

基于神经网络的液力马达提速效果预测研究

熊秀丽, 李 谦*, 刘君豪, 姜 杰

(成都理工大学环境与土木工程学院, 四川 成都 610059)

摘要: 钻井技术是深部资源勘探不可或缺的技术支撑, 对钻井效率的预测是提升钻井工艺技术的重要途径。针对南海某区块钻井提速的需求, 本文对现场采集的10口井数据进行了插值补全和标准化预处理。为消除数据间高相关性, 基于因子分析将原始数据的43种不同参数进行降维, 最终确定建模输入参数为相互无相关性的21种公共因子。以井号和深度为基准, 结合10折交叉验证的方案, 针对原始数据进行分层采样分组, 优选单隐藏层15个神经元结构, 分别建立了使用液力马达和不使用液力马达的神经网络模型, 对比真实钻速数据, 模型整体预测精度均超过96%。模型预测显示, 在目标区块内含硅质不高的井段内使用液力马达能够有效提高钻进效率。同时模型针对高硅质井段钻进效果进行了预测, 结果显示提速工具的使用将加剧钻具的磨损, 引起钻速的下降。研究结果表明, 基于神经网络建立的钻速预测模型能够有效消除不同钻井井眼之间的差异, 高效预测提速工具的使用效果, 提高钻进效率。

关键词: 钻速预测模型; 神经网络; 提速工具; 钻探数据处理

中图分类号: P634; TE242 **文献标识码:** A **文章编号:** 2096-9686(2025)05-0042-09

Research on evaluating of using hydraulic motor based on neural network

XIONG Xiuli, LI Qian*, LIU Junhao, JIANG Jie

(College of Environment and Civil Engineering, Chengdu University of Technology, Chengdu Sichuan 610059, China)

Abstract: Drilling technology is an indispensable technical support for deep resource exploration, and the prediction of drilling efficiency is an important way to improve drilling technology. In response to the requirements for drilling speed-up in a certain block in the South China Sea, this paper collected actual drilling data from 10 wells, and these data were first interpolated and normalized. In order to eliminate the high correlation among different parameters, the initial 43 parameters were reduced to 21 common factors based on factor analysis, where there was no correlation between the 21 factors. Based on well number and depth, combining with a 10-fold cross-validation scheme, stratified sampling and grouping were performed on the original data. Through an optimized structure with a single hidden layer and 15 neurons, two neural network models were established on the basis of whether a hydraulic motor was used, and they both achieved an accuracy of over 96%. The model prediction shows that the use of speed-up tools in the target block with low silica content can effectively improve the drilling efficiency. At the same time, the model also predicts that for the high silicon content section, the use of speed-up drilling tools will increase wear on the drilling tools and cause a decrease in drilling speed. The results of the study show that the drilling speed prediction model based on a neural network can effectively make up for the differences among wellbores. Through accurate drilling speed prediction, it is possible to efficiently evaluate the effect of using speed-up tools and improve drilling efficiency.

Key words: ROP prediction model; artificial neuron network; speed-up tools; drilling data processing

收稿日期: 2025-01-07; 修回日期: 2025-04-06 DOI: 10.12143/j.ztgc.2025.05.006

基金项目: 四川省自然科学基金项目青年基金“基于数字孪生的动态时变钻进工况自适应迁移模型研究”(编号: 2024NSFSC0817); 中海石油(中国)有限公司项目“南海西部油田上产2000万方钻完井关键技术研究”子课题“乐东10区超高温高压井综合提速技术研究”(编号: CNOOC-KJ135ZDXM38ZJ05ZJ)

第一作者: 熊秀丽, 女, 汉族, 2004年生, 硕士研究生, 研究方向为钻探数据处理与分析, 四川省成都市二仙桥东三路1号, 3444237972@qq.com。

通信作者: 李谦, 男, 汉族, 1987年生, 副教授, 硕士生导师, 地质工程专业, 博士, 从事智能钻探与地外钻探相关技术研究工作, 四川省成都市二仙桥东三路1号, liqian2014@cdut.edu.cn。

引用格式: 熊秀丽, 李谦, 刘君豪, 等. 基于神经网络的液力马达提速效果预测研究[J]. 钻探工程, 2025, 52(5): 42-50.

