性^[14]。在本研究中,笔者利用收集到的矿山开采技术条件、技术经济指标及采矿方法的统计数据对提出的Optuna-RF模型进行了训练和测试。为了验证模型的有效性,研究将优化后RF模型的结果与传统未优化的RF模型进行了比较分析,确保模型具有优异的预测精度,为采矿方法的选择提供了一个高效、可靠的决策工具。

1 方法原理

1.1 自动超参数优化框架

Optuna是由AKIBA等^[15]于2019年提出的用于自动超参数优化的开源框架,广泛应用于机器学习项目中以自动寻找最佳的模型参数。Optuna基于3个核心概念^[16]:目标函数(Objective Function)、试验(Trial)和研究(Study)。

1)目标函数:这是一个由用户定义的函数,它接受一组超参数并返回一个数值,通常是模型的性能指标(如准确率、损失等)。目标函数是优化过程的核心,Optuna通过调整超参数来最小化或最大化这一指标。目标函数定义了超参数的搜索空间,用户可以自由定义每个超参数的分布范围。

2)试验:试验代表一次独立的参数评估过程。在

每个试验中,Optuna 选择目标函数的一个参数集合,运行模型,并记录结果。试验不仅评估当前的参数组合,还通过其性能反馈帮助调整后续的搜索策略。Optuna 支持试验的并行执行,大大节省了计算资源并减少了优化过程的总时间。

3)研究:研究是一系列试验的集合,它负责管理整个优化过程。一个研究定义了优化的目标(最小化或最大化)、优化策略及记录所有试验结果的数据库。研究允许用户检视整个优化过程的历史,评估不同超参数的影响,并从中选择最佳的参数配置。

Optuna 以其易用性、灵活性和高效性著称。它采用了一种名为“Tree-structured Parzen Estimator (TPE)”的算法来实施贝叶斯优化,这种算法比传统的网格搜索和随机搜索更有效地探索参数空间。此外,Optuna 设计了剪枝(Pruning)机制,可以在试验过程的中间阶段终止表现不佳的试验,从而节省资源并集中精力在更有前景的参数配置上。Optuna 支持在多个处理器或多台机器上并行执行优化过程,以加快寻找最佳超参数的速度。它还提供了直观的结果可视化工具,帮助用户理解和分析优化过程。总的来说,Optuna 结合了高效的算法、灵活的参数定义方法、强大的剪枝机制及出色的并行处理能力和可视化支持,成为机器学习及其他领域中超参数优化的强大工具。

1.2 随机森林算法原理

随机森林算法是一种集成学习算法,它融合了 Bagging 技术和随机特征选择的方法来构建多棵决策树,从而提供优于传统单棵决策树的分类效果^[1]。RF 算法分类模型结构如图 1 所示,该算法的构建和运行步骤如下:




图 1 RF 算法分类模型结构示意图

Fig. 1 Structure diagram of the RF algorithm classification model

1)数据集的采样:RF 算法通过 Bagging 方法从原始训练数据集 $T=\{(x_1,y_1),(x_2,y_2),\cdots,(x_m,y_m)\}$ 中随机抽取样本,从中选取 N 个样本,形成多个子训练集,每个子训练集用来训练一个独立的决策树。

2)决策树构建:在每棵决策树的构建过程中,RF 算法不是考虑所有可能的特征,而是从所有可用特征 M 中随机选取一个小子集 $m(m \ll M)$,并在这些特征中寻找最优的分裂点来进行节点的划分。这些决策树一般允许生长至很深,除非达到预设的停止条件。虽然深层决策树可能学习到更复杂的数据模式,但也有过拟合的风险。在随机森林中,单棵决策树的过拟合不会影响整体模型的泛化性能,因为它只是森林中的一部分。重复执行上面步骤来生成大量的决策树,这些决策树就会构成随机森林。

