◀钻井技术与装备▶

基于大数据分析和智能技术的PDC钻头选型与参数优化*

叶山林[1] 宋先知[2] 祝兆鹏[1,3] 王超尘[2] 朱 林[1] 刘子豪[2]
（1. 中国石油大学（北京）人工智能学院 2. 中国石油大学（北京）石油工程学院
3. 中国石油大学（北京）机械与储运工程学院）

叶山林，宋先知，祝兆鹏，等. 基于大数据分析和智能技术的PDC钻头选型与参数优化［J］. 石油机械，2026，54（9）：10-18.

Ye Shanlin，Song Xianzhi，Zhu Zhaopeng，et al. PDC bit selection and parameter optimization based on big data analysis and intelligent technology［J］. China Petroleum Machinery，2026，54（9）：10-18.

摘要：随着油田技术聚焦于数字化与智能化转型，钻头选型和参数优选方法也亟须升级和创新，以发挥大数据和智能算法优势，让钻头和参数优选更合理高效。然而现有钻头选型智能模型大多建立在地层抗钻属性与钻头型号的对应关系上，缺乏对更深层原因（如钻头设计特征）的探索。为此，提出一种基于大数据分析和智能技术的钻头选型与参数优选框架。具体作法如下：融合地层岩石力学数据、钻头历史性能表现数据及关键特征数据，构建钻头特征-地层信息与平均进尺-机械钻速间的智能预测模型，评价不同钻头特征组合在测试地层的性能表现，为最优表现的钻头组合匹配已有的钻头型号；基于优选钻头的历史数据，建立钻压-转速与机械钻速的分布热力图，优化钻井参数；利用西南某油田区块实测数据对模型进行验证。研究结果表明：模型在训练集和测试集上的R^2分别达到了0.9及0.8以上，平均绝对百分比误差均小于20%；井深、岩性、地层密度及抗压强度等地层属性对钻头机械钻速和进尺具有显著影响，钻头自身的刀翼数量、主切削齿倾角与齿高等关键参数也对钻头性能发挥着至关重要的作用；在同一井段内，经过参数优选后的钻头可将趟钻次数由原来的5次减少到3次，机械钻速由0～10 m/h提升至10～20 m/h，整体钻井效率明显提高。研究成果可为智能钻井中钻头选型与参数调控提供数据驱动解决方案。

关键词：大数据分析；智能模型；钻头优选；机器学习；参数优化；岩石力学参数
中图分类号：TE921 **文献标识码：**A DOI：10.12473/CPM.202505039

PDC Bit Selection and Parameter Optimization Based on Big Data Analysis and Intelligent Technology

Ye Shanlin[1] Song Xianzhi[2] Zhu Zhaopeng[1,3] Wang Chaochen[2] Zhu Lin[1] Liu Zihao[2]
（1. *College of Artificial Intelligence*, *China University of Petroleum*（*Beijing*）; 2. *College of Petroleum Engineering*, *China University of Petroleum*（*Beijing*）; 3. *College of Mechanical and Transportation Engineering*, *China University of Petroleum*（*Beijing*））

Abstract: As oil-gas field development engineering technology focuses on digital and intelligent transformation, the methods for bit selection and parameter optimization need to be upgraded and innovated urgently. By leveraging the advantages of big data and intelligent algorithms, bit and parameter selection can become more reasonable and efficient. However, most existing intelligent models for bit selection are established based on the corre-

* 基金项目：国家自然科学基金杰出青年基金项目“油气井流体力学与工程”（52125401）；中国石油天然气集团有限公司-中国石油大学（北京）战略合作科技专项“物探、测井、钻完井人工智能理论与应用场景关键技术研究”（ZLZX2020-03）。

© Editorial Office of *China Petroleum Machinery*. OA under CC BY-NC-ND 4.0

spondence between formation drillability properties and bit models, lacking exploration of deeper causes such as bit design characteristics. To address this issue, a framework for bit selection and parameter optimization based on big data analysis and intelligent technology is proposed. Firstly, an intelligent prediction model for bit features-formation information vs. average footage-rate of penetration (ROP) was constructed by integrating formation rock mechanical data, historical bit performance data, and key feature data, to evaluate the performance of different bit feature combinations in the tested formation and match the optimal bit combination with available bit models. Then, based on historical data of the optimized bit, a distribution heat map of weight on bit (WOB)-rotary speed and ROP was established to optimize drilling parameters. Finally, field data from a block of an oilfield in southwest China were used to verify the model. The results show that the R^2 values of the model on the training set and test set reach above 0.9 and 0.8, respectively, both with the mean absolute percentage error (MAPE) less than 20%. Formation properties including well depth, lithology, formation density and compressive strength have significant effects on bit ROP and footage. Key bit parameters such as the number of blades, main cutting tooth inclination angle and tooth height also play a vital role in bit performance. In the same well section, after parameter optimization, the number of bit runs is reduced from 5 to 3, and the ROP is increased from 0-10 m/h to 10-20 m/h, resulting in a significant improvement in overall drilling efficiency. This study provides a data-driven solution for bit selection and parameter regulation in intelligent drilling.