XIONG Xiuli, LI Qian, LIU Junhao, et al. Research on evaluating of using hydraulic motor based on neural network[J]. Drilling Engineering, 2025, 52(5): 42-50.

0 引言

钻井是深部资源勘探不可或缺的技术手段,随着勘探深度不断增加,对钻井技术发展的需求也不断提高,亟需科学可靠的钻井技术来突破我国深部资源勘探开发的瓶颈。面对未知的地层环境,想要提升钻进效率,实现对钻井作业的实时掌控和优化,需要基于现场采集的数据建立准确的评估分析模型。

当前深部勘探钻井的评估分析模型从原理上可分为机理驱动模型和数据驱动模型两大类。机理驱动模型侧重于通过建立机械比能模型对钻进效率进行评估。机械比能指单位时间内破碎单位体积岩石需要的机械能。因此,机械比能越低,微观上代表破碎同等体积岩石效率越高,宏观上则代表当前钻进使用的钻进参数、钻头结构与类型等与地层适应程度更高^[1-2]。常见的机械比能计算模型包括Teale模型、Pessier模型、樊洪海模型、Dupriest模型和Cherif模型。相对而言,Teale模型最为基础简洁,计算参数少,但若无法获得实时钻头扭矩,则无法进行量化分析^[3];Pessier模型和樊洪海模型对其进行了优化,基于地面参数实现了钻头扭矩的实时评估,进而提高了机械比能量化计算精度,但上述两个模型中引入了偏经验性的扭矩回归系数与滑动摩擦系数,因而存在较大误差^[4-5];Dupriest模型和Cherif模型将机械效率引入Teale模型中,通过计算钻柱摩阻,区分了钻头高峰与低效工作区间,因而更贴近钻头实际工作情况,提高了计算精度^[6-7]。

数据驱动型模型可分为传统的统计型模型与机器学习型模型,但现场统计回归模型使用数据有限(通常 ≤ 10 种),且难以体现不同参数间跨区域后的高维非线性耦合关系,近年多被机器学习模型所取代。如刘胜娃等^[8]对比了机器学习与传统统计回归的钻进预测精度,基于6个区块的测试结果,表明以BP神经网络和支持向量机为代表的机器学习模型精度超过85%,而传统统计回归模型精度为67%~75%。在此基础上,研究人员使用不同的机器学习模型开展了多项预测工作,如Elkhatatny^[9]基于定向井数据分别建立了基于自适应模糊推理系统(ANFIS)、函数神经网络(FN)、随机森林(RF)和支持向量机(SVM)的机器学习模型,测试结果证明机器学习模型最高可达96%的泛化精度,远超过同类型物理模型;朱玥等^[10]使用神经网络(ANN)、RF

和XGBoost建立了钻速优化系统,基于三区域六井段测试,其均方误差最小仅为0.014;Encinas等^[11]基于时序预测的LSTM网络混合多层感知机MLP,对实际钻速预测精度误差 ≤ 6 m/h,并依据该模型对井下数据进行了修正;甘超等^[12]基于数据优选技术,将实时采集数据与模型仓库中数据相互匹配,以智能模型预训练技术实现了地质钻探的钻速动态预测,相较于同类算法误差减少13.4%;张琦等^[13]针对大洋钻探提出了以粒子群算法(PSO)结合极限学习机(ELM)的在线钻速区间预测方案,相较于常规极限学习机算法其精度提高了21%;胥知画等^[14]将粒子群算法引入智能钻速模型的参数筛选流程,证明参数筛选优化后的钻速预测模型最高可实现42.9%的精度提升。

对比当前常见的钻速预测分析模型,机理驱动型模型通过构建物理力学方程研究钻进过程,但为了获得明确的解析解,必须简化真实的复杂边界条件,降低了分析精度。同时,由于模型中使用的参数主要依赖室内试验分析法,受当前技术条件限制,难以在地表还原真实的井下环境,导致试验结果存在一定误差。随着智能化产业的发展,数据驱动型机器学习模型逐渐展现出巨大应用潜力。近年来,多项研究证明在钻井现场数据实时增加的条件下,机器学习模型的预测精度远超过机理分析和统计回归模型,正逐渐成为钻井过程定义分析研究中的主流方案。故本文针对南海某区块现场实际采集的10口钻井数据,使用神经网络搭建了钻速预测模型,并基于该模型对该区块的提速工具使用效果进行了定量评价。