3)结果汇总:在分类任务中,每棵决策树对于输入样本都会给出一个预测结果。随机森林通过集成所有决策树的输出,并通过投票机制确定得票最多的类别,作为最终的分类决定。

2 采矿方法优选模型

2.1 数据描述与预处理

基于文献[9],共收集了 15 组关于采矿方法的详细统计数据,涵盖了多种开采技术条件和技术经济指标,如表 1 所示。其中,输入为走向长度(X_1)、厚度(X_2)、倾角(X_3)、矿体稳固性(X_4)、上盘稳固性(X_5)、下盘稳固性(X_6)、采场生产能力(X_7)、采矿效率(X_8)、采矿损失率(X_9)、矿石贫化率(X_{10})、采矿成本(X_{11})。输出为五类采矿方法,分别是留矿采矿法、分层充填采矿法、分段空场采矿法、削壁充填采矿法和全面采矿法,依次记为 1,2,3,4,5。由于所涉及的数据具有不同的量纲和层级,数据间存在显著差异,这可能影响模型的训练和测试效果。为了解决这一问题,并保证数据处理的一致性,研究前对数据进行了标准化处理,依据式(1)将各项指标统一到相同的尺度。

$$z = \frac{x - \mu}{\sigma} \tag{1}$$

式中: x 为原始数据点; μ 为数据集中所有数据的平均值; σ 为数据集中所有数据的标准差。

2.2 超参数优化

为了充分发挥 RF 分类模型的性能潜力,利用 Optuna 进行超参数优化是关键。随机森林模型中几个可优化的关键超参数^[17-19]包括: $n_estimators$ 、 max_depth 、 $min_samples_split$ 、 $min_samples_leaf$ 。这些参数的具体定义及其搜索空间如表 2 所示。通过系统地探索这些参数的配置空间,可以有效提高模型的准确性和泛化能力。

表 1 某矿山开采技术条件及技术经济指标、采矿方法统计数据

Table 1 Statistical data on mining technical conditions, technical and economic indicators, and mining methods of a mine

编号	开采技术条件						技术经济指标					采矿方法标签
	走向长度 X_1/m	厚度 X_2/m	倾角 $X_3/^\circ$	矿体稳 固性 X_4	上盘稳 固性 X_5	下盘稳 固性 X_6	采场生产能 力 $X_7/(\text{t}\cdot\text{d}^{-1})$	采矿效率 $X_8/$ $[\text{t}\cdot(\text{工}\cdot\text{班})^{-1}]$	采矿损失 率 $X_9/\%$	矿石贫化 率 $X_{10}/\%$	采矿成本 $X_{11}/(\text{元}\cdot\text{t}^{-1})$	
F ₁	500.00	1.91	40.50	9	9	9	59.00	9.50	13.50	17.50	13.00	1
F ₂	300.00	1.50	67.50	9	9	9	80.00	14.00	15.90	16.70	13.00	3
F ₃	350.00	0.61	85.07	6	8	8	20.00	3.71	2.52	35.47	22.79	4
F ₄	700.00	0.47	72.54	16	10	10	33.00	7.60	3.96	87.25	11.27	1
F ₅	315.00	5.00	45.00	14	15	15	70.00	12.04	16.20	10.00	23.29	2
F ₆	1 200.00	0.30	29.01	8	8	12	19.00	3.10	6.00	31.40	13.20	5
F ₇	740.00	1.57	47.46	10	10	10	50.00	2.50	5.00	18.00	25.00	2
F ₈	800.00	0.25	70.23	8	8	4	18.00	2.60	18.30	24.50	26.65	4
F ₉	700.00	0.19	42.32	10	9.8	10	21.20	3.80	5.00	57.50	18.26	3
F ₁₀	900.00	1.23	43.54	9	11	11	50.00	7.00	15.00	35.00	87.25	1
F ₁₁	1 150.00	1.52	30.06	10	8	7	35.00	3.40	3.02	7.10	13.80	5
F ₁₂	310.00	3.80	43.05	9	9	4.5	122.00	17.00	13.65	10.00	10.20	3
F ₁₃	1 300.00	0.95	22.03	5	16	3	14.50	2.80	4.15	25.30	14.75	5
F ₁₄	300.00	0.38	77.50	9	9	9	56.00	11.80	5.96	79.90	9.70	1
F ₁₅	320.00	1.50	77.01	12	12	12	50.00	2.26	0.65	16.44	17.40	2