Keywords: big data analysis; intelligent model; bit selection; machine learning; parameter optimization; rock mechanical parameter

0　引　言

在油气勘探开发向深层、超深层及复杂地层拓展的背景下，钻头选型与参数优化已成为制约钻井效率与成本控制的核心问题[1-2]。为地层选择合适的钻头和钻井参数不仅可以提高钻井速度，还能减轻钻头的不规则振动，进而减小磨损速率，延长钻头寿命，为钻井提效和安全提供保障[3]。近年来，油田技术聚焦于数字化与智能化转型[4-5]，钻头选型和参数优选方法亟须升级和创新，发挥大数据和智能算法优势，让钻头和参数优选更合理高效。

钻头选型技术的发展可以总结为3个阶段。早期，专家依据已钻井钻头使用资料，对不同地层的钻头使用情况进行统计，使用每米成本、机械比能等指标实现特定地层的钻头选型[6-7]。此类方法受限于数据样本单一，且无法量化钻头特征与地层参数的动态匹配关系，优选效率低，需要专家结合经验对选型结果进行矫正。后来，通过室内试验或测井数据定量评估地层抗钻属性，依据地层属性匹配钻头型号。苏强等[8]基于岩石可钻性试验建立预测地层可钻性模型，依据可钻性优选川西深井钻头，使钻井周期缩短41.44%。潘起峰等[6]和赵军等[7]综合测井资料计算岩石力学参数，优选PDC钻头，克服取芯局限，在现场应用中使钻速得到提升。张武昌等[9]建立了基于测井资料的砂砾岩地层抗钻特性参数预测模型，结合比能法、机械钻速法和因子分析法开展钻头优选和现场应用，结果显示提速效果明显。此外，一些学者[10-11]采用灰色关联分析评估待钻地层和已钻地层的抗钻参数相似性，优选结果使钻速提升显著，方法科学。然而，此类方法需要试验支撑，试验条件与井下环境不一致，且难以处理高维度、非线性的工程数据。现在，依托大数据技术整合地质、钻井、工具等多源数据，利用随机森林、梯度提升树（GBDT）等机器学习算法构建地层属性、钻头型号与钻头性能表现的预测模型。多数学者选用神经网络建立智能选型模型[12-13]。冯定[12]提出神经网络综合选型法，整合多源数据，使辽河、四川等油田钻头优选符合率达100%，钻速大幅提升。张辉等[13]基于BP神经网络预测岩石抗钻特性优选钻头，现场试验相比于邻井同一层段平均机械钻速提高25%。主成分分析[14]、近邻聚类[15-16]等方法也被尝试应用于钻头智能选型。邹德永等[16]利用模式识别理论，对已钻井地层及使用的钻头进行聚类分析，建立了地层-钻头标准映射模式。该方法在青海油田东坪、牛东区块进行了钻头选型现场试验，结果表明，与未使用推荐钻头的邻井相比，机械钻速和进尺都有了很大提高，提速效果明显。钻头的性能表现与刀翼数量、切削齿直径、后倾角等设计特征

直接相关。但是现在大多数算法都是建立地层抗钻属性与钻头型号的对应关系，缺乏对更深层原因（如钻头设计特征）的探索，一定程度上导致智能模型泛化能力不足、工程应用适配性差等问题。

为此，笔者提出一种基于大数据分析和智能技术的PDC钻头选型与参数优选框架。首先，融合地层岩石力学数据、钻头历史性能表现数据及关键特征数据，构建钻头特征–地层信息与平均进尺–机械钻速间的智能预测模型，评价不同钻头特征组合在测试地层的性能表现，为最优表现的钻头组合匹配已有的钻头型号；然后，基于优选钻头的历史数据，建立钻压–转速与机械钻速的分布热力图，优化钻井参数；最后，利用西南某油田区块实测数据进行验证。研究成果可为智能钻井中的钻头选型与参数调控提供数据驱动解决方案。

1　数据介绍和处理

从西南某油田区块收集了100多口井的钻头使用数据，共包含440只不同型号的钻头。其中金刚石（PDC）钻头304只，牙轮钻头62只，混合钻头74只，PDC钻头占比为69.1%。所选区块地层以泥页岩为主。

图1为不同类型钻头的历史性能表现图。由图1可知，相比于其他类型的钻头，PDC钻头表现较好，平均机械钻速为11.5 m/h，平均进尺为505.2 m，均高于其他类型钻头，所以笔者的研究目标是该区块的PDC钻头选型与参数优选方案。所用数据类型齐全，包含钻头历史使用的工程参数、测井参数、岩石力学参数、钻头关键特征及钻头性能表现，共21种特征参数，详细参数信息如表1所示。其中钻头关键特征是指直接决定钻头破岩机理和钻进效率的几何与结构参数，主要包括以下几类：①刀翼数量，指钻头底部刀翼的个数，数量增加通常有助于增强稳定性，但可能降低单齿切削效率；②布齿密度，指单位面积内布置的切削齿数量，反映钻头切削齿分布紧密程度，影响破岩均匀性和耐磨性；③主切削齿齿高，指主切削齿从齿根到齿顶的高度，决定了切削深度和岩石接触方式；④主切削齿倾角与直径，倾角影响切削齿侵入岩石的角度，直径则与单齿受力和切削效率直接相关；⑤主切削齿类型，如平面齿、三棱齿等，不同类型对应不同的切削机理与地层适应性；⑥轮廓攻击性，指钻头整体轮廓对岩石的侵入能力，一般通过前倾角、刀翼外展角等综合表征，通常分为“弱、中、强”3个等级。这些结构特征与地层抗压强度、硬度、岩性等地层参数相互作用，共同决定钻头在不同井段的机械钻速和进尺表现。