1 数据采集与处理

1.1 数据采集与插值补全

本文所用数据源于南海某区块10口井实钻数据,数据包含5大类44种不同参数(见表1),样本集共21917条数据^[15]。初始采集的数据存在明显的密度差异,如钻压、扭矩、转速等施工工艺参数的数据密度为1条/m,而孔隙压力等地质数据密度为1条/40 m。不同的数据密度,会为后期建模带来巨大的误差,因此完成采集后的首要任务是通过插值补全数据,统一数据密度。对于频繁波动且无规律的钻探数据,为避免常规数值填充带来的误差^[16],本分析优选回归填充中的拉格朗日法(式1)作为数

据插值补全的核心算法^[17]。

$$y(x) = \sum_{k=1}^n y_k \left(\prod_{\substack{j=1 \\ j \neq k}}^n \frac{x - x_j}{x_k - x_j} \right) \quad (1)$$

式中: $y(x)$ ——指定坐标 x 的插值结果; y_k, x_k ——待插值数列第 k 个 y, x 值; x_j ——待插值数列第 j 个 x 值; n ——插值数据数量。

表1 收集参数列表^[15]

Table 1 Data variables and abbreviations

参数类型	参数名称/缩写
井眼位置	井号/No.(指代井眼位置坐标);深度/D
施工工艺	井径/d;钻速/ROP;钻压/WOB;大钩载荷/WH;转速/RPM;扭矩/T;泵压/SPP;泵量/Q;钻时/BT;泵时/PT;钻井液入口密度/MI;钻井液出口密度/MO;钻井液入口温度/ТИ;钻井液出口温度/TO
钻井液性	屈服值/YP;密度/MW;漏斗黏度/MV;塑性黏度/PV;3转读数/D3;6转读数/D6;10 s静切力/SS;10 min静切力/SM;滤矢量/FL;泥饼厚度/MT;pH/PH;流型指数/N;稠度系数/K;氯离子含量/CLC;钙离子含量/CAC;膨润土含量/SOC;固相含量/SO;含沙量/SA
地质情况	地震速度/EV;孔隙压力/PP;破裂压力/FP;上覆压力/OP;岩性/TYP
钻头参数	喷嘴数量/NN;喷嘴等效直径/NS;钻头内排磨损分级/WI;钻头外排磨损分级/WO;提速工具使用/ST

1.2 数据标准化预处理

完成插值整合的数据数量级差异明显,如图1所示,本分析中各参数之间横跨4个数量级($10^{-1} \sim 10^3$),直接建模将为预测模型带来较大误差隐患^[18-19]。本分析使用如式(2)所示 Min-Max 数据标准化算法,在消除参数单位的同时压缩其数据区间至 $[0, 1]$ 范围内。处理前后数据对比如图2所示,可见 Min-Max 算法可以较好地将所有不同数量级的数据映射在 $[0, 1]$ 范围内,同时真实地保留了原始数据的波动。

$$x_n = (x_i - X_{\min}) / (X_{\max} - X_{\min}) \quad (2)$$

式中: x_n ——归一化后标准数据; x_i ——原始数据; $X_{\min}, X_{\max}$ ——原始数据集的最小值、最大值。

1.3 采集数据相关性分析

原始建模参数间的高相关性将为后期模型带来明显误差^[20-21],因为算法在建模过程中无法处理




图1 原始数据数量级分布统计

Fig.1 Statistics of the magnitude distribution of raw data




图2 使用 Min-Max 算法进行标准化前后数据趋势对比

Fig.2 Comparison of data trends before and after normalization using the Min-Max algorithm

各参数间的相互协调变化情况。本分析选用 Person 相关系数法进行分析,如式(3)所示,令 ρ_{ab} 为变量 a, b 的相关系数,计算结果的正负代表正负相关性,