表 2 RF 模型超参数含义及搜索空间

Table 2 Meanings of RF model hyperparameter and their search space

超参数	含义	搜索空间
$n_estimators$	决策树的数量	[1, 100]
max_depth	决策树的最大深度	[1, 32]
$min_samples_split$	内部节点再划分所需的最小样本数	[2, 14]
$min_samples_leaf$	一个叶子节点必须拥有的最小样本数量	[1, 14]

2.3 Optuna-RF 模型

Optuna-RF 模型的构建流程如图 2 所示。具体而言,在构建模型之前,数据集被划分为训练集和测试集。其中,样本编号 F₁~F₁₂ 被选为训练集,而 F₁₃~F₁₅ 则作为测试集。模型的训练过程中,将采用 Optuna 来优化随机森林的 4 个关键超参数,即 $n_estimators$ 、 max_depth 、 $min_samples_split$ 和 $min_samples_leaf$,并设置迭代优化过程为 200 次。达到预定的迭代次数后,将根据 Optuna 优化得出的最优超参数配置完成模型的训练。然后使用独立的测试集来评估模型的性能,其中模型预测的准确率将作为主要评价指标。

3 结果与讨论

3.1 超参数优化结果

在使用 Optuna 对 RF 模型进行超参数优化的过程




图 2 Optuna-RF 模型的构建流程

Fig. 2 Construction process of Optuna-RF model

中,模型在第 42 次迭代时准确率达到了峰值,如图 3 所示。在此次迭代中得到的超参数组合被视作该 RF 模型的最佳参数配置,具体的参数值如表 3 所示。此外,Optuna 还评估了各个超参数对模型性能的贡献度,如图 4 所示。其中, $min_samples_split$ 和 $min_samples_leaf$ 这 2 个参数的调整对优化结果有着较为显著的影响,特别是 $min_samples_leaf$ 的重要性尤其突出。相反, $n_estimators$ 和 max_depth 这 2 个参数在优化结果中的作用相对较小。这表明该模型调优过程中应优先考虑调整 $min_samples_leaf$ 和 $min_samples_split$ 参数,这样的策略更有可能在提高模型的预测准确性方面产生积极效果,而无需通过增加决策树的数量或深度来实现。




图3 Optuna 优化迭代过程
Fig. 3 Optimization and iteration process of Optuna

表3 超参数最佳取值

超参数	<i>n_estimators</i>	<i>max_depth</i>	<i>min_samples_split</i>	<i>min_samples_leaf</i>
最优值	13	6	6	2




图4 超参数重要性
Fig. 4 Importance of hyperparameters

3.2 Optuna-RF 模型预测结果

Optuna-RF 模型训练集的混淆矩阵如图 5 所示。利用 Optuna-RF 模型对测试集进行性能评估。为了凸显 Optuna-RF 模型的性能优势,本文还使用了未优化的 RF 进行比较。值得指出的是,这 2 个模型都是在相同的训练集和测试集上进行评估的。Optuna-RF 模型训练集预测结果与实际值的对比如表 4 所示。从结果对比中可以看出,Optuna-RF 模型在测试集上的准确率远高于未优化 RF 模型的准确率(仅为 67%),这表明经过 Optuna 优化 RF 模型的预测性能有了明显提高。在实际工程应用中,为了进一步增强模型的预测能力,建议根据具体的工程要求,收集更多的案例数据扩充数据库。

3.3 工程实例

中金岭南有色金属股份有限公司凡口铅锌矿(下称“凡口铅锌矿”)属于沉积-改造黄铁矿型层控铅锌矿。金星岭矿体表现为向北倾斜,狮岭矿体则向东倾斜,狮岭南矿体为狮岭矿体的南部延伸区域。矿体形态复杂,产状受构造控制。主矿体的走向长度 X_1 为




图5 Optuna-RF 模型训练集的混淆矩阵
Fig. 5 Confusion matrix of the training set of the Optuna-RF model

表4 Optuna-RF 与 RF 测试集结果对比

training sets			
试样编号	实际值	Optuna-RF 预测值	RF 预测值
F_{13}	5	5	5
F_{14}	1	1	3
F_{15}	2	2	2