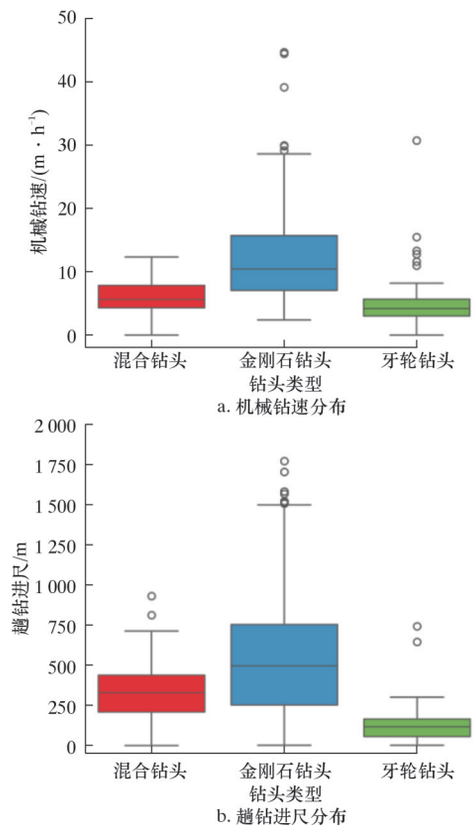


图1　不同类型钻头的历史性能表现图

Fig. 1　Historical performance of different types of bits

表1　用于钻头型号优选建模的数据特征

Table 1　Data features for bit selection modeling

数据类型	特征参数	数量
工程参数	钻压、转盘转速、排量	3
测井参数	井深、岩性密度、伽马、声波时差	4
岩石力学参数	岩性、抗压强度、可钻性、硬度、内摩擦角	5
钻头关键特征	刀翼数量、布齿密度、主切削齿倾角、主切削齿直径、主切削齿齿高、主切削齿类型、轮廓攻击性	7
钻头性能指标	平均进尺、平均钻速	2

在数据处理阶段，按照井深对齐不同类型的数据，并计算每只钻头对应的其他特征参数的平均值，然后删除缺失值和异常值，形成最终的模型训练数据库。在模型训练前采用独热编码对非结构化数据（如岩性、主切削齿类型、轮廓攻击性等）进行向量化处理。

2　选型方案设计与算法原理

2.1　钻头选型流程

依托前文整理的地层-钻头历史数据库，结合机器学习算法建立钻头性能预测模型，实现基于地层性质的钻头特征与型号选择和参数优选。图 2 为钻头选型与参数优选流程图。首先利用已钻井的地层抗钻属性、钻头关键特征和钻头使用效果数据训练机械钻速和趟钻进尺预测的随机森林模型；然后使用邻井的地层抗钻属性数据插值得到待钻井的地层属性；其次采用数据库中固定的钻头特征组合和基于已有特征随机生成新的钻头特征组合，形成钻头特征优选集合；最后将地层属性和钻头特征优选集合输入训练好的机械钻速和趟钻进尺预测模型，输出每种钻头特征组合在对应地层条件下的机械钻速和平均进尺。通过综合效率公式对特征组合进行排序。综合评价效率 E 计算公式如下：

$$E=\frac{\hat{L}-L_{\min}}{L_{\max}-L_{\min}}+\frac{\hat{v}-v_{\min}}{v_{\max}-v_{\min}} \tag{1}$$

式中：E 为钻头特征的综合评价效率；$\hat{L}$ 为预测趟钻进尺，m；$L_{\min}$ 和 $L_{\max}$ 分别为数据库中趟钻进尺最小值和最大值，m；$\hat{v}$ 为预测平均机械钻速，m/h；$v_{\min}$ 和 $v_{\max}$ 分别为数据库中钻头机械钻速最小值和最大值，m/h。

由于趟钻进尺和机械钻速数值相差较大，在计算综合评价效率 E 时，将两者归一化之后的值相加。

根据排序结果，选取对应地层属性条件下最优的钻头特征组合；将钻头特征组合与数据库中的固定钻头组合进行匹配，找到对应的钻头型号；如果钻头组合未能匹配到对应的钻头型号，可以使用优选出的钻头组合指导钻头的设计。

应用所选钻头型号的历史工程数据训练该钻头的性能智能预测模型。通过网格搜索法，生成钻压-转盘转速-排量钻井参数优选集合。输出该型号钻头在不同钻井参数组合下对应的钻头性能指标，选出最优钻头性能条件下的钻压-转盘转速-排量作为推荐钻井参数。

2.2　算法原理介绍

2.2.1　随机森林原理

随机森林是一种集成学习方法，它通过构建多个决策树并将它们的预测结果进行汇总，以提高模型的预测准确性和鲁棒性[17]。算法原理示意图如图 3 所示。在本研究中，随机森林被用来构建地层属性、钻头特征与钻头性能表现之间的预测模型。具体如下：从收集到的钻头使用数据中随机抽取多个样本子集，为每个子集训练一个决策树模型；在训练过程中，通过随机选择特征子集进行节点分裂，增加模型的多样性；将所有决策树的预测结果进行投票或平均，得到最终的预测结果。这种方法能够有效地处理少样本、高维度数据，减小过拟合风险，并增强模型的泛化能力。