当其绝对值 >0.6 时可判定为高相关,绝对值位于 $[0.3, 0.6]$ 区间时为中相关, <0.3 则可判定为低相关或不相关^[22]。

$$\rho_{ab} = \text{cov}(a, b) / \sigma_a \sigma_b = \frac{\sum_{i=1}^n (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_{i=1}^n (a_i - \bar{a})^2} \sqrt{\sum_{i=1}^n (b_i - \bar{b})^2}} \quad (3)$$

式中: $\text{cov}(a, b)$ ——变量 a, b 的协方差; σ_a, σ_b ——变量 a, b 的标准差; a_i, b_i ——变量 a, b 的第 i 个参数值; $\bar{a}, \bar{b}$ ——变量 a, b 的平均值。

对初始数据集中所有变量进行两两相关性计算,除钻速(目标参数)以外43种参数的两两相关性组合共 $43 \times 42/2 = 903$ 种,输入变量间的相关性如图3所示,48%的输入参数组合存在相关性(相关性系数 >0.1 的输入变量组合达到429种),其中,中、高相关的输入参数组合(相关性系数 ≥ 0.3)达到253种,占比达28%。据此,在所有输入变量间广泛存在着大小不一的相关性,因此对输入变量进行降维、降相关性不可或缺。




图3 输入参数间相关性统计结果

Fig.3 Correlation statistics between input parameters


1.4 输入参数因子分析降维

过多变量可通过因子分析算法进行分组和降维,从中寻找内部相关性较高的变量组合。如式(4)所示,假设原始数据集有 n 个原始特征($X_1, X_2, \dots, X_n$),本分析采用的因子分析算法从原始特征的相关矩阵出发,通过计算分析原始特征之间的内部依赖关系,将原始特征转化为 m 个($m < n$)公共因子($f_1, f_2, \dots, f_m$)的线性组合,提取出不同原始特征之间的公共因子,通过公共因子描述原始变量之间的相互关系。


$$\begin{cases} f_1 = a_{11}X_1 + a_{12}X_2 + \dots + a_{1n}X_n \\ f_2 = a_{21}X_1 + a_{22}X_2 + \dots + a_{2n}X_n \\ \vdots \\ f_m = a_{m1}X_1 + a_{m2}X_2 + \dots + a_{mn}X_n \end{cases} \quad (4)$$

式中: $f_1, f_2, \dots, f_m$ ——转换后的公共因子; $(a_{ij})_{m \times n}$ ——因子得分矩阵,表示第 i 个变量在第 j 个指标中所占比例。

依次计算从原始43种参数中提取不同公共因子数量后的贡献率见图4。理论上,公共因子是原始数据通过线性组合后提取出的参数组合,故公共因子数量不可能超过原始数据,即公共因子最大数量为43个。将各因子包含的原始数据信息浓度进行排序,如图4(a)所示,1号因子包含了34.7%的原始信息。随着因子序号增加,其包含信息浓度锐减,21号以后公共因子包含的原始数据信息均不足1.5%。如图4(b)所示,累积叠加前21个公共因子的原始信息浓度已超过90%,故后续建模分析中可仅使用前21个公共因子。如此实现了将原始43个参数数量降至21个公共因子,同时也消除了各参数间的相关性(21个公共因子间相关性全部归零)。



(a)单因子贡献率



(b)累积贡献率

图4 因子分析计算结果

Fig.4 Factor analysis results

2 神经网络建模流程

2.1 数据分组

考虑建模分析数据集 21917 条数据总量,降维后 21 个建模参数,在数据条目总量超过 10 倍于变量的条件下,采用了以井号和地层深度两个参数为基准的分层采样结合 10 折交叉验证的方式进行数据分组,如图 5 所示。




图 5 基于 10 折交叉验证的测试集选择

Fig.5 Test set selection based on 10-fold cross validation

分组流程设计如下:

(1) 将 10 口井眼数据按深度进行排列,可知本分析中 10 口井眼数据大部分集中于 2000~4000 m 之间。

(2) 参考交叉验证基本理论,将每口井的数据按各自深度区间均匀划分为 10 段,每次分析依次取出 10 口井中的一个井段,将取出的 10 个井段联合作为测试集,其余井段联合作为训练集。