800 m,厚度 X_2 为 7.34 m,倾角 X_3 为 60.41° ,矿体稳固性 X_4 为 12,上盘稳固性 X_5 为 9,下盘稳固性 X_6 为 10。采场生产能力 X_7 为 150 t/d,采矿效率 X_8 为 50 t/工班,采矿损失率 X_9 和矿石贫化率 X_{10} 分别为 2.5 % 和 12.5 %,采矿成本 X_{11} 为 150 元/t。由于地质条件复杂,为确保地面建筑物的稳定性,采区内不允许发生地表塌陷。

基于凡口铅锌矿的开采技术条件和相关技术经济指标,利用开发的 Optuna-RF 模型对采矿方法进行了优选,结果如表 5 所示。模型最终预测结果为分层充填采矿法(2),而当前凡口铅锌矿实际采用的采矿方法为上向水平分层充填采矿法(如图 6 所示)。凡口铅锌矿经过多年的采矿实践且结合生产状况和矿体开采技术条件,得出盘区机械化上向分层充填采矿法是较适合的采矿方法,其通过采用高效无轨配套设备对厚大矿体进行强化开采提高了采场生产能力和综合效率^[20]。模型预测与实际情况一致,验证了所构建的采矿方法优选智能模型的预测精度与可靠性。

4 结 论

1)本研究应用 Optuna 来实现 RF 模型超参数的优化,构建的 Optuna-RF 模型在训练集和测试集上的分类准确率有明显提升,较未优化模型(准确率 67 %)表现出显著的性能提升,证明了超参数优化在增强模型泛化能力和预测精度方面的有效性。

表5 凡口铅锌矿开采技术条件、技术经济指标及采矿方法预测结果

Table 5 Prediction results of mining technical conditions, technical and economic indicators, and mining methods for the Fankou Lead-Zinc Mine

开采技术条件						技术经济指标					预测的采矿方法
X_1/m	X_2/m	$X_3/(\text{^\circ})$	X_4	X_5	X_6	$X_7/(\text{t}\cdot\text{d}^{-1})$	$X_8/[\text{t}\cdot(\text{工}\cdot\text{班})^{-1}]$	$X_9/\%$	$X_{10}/\%$	$X_{11}/(\text{元}\cdot\text{t}^{-1})$	
800	7.34	60.41	12	9	10	150	50	2.5	12.5	150	2




图6 凡口铅锌矿上向水平分层充填采矿法

Fig. 6 Method of upward horizontal slicing with backfilling in the Fankou Lead-Zinc Mine

2) Optuna 优化过程显示, $min_samples_split$ 和 $min_samples_leaf$ 对模型性能有显著影响,而 $n_estimators$ 和 max_depth 的影响较小,这表明未来模型优化应聚焦于叶节点和分裂节点的样本数量调整,而不是单纯增加模型的复杂度。

3)基于 Optuna-RF 模型对凡口铅锌矿的采矿方法进行了优选,模型的预测结果与矿山实际情况一致。这一工程实例的应用进一步证明了 Optuna-RF 模型在预测精度和可靠性方面的优越性,为采矿方法的选择与优化提供了有力的技术支持。

[参 考 文 献]

[1] 李永新,王庆磊,吕军恩.呼伦贝尔山金矿业有限公司急倾斜极薄矿体采矿方法研究[J].黄金,2023,44(2):19-21.
[2] 曾令义.低品位倾斜中厚矿体充填采矿法优选[J].黄金,2023,44(2):22-26.
[3] 董国强,王彦,张宏伟.胶东半岛某金矿深部矿体采矿方法优化[J].黄金,2023,44(6):11-14.
[4] 王瑞源.基于采矿地球物理方法的人工智能采矿技术研究——评《采矿地球物理理论与技术》[J].有色金属工程,2022,12(2):146.
[5] 刘明淳,蔣加森,姜海涛,等.基于PCA-EWM-TOPSIS耦合算法的地下开采矿山岩体质量分级[J].黄金,2022,43(6):27-31.
[6] 孙征南.基于人工智能理论的采矿方法选择的研究[D].沈阳:东