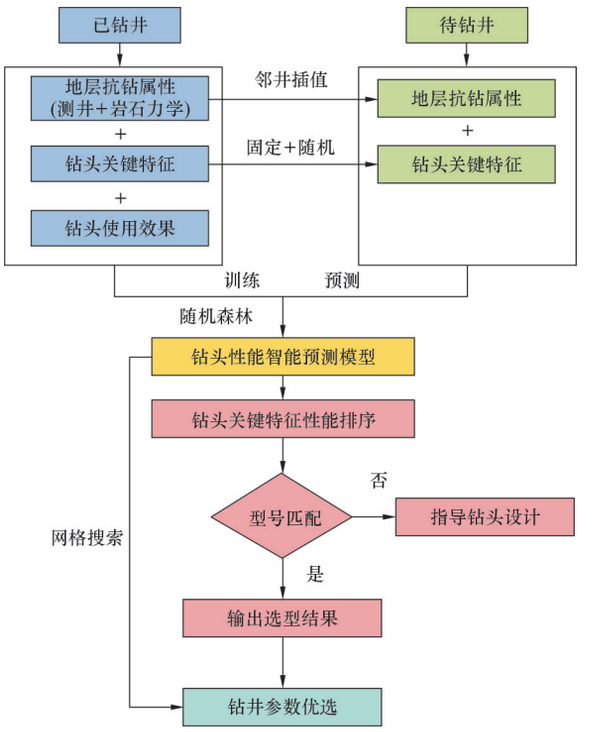


图 2　钻头选型与参数优选流程图

Fig. 2　Flowchart of bit selection and parameter optimization

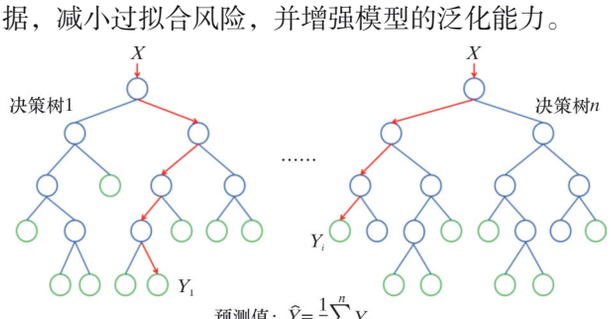


图 3　随机森林算法示意图

Fig. 3　Schematic diagram of random forest algorithm

2.2.2　网格搜索用于随机森林超参数优选和钻井参数优选

网格搜索是一种系统化的参数优化方法，用于寻找给定算法模型的最佳参数组合[18]。算法原理示意图如图 4 所示。在研究中，网格搜索被应用于 2 个关键环节：一是随机森林模型的超参数优选，二是钻井参数的优选。

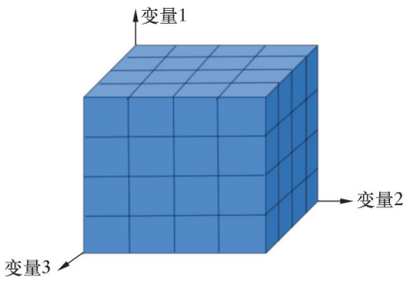


图 4　网格搜索原理示意图

Fig. 4　Schematic diagram of grid search

对于随机森林模型的超参数优选，这里选择了决策树数量、最大深度、最小节点分裂数等关键参数，通过网格搜索遍历所有可能的参数组合，以交叉验证的方式评估每一组参数的预测性能。选择预测性能最优的参数组合作为随机森林模型的最终配置，以提高模型的预测准确性和稳定性。

在钻井参数的优选方面，基于已选定的钻头型号，利用网格搜索方法调整钻压、转速等钻井参数，以最大化机械钻速为目标。通过模拟不同参数组合下的钻井过程，结合历史数据和地层属性信息，评估各参数组合对机械钻速的影响，从而确定最优的钻井参数组合。这种方法能够实现钻井参数的精细化调控，进一步提升钻井效率并降低成本。

2.3　模型评价指标

笔者使用随机森林回归模型来建立钻头特征参数、地层参数与钻头进尺和平均机械钻速的映射关系。回归问题的预测结果可以通过许多指标来衡量，这里采用了 2 个指标，即 R^2（决定系数）和平均绝对百分比误差 E_{MAP}。R^2 代表数据拟合的效果，其值越接近 1，效果越好。E_{MAP} 反映预测值与观测值之间的百分比相对误差，其值越小越好。各指标的计算公式如下：

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2} \tag{2}$$

$$E_{MAP} = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{\hat{y}_i - y_i}{y_i}\right| \times 100\% \tag{3}$$

式中：y_i 为真实值，$\hat{y}_i$ 为预测值，$\bar{y}_i$ 为真实值的平均值，n 为样本数量。

3　案例分析

3.1　趟钻进尺和机械钻速预测智能模型建立

将数据库数据按照 8∶2 的比例划分训练集和测试集。由于数据具有高维稀疏、数量较小的特点，选择使用随机森林作为训练模型，得到钻头特征、地层属性预测趟钻进尺和机械钻速的智能预测模型。在模型训练过程中，使用网格搜索方法对随机森林模型的决策树数量、决策树最大深度、节点分裂最小样本数、叶节点最小样本数进行优选，优选范围如表 2 所示。

表 2　随机森林模型超参数优选范围

Table 2　Random forest model hyper-parameter optimization ranges

优选模型参数	最小值	最大值	网格间隔
决策树数量	50	200	10
决策树最大深度	5	20	1
节点分裂最小样本数	2	10	1
叶节点最小样本数	1	10	1

试验过程发现，当决策树数量和最大深度分别超过 100 和 10 后，会出现过拟合现象，即训练集预测精度持续提高，但测试集预测精度降低。最终选择的超参数组合为：决策树数量 100，决策树最大深度 10，节点分裂最小样本数 2，叶节点最小样本数 1。对应模型的预测效果如图 5 所示，预测精度见图 6a。在该超参数组合下，平均机械钻速和趟钻进尺决定系数训练集在 0.9、测试集在 0.8 以上，相对百分比误差均小于 20%，整体预测效果较好。