(3) 参考数据分层采样理论,每次建模过程中每口井的测试集选择按顺序下移,如 1 号井选择 1 号井段为测试集,则同次建模中 2 号井则选择 2 号井段,3 号井则选择 3 号井段。具体选择如图 5 所示,以不同颜色区分每口井每次测试集的选择。

(4) 最终 10 次测试建模测试集的选择结果为每个井段测试集的合集,每次建模的训练集为排除测试集后的其余数据。

2.2 神经网络结构设计与评价

本分析建模属于典型的多输入单输出的非线性拟合,因此选用在该方面拟合精度非常高的 BP 神经网络进行模拟,建立网络结构如图 6 所示,整体结构划分为输入层、隐藏层和输出层,各层均包含若干个独立的神经元模型。其中输入层包含 21 个神经元,分别对应 21 个公共因子;输出层包含 1 个神经元,对应 1 个输出参数钻速。隐藏层的层数和神经元数量是控制建模分析精度的关键。较少的层数与数量会显著降低建模精度,而过多则会带来明显增大的计算资源消耗。




图 6 本分析所建神经网络结构示意图

Fig.6 Schematic diagram of the neural network structure built for this analysis

本次建模隐藏层神经元数量计算如式(5)所示。结合本次训练的相关数据: $N_i = 21$, $N_o = 1$, 可计算得到图6所示隐藏层神经元数量 $m = N_h = 15$ 。

$$N_h = 2(N_i + N_o)/3 \quad (5)$$

式中: N_h ——隐藏层神经元数量; N_i ——输入层神经元数量; N_o ——输出层神经元数量。

相较于其他机器学习算法,神经网络模型在可解释性方向具有较大优势,这也是本研究选用神经网络建模的原因之一。结合基本神经元的结构,可将神经网络输入层-隐藏层-输出层之间的连接与权重取出进行展开,进而获得各参数对最终输出模型的影响趋势。参考图6,21个输入参数,15个隐藏层神经元条件下,以默认的Sigmoid函数为激活函数 $f(x)$,训练拟合完成后的神经网络模型可展开如式(6)所示。

$$\begin{cases} ROP = \left[\sum_{i=1}^{15} w_{2i} \left(f \left(\sum_{j=1}^{21} w_{1j} x_j + b_j \right) \right) \right] + b_2 \\ f(x) = 1/(1 + e^{-x}) \end{cases} \quad (6)$$

式中: w_1, w_2 ——输入层-隐藏层、隐藏层-输出层传递的权重系数; b_j, b_2 ——隐藏层、输出层相关的偏差阈值; $f(x)$ ——激活函数。

对本分析神经网络建模效果以常规指标 R^2 进行评估,其计算方法如式(7)所示,评价预测结果与真实数据集的吻合程度,通常评价结果位于 $[0, 1]$ 之间,越接近1代表预测结果越接近真实结果。

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - Y_p)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (7)$$


式中: Y_i ——神经网络预测结果序列中第*i*个结果; Y_p ——第*i*个结果对应真实值; $\bar{Y}$ ——结果序列真实值的平均值。

3 基于神经网络的液力马达提速效果预测


3.1 分析目的与方法

实际应用过程中,为判定该区域内主要钻井提速工具液力马达的使用是否达到了提高钻速的效果,分别对1、2、3、10号4口井中2700~3900 m井段中使用液力马达的井段与同区域其他未使用的井眼进行了对比分析。将目标区块所有相同深度井段数据提出,分离使用和未使用液力马达的井段,各井段钻速对比见图7。对比发现未使用提速工具的井眼在3400 m左右出现明显的钻速下降(图7a),使用提速工具的井眼则不会。但从整体钻速分布

看,未发现提速工具的使用能有效提升钻速,甚至在深度<3400 m的井段中出现使用液力马达后钻速明显低于未使用的情况。



(a)未使用液力提速马达



(b)使用液力提速马达

图7 目标区块提速工具直接对比

Fig.7 Direct comparison of speed-up drilling tools in target areas

考虑到目标区块10口井具体的地层分布并不均匀,如图7所示的对比结果并不能直接得到在目标区块使用提速工具不能提高钻速的结论,故在本分析中,使用图8所示的分析方法:(1)首先将初始数据集中未使用提速工具的井段与已使用提速工具的井段分别提出,而后分别在两组井段中将完成基本处理与降维分组的输入数据与输出数据(钻速)区分开;(2)分别基于未使用与使用提速工具的井段各自建立钻速预测模型;(3)模型建立完成后交换预测,在使用提速工具的井段预测未使用提速工具的效果,同理,在未使用提速工具的井段预测使用了提速工具的效果;(4)最后将同井段的预测钻速与实际钻速进行对比,就可得到相同地质、施工、钻井液条件下使用提速工具的对比效果。