北大学,2009.
[7] 徐征军,李雪松,张安.基于人工智能理论的采矿方法选择的研究[J].世界有色金属,2019(17):54-55.
[8] ALI D, FRIMPONG S. Artificial intelligence, machine learning and process automation: Existing knowledge frontier and way forward for mining sector [J]. Artificial Intelligence Review, 2020, 53 (8) : 6 025-6 042.
[9] 陈建宏,刘浪,周智勇,等.基于主成分分析与神经网络的采矿方法优选[J].中南大学学报(自然科学版),2010,41(5):1 967-1 972.
[10] ABDELRASOUL M E I, WANG G, KIM J G, et al. Review on the development of mining method selection to identify new techniques using a cascade-forward backpropagation neural network [J]. Advances in Civil Engineering, 2022, 2022: 1-16.
[11] ÖZYURT M C, KARADOĞAN A. A new model based on artificial neural networks and game theory for the selection of underground mining method[J]. Journal of Mining Science, 2020, 56(1): 66-78.
[12] ZHOU J, HUANG S, ZHOU T, et al. Employing a genetic algorithm and grey wolf optimizer for optimizing RF models to evaluate soil liquefaction potential[J]. Artificial Intelligence Review, 2022, 55(7): 5 673-5 705.
[13] 胡友彪, 据棋定. 基于粒子群优化随机森林的煤矿涌(突)水水源机器学习识别技术[J]. 煤炭科技, 2022, 43(4): 52-60.
[14] 李振华,徐杰,王文强,等.基于 Optuna-LSTM 的矿压预测方法

- 研究[J]. 矿业研究与开发, 2023, 43(3): 98-102.
- [15] AKIBA T, SANO S, YANASE T, et al. Optuna: A next-generation hyperparameter optimization framework[C]//Association for Computing Machinery. Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining. New York: Association for Computing Machinery, 2019: 2 623-2 631.
- [16] 蒋熙梅, 闫伟超, 邢会林, 等. 基于自动超参数优化框架与梯度提升算法融合的储层粒度二维分布预测研究[J]. 地球物理学进展, 2024, 39(5): 1 886-1 900.
- [17] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5-32.
- [18] ZHOU J, HUANG S, QIU Y. Optimization of random forest through the use of MVO, GWO and MFO in evaluating the stability of underground entry-type excavations [J]. Tunnelling and Underground Space Technology, 2022, 124: 104494.
- [19] 张建涛, 刘志祥, 张双侠, 等. 基于WOA-RF的边坡稳定性预测模型[J]. 高压物理学报, 2024(3): 191-202.
- [20] 唐建. 盘区机械化充填采矿工艺在凡口铅锌矿的运用[J]. 采矿技术, 2011, 11(1): 4-5, 10.

Optimal selection of mining methods based on the Optuna-RF intelligent model

Xu Yangfeng¹, Chen Yuxin², Zhou Jian², Qiu Xianyang², Tian Zhigang¹
(1. Fankou Lead-Zinc Mine, Zhongjin Lingnan Non-ferrous Metals Co., Ltd.;
2. School of Resources and Safety Engineering, Central South University)

Abstract: With the growing global demand for industrial resources, the selection of efficient and reliable mining methods has become increasingly critical. This study explores ways to enhance the scientific and accurate selection of mining methods by integrating advanced machine learning techniques with an automated hyperparameter optimization framework. Based on the collection and analysis of various mining conditions and techno-economic indicators, an optimized random forest model based on Optuna was developed. The optimization process focused on tuning 4 key hyperparameters of the RF model to improve its predictive accuracy and generalization performance. Experimental results showed that the optimized RF model evidently improved classification accuracy on both the training and testing datasets. The Optuna-RF model significantly outperformed the unoptimized model. These results demonstrate the crucial role of automated hyperparameter optimization in enhancing the generalization and predictive capabilities of machine learning models and provide an effective technical approach for the intelligent selection of mining methods.

Keywords: artificial intelligence; mining method; classification prediction; intelligent model; automation; hyperparameters; random forest; Optuna