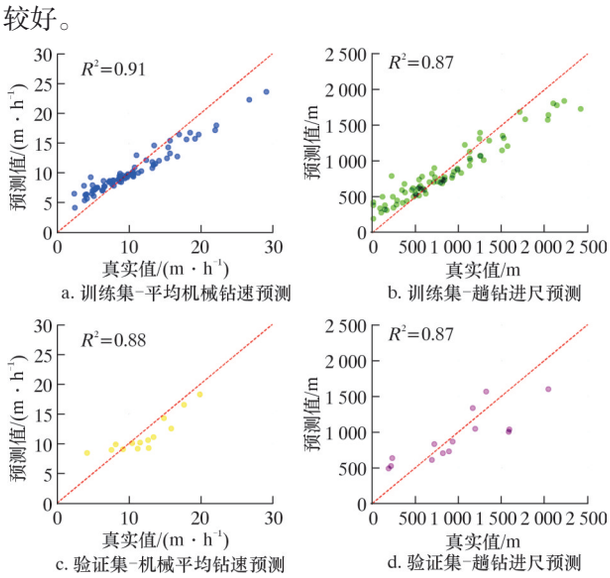
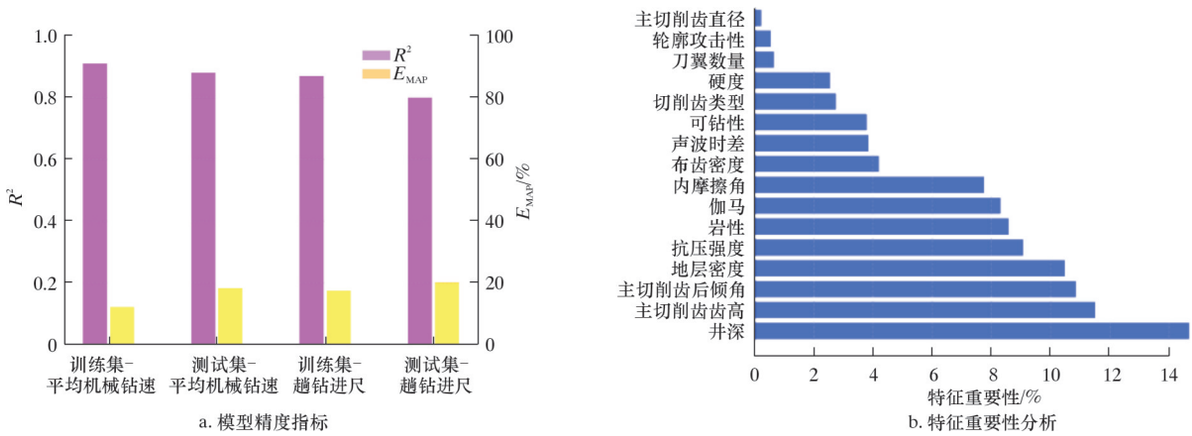


图 5　钻头性能指标智能模型预测结果

Fig. 5　Intelligent prediction model results for bit performance indicators

在随机森林模型训练好后，可以使用 sklearn 代码库中的 feature_importances_方法输出特征对预测的贡献度，结果如图 6b 所示。由图 6b 可以看出，钻头的工作井深对钻头的机械钻速和进尺影



a. 模型精度指标　　b. 特征重要性分析

图 6　钻头性能智能预测模型精度与特征重要性分析

Fig. 6　Accuracy and feature importance analysis of the intelligent prediction model for bit performance

响最为重要，这是因为井深与地层性质密切相关，如岩性、地层密度、抗压强度等特征直接影响钻头表现。此外，钻头的主切削齿齿高、主切削角倾角和布齿密度也是影响钻头表现的重要特征，符合机理认知。刀翼数量、主切削齿直径重要性相对较低，与工程经验不一致，这是因为数据集中这 2 个特征的数据分布范围较窄。刀翼数量和切削齿直径在破岩机理上仍然是关键因素，未来将通过扩充样本进一步改进。影响钻头性能表现的本质是钻头的设计参数特征和地层信息，只关注于型号的选择难以捕捉相关信息。

3.2　钻头特征组合和型号优选

从数据库中选择 1 口井作为算法的应用案例，假设所选井未钻进且没有对应的地层属性数据。首先使用邻井数据插值或者直接使用邻井数据得到本井的地层属性数据。然后将每米地层属性和钻头特征集合输入到钻头性能预测智能模型中，输出每个特征组合在对应地层下的趟钻进尺和机械钻速预测，并通过式（1）计算综合评价效率，为每米地层选出综合评价效率最高时所对应的钻头特征组合。测试井的地层信息和选择的钻头特征信息如图 7 所示。由于邻井 2 300 m 以上无测井数据，所以只对 2 300~5 400 m 的井段进行优选分析。试验井段自上而下穿过的岩性主要为石灰岩、页岩和泥岩，3 种岩性对应的地层属性趋势变化明显。从抗压强度和硬度等指标可以看出上部石灰岩和底部泥岩比较难钻进，页岩相对容易钻进。通过钻头性能预测智能模型，选取对应地层属性条件下最优的钻头特征组合，将钻头特征组合与数据库中的固定钻头组合进行匹配，找到对应的钻头型号，选择其中最优的 3 种型号作为推荐示例，结果如表 3 所示。总体来看，钻头特征组合的推荐符合地层属性的变化趋势，说明模型学习到了地层属性和钻头特征的相互影响关系。

根据匹配到的钻头型号，对比了历史钻头使用情况和所选钻头的历史表现，如图 8 所示。图 8 右侧的蓝色矩形表示该井历史使用钻头，矩形的长度为历史趟钻进尺；蓝色散点表示历史钻头的实际钻速表现；红色、橙色和黑色矩形表示优选钻头及预测趟钻进尺，对应的散点是所选型号钻头在数据库相似地层的历史表现。按照选型结果，测试井段（2 300~5 400 m）趟钻可由原来的 5 次减少到 3 次。3 只优选钻头的预测趟钻进尺分别为 1 180、1 200 和 550 m，并且机械钻速主要分布区间可由原来的 0~10 m/h 提升至 10~20 m/h，钻井总体效率明显提高。