3.2 模型建立

结合图8所示流程,将目标区块使用提速工具的井段数据(3432条)与未使用的井段数据(18482




图8 提速工具使用效果分析流程

Fig.8 Analysis process of the effect of using speed-up drilling tools

条)分开,分别对应训练神经网络,训练精度如图9所示。对所建立的两个模型,预测值 ROP_{pre} 与真实值 ROP_{real} 的拟合效果见图9(a)、(c),拟合预测值的回归线与理论直线较为吻合,可推演得到模型预测值与真实值之间的拟合关系,见式(8)。同时,模型

整体预测误差分布见图9(b)、(d),两个模型预测误差分布最多的区间为 $0 \sim 1.11$ m/h和 $-0.06 \sim 0$ m/h之间。汇总所有建模预测数据,对比真实钻速数据,两个模型整体预测精度均超过96%,能够较为精准地获得预测效果。




图9 神经网络预测模型建模精度效果

Fig.9 Effect of modeling accuracy of neural network prediction model

$$\begin{cases} ROP_{pre} = 0.92ROP_{real} + 1.6, \text{不提速预测模型} \\ ROP_{pre} = 0.93ROP_{real} + 0.28, \text{提速预测模型} \end{cases} \quad (8)$$

3.3 实际应用效果

基于上述准确预测模型,首先判定提速工具的

提速效果,预测实际使用提速工具井段在未使用提速工具条件下的钻速,后与真实使用提速工具的钻速相比较,如图10所示,证明在使用了提速工具的1、2、3号井眼中,液力马达均能明显提高钻速,模型

预测这些井眼若不使用提速工具的钻速明显偏低。值得注意的是,预测结果显示在10号井眼中提速工具的使用反而降低了钻速。结合现场录井数据,10号井眼提速效果不佳的主要原因在于该井段地层硅质含量明显高于其他井段,过高的硅质含量导致地层研磨性强,液力马达的使用无疑会加剧钻头的磨损,进而导致钻速下降。结合现场对钻头磨损的评价也可验证该观点,该井段钻头磨损达到3~4级,明显高于其他井段的1~2级。对比未使用提速工具的井段,如图11所示,在目标区块相同深度条件下,使用提速工具后钻速显著提高。




图10 使用提速工具的井段提速效果分析

Fig.10 Effect of increasing the speed of drilling in the well section using the speed-increasing drilling tool




图11 未使用提速工具的井段提速效果预测

Fig.11 Prediction of speed-up effect in well sections without speed-up drilling tools

4 结论

本文基于南海某区块10口井的实钻数据分析,对应建立了神经网络预测算法模型,对该区块内提

速工具的使用进行了优化设计与选用,得到如下结论:

(1)实时采集的现场数据需进行插值补全、标准化处理后获得数据矩阵,基于对数据矩阵的相关性分析,各数据间存在明显的相关性,采用因子分析可在降低建模数据维度的同时有效降低数据间的相关性。结合数据样本数与输入参数数量,采用10折交叉的方式进行数据分组,构建了BP神经网络预测模型。

(2)将实际数据中使用提速工具与未使用提速工具的井段分离,分别建立了预测精度超过96%的神经网络模型。将该模型分别应用于该区块两种井段中,预测结果显示使用提速工具能够有效提高当前区域钻速。同时,针对当前区块部分含硅质较高的井段,所建模型也准确预测了使用提速工具后钻头易磨损导致钻速反而下降的现象。

参考文献 (References):