3.3　钻井参数推荐

针对所选出的钻头，检索每只钻头的历史工程数据与机械钻速表现，训练得到对应钻头的机械钻速预测模型。使用网格搜索法，将钻头历史参数的最大和最小值作为网格边界，形成钻压-转速-排量参数的搜索网格，预测机械钻速分布图版，并优选出理想最优机械钻速所对应的钻井参数区间作为推荐结果，如图 9 所示。图 9 中颜色越蓝代表钻速越低，越红代表钻速越高，星号标记了推荐参数位置。推荐结果为建议钻井参数区间，实际应用时须结合现场工况进行调整。从优选结果可以看出，每种型号的钻头在不同井段的最优参数有区别，在钻头选型时应该为每只钻头结合具体的作业井段推荐最优参数组合。

4　结论与展望

（1）通过对 100 多口井、440 只不同型号钻头

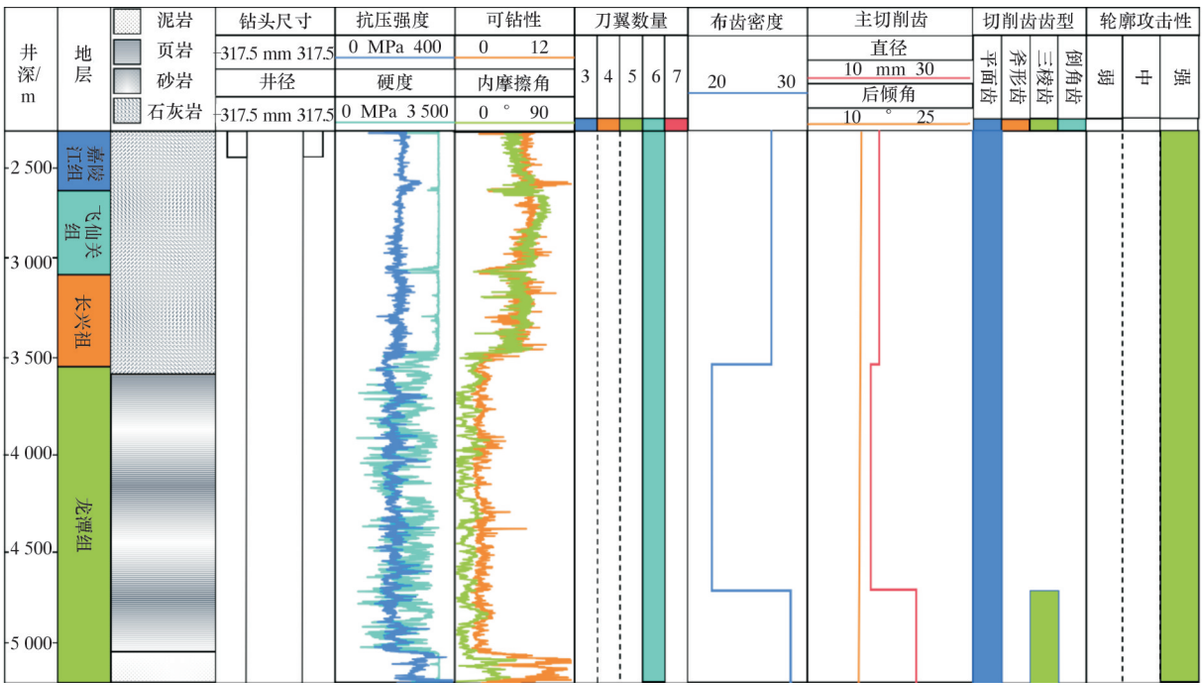


图 7　地层信息和钻头特征优选结果

Fig. 7　Formation information and bit feature selection results

表 3　钻头特征组合和型号优选结果

Table 3　Bit feature combinations and model selection results

井深/m	刀翼数量	布齿密度（切削齿数）	主切削角倾角/(°)	主切削齿直径/mm	主切削齿齿高/mm	主切削齿类型	轮廓攻击性	匹配型号（前三）
2 370~3 550	6	27.0	16	16	5.5~6.5	平面齿	强	KS1652DFGRT、TS516、DF1605BUD
3 550~4 750	6	22.0	15	16	6.0~6.5	平面齿	强	KSD1652AGR、T613B、KSD1652FRTY
4 750~5 400	6	29.4	20	16	4.5~6.5	平面齿+三棱齿	强	KSD1652FRTY、EDS1635MT、KSD1652AGR

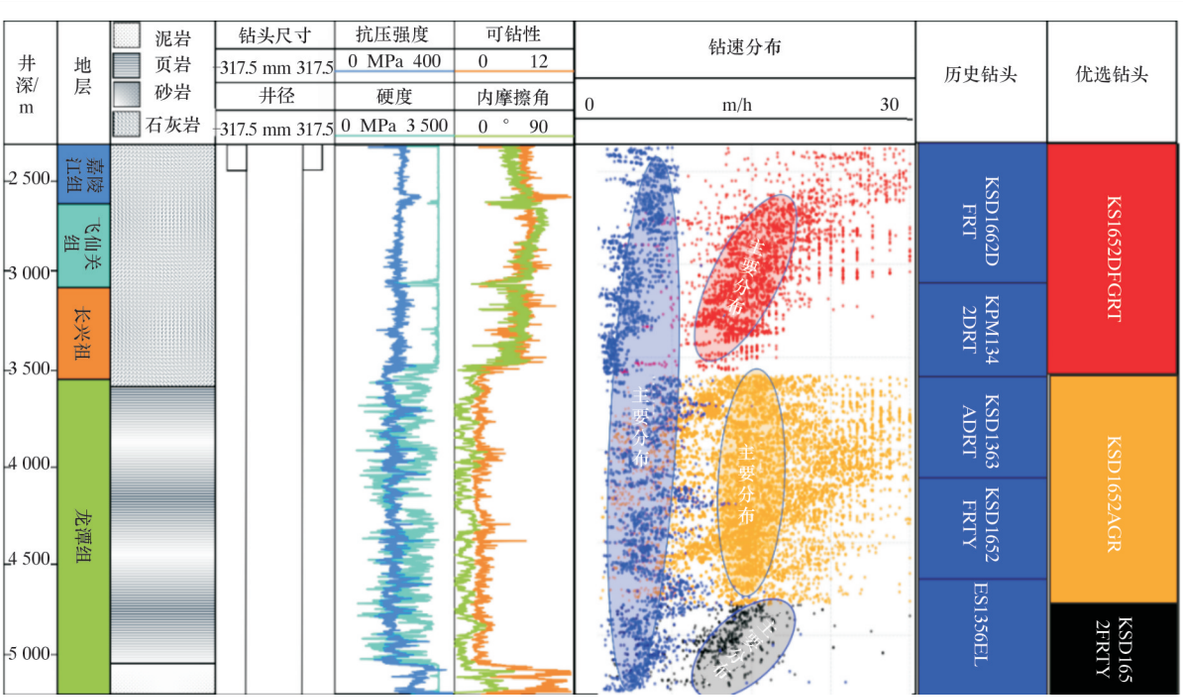
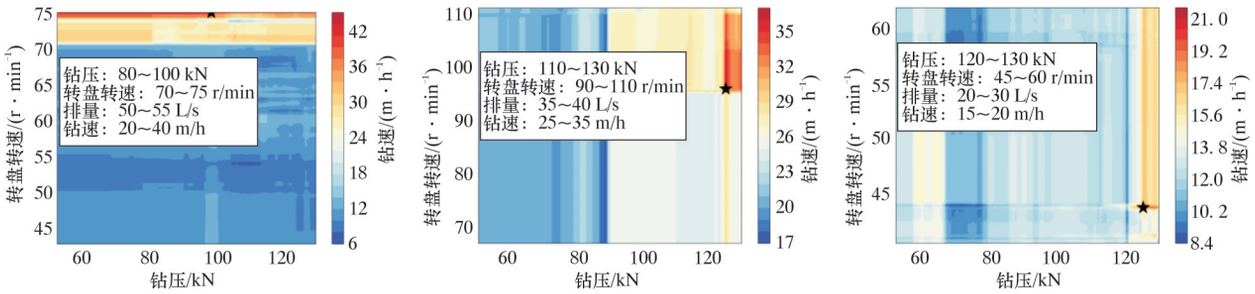


图 8　优选钻头与历史钻头的效率对比

Fig. 8　Efficiency comparison between optimal and historical bits



a. KS1652DFGRT钻头(井段2 370～3 550 m)　b. KSD1652AGR钻头(井段3 550～4 750 m)　c. KSD1652FRTY钻头(井段4 750～5 300 m)

图 9　所选钻头型号的钻井参数区间智能优选结果

Fig. 9　Ranges of drilling parameters for selected bit models

的历史数据进行清洗、异常值剔除和归一化处理，提取了工程参数、地层属性、钻头关键特征及其性能指标18种特征参数，充分反映了钻井工程的多维因素，为后续模型的构建打下了坚实的数据基础。

（2）基于随机森林模型构建了钻头机械钻速和趟钻进尺的预测模型，通过网格搜索方法对决策树数量、最大深度、节点分裂最小样本数和叶节点最小样本数等超参数进行调优，实现了对钻井性能的精准预测。结果表明，模型在训练集和测试集上的R^2分别达到了0.9及0.8以上，平均绝对百分比误差均小于20%，验证了模型的鲁棒性和泛化能力。

（3）模型的特征重要性分析表明，井深、岩性、地层密度及抗压强度等地层属性对机械钻速和进尺具有显著影响；同时，钻头自身的刀翼数量、主切削齿倾角与齿高等关键参数也对钻头性能发挥至关重要的作用。这与物理机理和工程实践相符，进一步说明所采用的机器学习方法在挖掘数据内在规律方面的有效性。

（4）利用历史数据和现场邻井数据插值获取待钻井地层属性，通过对每米地层的钻头特征组合进行预测与综合效率评估，实现了根据地层变化自动选取最优钻头组合，并通过匹配历史工程案例确定钻头型号。同时，在针对具体钻头型号的基础上，通过网格搜索进一步对钻压、转速和排量等参数进行调优，实现了钻井参数的智能优化。结果显示，在同一井段内，经过参数优选后的钻头可将趟钻次数由原来的5次减少到3次，机械钻速由0~10 m/h提升至10~20 m/h，整体钻井效率明显提高。

总体来说，研究初步验证了基于机器学习和网格搜索方法在钻头性能预测及参数优化中的可行性，为油田钻井作业的智能化提供了有力的数据支持和理论依据。未来可通过进一步拓宽数据来源、优化模型算法和构建动态实时系统，有望实现更高效、更精准的钻井作业优化，为降低钻井成本、提高资源开发效益提供重要支撑。

参　考　文　献

[1] 李根生，宋先知，祝兆鹏，等. 智能钻完井技术研究进展与前景展望 [J]. 石油钻探技术，2023，51（4）：35-47.
Li Gensheng，Song Xianzhi，Zhu Zhaopeng，et al. Research progress and the prospect of intelligent drilling and completion technologies [J]. Petroleum Drilling Techniques，2023，51（4）：35-47.

[2] 毕开原. 我国页岩气钻完井关键技术现状及发展趋势 [J]. 石油机械，2024，52（11）：12-20，28.
Bi Kaiyuan. Current status and trend of key technologies for shale gas well drilling and completion in China [J]. China Petroleum Machinery，2024，52（11）：12-20，28.

[3] Al-Dujaili A N，Asad M S，Saeed N，et al. Optimizing polycrystalline diamond compact bit selection and drilling parameters for deviated wells in the Majnoon Field，Iraq [J]. Scientific Reports，2025，15（1）：3178.

[4] 段鸿杰，马承杰，董琰，等. 胜利油田数字化转型实践与成效 [J]. 石油科技论坛，2023，42（3）：48-55，64.
Duan Hongjie，Ma Chengjie，Dong Yan，et al. Practice and achievements from digital transformation in shengli oilfield [J]. Petroleum Science and Technology Forum，2023，42（3）：48-55，64.

[5] 李金蔓，周守为，孙金声，等. 数字技术赋能海上油田开发：渤海智能油田建设探索 [J]. 石油钻采工艺，2022，44（3）：376-382.
Li Jinman，Zhou Shouwei，Sun Jinsheng，et al. Digital technology energizes offshore oilfield development：an attempt to build the Bohai smart oilfield [J]. Oil Drilling & Production Technology，2022，44（3）：376-382.

[6] 潘起峰，高德利，孙书贞，等. PDC钻头选型新方法[J]. 石油学报，2005，26（3）：123-126.
Pan Qifeng，Gao Deli，Sun Shuzhen，et al. A new method for PDC bit selection[J]. Acta Petrolei Sinica，2005，26（3）：123-126.

[7] 赵军，蔡亚西，林元华. 声波测井资料在岩石可钻性及钻头选型中的应用[J]. 测井技术，2001，25（4）：305-307.
Zhao Jun，Cai Yaxi，Lin Yuanhua. Application of sonic logs to rock drillability and bit selection[J]. Well Logging Technology，2001，25（4）：305-307.

[8] 苏强，何世明，胡锡辉，等. 川西双鱼石构造难钻地层岩石可钻性及钻头选型研究与应用[J]. 钻采工艺，2019，42（2）：124-127.
Su Qiang，He Shiming，Hu Xihui，et al. Research and application on rock drillability and bit selection of difficult drilling formations in Shuangyushi structure of western Sichuan basin[J]. Drilling & Production Technology，2019，42（2）：124-127.

[9] 张武昌，李忠慧，寿翔，等. 玛湖凹陷砂砾岩地层抗钻特性预测及钻头优选[J]. 石油机械，2023，51（3）：9-15.
Zhang Wuchang，Li Zhonghui，Shou Xiang，et al. Prediction of anti-drilling properties and bit selection for glutenite formations in Mahu sag[J]. China Petroleum Machinery，2023，51（3）：9-15.

[10] 田云英，夏宏泉，张晶晶. 川西深井钻头选型的测井参数灰色关联研究[J]. 钻采工艺，2007，30（3）：30-32，48.
Tian Yunying，Xia Hongquan，Zhang Jingjing. Research on grey relation method of logging parameter about bit selection in deep wells of west Sichuan[J]. Drilling & Production Technology，2007，30（3）：30-32，48.

[11] 闫铁，许瑞，孙文峰，等. 地层抗钻能力相似性评价及钻头选型新方法[J]. 石油勘探与开发，2021，48（2）：386-393，420.
Yan Tie，Xu Rui，Sun Wenfeng，et al. Similarity evaluation of stratum anti-drilling ability and a new method of drill bit selection[J]. Petroleum Exploration and Development，2021，48（2）：386-393，420.

[12] 冯定. 神经网络在钻头选型中的应用研究[J]. 石油钻探技术，1998（1）：45-47，64.
Feng Ding. Application research of neural network in bit selection[J]. Petroleum Drilling Techniques，1998（1）：45-47，64.

[13] 张辉，王昊，姜敞，等. 基于岩石抗钻特性的BP神经网络钻头选型方法[J]. 钻采工艺，2019，42（4）：24-27.
Zhang Hui，Wang Hao，Jiang Chang，et al. Bit type selection by BP neural network method based on rock's anti-drilling property[J]. Drilling & Production Technology，2019，42（4）：24-27.

[14] 赵廷峰，周启成，赵春艳，等. 基于PCA-BP的钻头优选方法与应用[J]. 断块油气田，2016，23（2）：243-247.
Zhao Tingfeng，Zhou Qicheng，Zhao Chunyan，et al. Selection and application of bit type based on PCA-BP[J]. Fault-Block Oil and Gas Field，2016，23（2）：243-247.

[15] 邓嵘，丰波，敖建章，等. 牙轮钻头牙齿破岩效率的模糊综合评判方法[J]. 石油机械，2016，44（3）：6-11.
Deng Rong，Feng Bo，Ao Jianzhang，et al. Fuzzy comprehensive evaluation method of cone bit teeth rock-breaking efficiency[J]. China Petroleum Machinery，2016，44（3）：6-11.

[16] 邹德永，孟祥雨，袁军，等. 基于模式识别的钻头选型新方法[J]. 石油钻探技术，2016，44（2）：40-45.
Zou Deyong，Meng Xiangyu，Yuan Jun，et al. A new method for bit selection based on pattern recognition[J]. Petroleum Drilling Techniques，2016，44（2）：40-45.

[17] Tewari S，Dwivedi U D，Biswas S. A novel application of ensemble methods with data resampling techniques for drill bit selection in the oil and gas industry[J]. Energies，2021，14（2）：432.

[18] 樊永东，金衍，林伯韬，等. 地质-工程驱动的邻井辅助同井钻速预测与优化方法[J]. 石油钻探技术，2025，53（1）：31-40.
Fan Yongdong，Jin Yan，Lin Baitao，et al. Prediction and optimization of ROP assisted by adjacent well data based on geological and engineering driving[J]. Petroleum Drilling Techniques，2025，53（1）：31-40.

第一作者简介：叶山林，生于1998年，现为在读博士研究生，研究方向为人工智能技术的钻井提速方法。地址：（102249）北京市昌平区。email：779975965@qq.com。
通信作者：宋先知，教授。email：songxz@cup.edu.cn。

修改回稿日期：2026-03-25
（本文编辑　王刚庆）