- [1] 李昌盛. 基于机械比能的钻井性能评价技术分析及应用研究 [C]//中国石化第四届五四青年学术报告会暨第九届石油工程新技术青年论坛论文集. 北京, 2018:149-160.
LI Changsheng. Technical analysis and applied research for assessing drilling efficiency based on mechanical specific energy [C]//Proceedings of the 4th May Fourth Youth Academic Report Conference of Sinopec and the 9th Youth Forum on New Technologies in Petroleum Engineering. Beijing, 2018:149-160.
- [2] 陈绪跃, 樊洪海, 高德利, 等. 机械比能理论及其在钻井工程中的应用 [J]. 钻采工艺, 2015, 38(1):6-10.
CHEN Xuyue, FAN Honghai, GAO Deli, et al. Research on mechanical specific energy theory used in drilling engineering and its development trend [J]. Drilling & Production Technology, 2015, 38(1):6-10.
- [3] Teale R. The concept of specific energy in rock drilling [J]. International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts, 1965, 2(1):57-73.
- [4] 樊洪海, 冯广庆, 肖伟, 等. 基于机械比能理论的钻头磨损监测新方法 [J]. 石油钻探技术, 2012, 40(3):116-120.
FAN Honghai, FENG Guangqing, XIAO Wei, et al. New approach for real-time bit wear monitoring based on the theory of MSE [J]. Petroleum Drilling Techniques, 2012, 40(3):116-120.
- [5] Pessier R C, Fear M J. Quantifying common drilling problems with mechanical specific energy and a bit-specific coefficient of sliding friction [C]//SPE Annual Technical Conference and Exhibition. Washington, 1992:SPE-24584-MS.
- [6] Hammoutene C, Bits S. FEA modelled MSE/UCS values optimise PDC design for entire hole section [C]//North Africa Technical Conference and Exhibition. Cairo, Egypt, 2012: SPE-149372-MS.

- [7] Dupriest F E, Koederitz W L. Maximizing drill rates with real-time surveillance of mechanical specific energy [C]//SPE/IADC Drilling Conference. Amsterdam, Netherlands, 2005: SPE-92194-MS.
- [8] 刘胜娃,孙俊明,高翔,等.基于人工神经网络的钻井机械钻速预测模型的分析与建立[J]. 计算机科学, 2019, 46(S1): 605-608.
- LIU Shengwa, SUN Junming, GAO Xiang, et al. Analysis and establishment of drilling speed prediction model for drilling machinery based on artificial neural networks [J]. Computer Science, 2019, 46(S1): 605-608.
- [9] Elkhatatny S. Real-time prediction of rate of penetration in S-shape well profile using artificial intelligence models [J]. Sensors, 2020, 20(12): 3506.
- [10] 朱玥,殷志明,张永忠,等.基于人工智能的钻速系统优化研究 [C]//第32届全国天然气学术年会(2020)论文集. 重庆, 2020: 2314-2319.
- ZHU Yue, YIN Zhiming, ZHANG Yongzhong, et al. Research on drilling speed system optimization based on artificial intelligence [C]//Proceedings of the 32nd National Natural Gas Academic Annual Conference (2020). Chongqing, 2020: 2314-2319.
- [11] Encinas M A, Tunkiel A T, Sui D. Downhole data correction for data-driven rate of penetration prediction modeling [J]. Journal of Petroleum Science and Engineering, 2022, 210: 109904.
- [12] 甘超,汪祥,王鲁朝,等.基于区域多井数据优选与模型预训练的深部地质钻探过程钻速动态预测方法[J]. 钻探工程, 2023, 50(4): 1-8.
- GAN Chao, WANG Xiang, WANG Luzhao, et al. Dynamic prediction method of rate of penetration (ROP) in deep geological drilling process based on regional multi-well data optimization and model pre-training [J]. Drilling Engineering, 2023, 50(4): 1-8.
- [13] 张琦,甘超,曹卫华.大洋钻探过程钻速在线区间预测方法——以微型钻探船室内模拟实验为例[J]. 钻探工程, 2024, 51(5): 45-52.
- ZHANG Qi, GAN Chao, CAO Weihua. An online interval prediction method for rate of penetration (ROP) during the ocean drilling: a case study on the indoor simulation experiments by micro drilling ship [J]. Drilling Engineering, 2024, 51(5): 45-52.
- [14] 胥知画,姜杰,周长春,等.基于粒子群优化的融合特征选择钻速预测模型研究[J]. 钻探工程, 2025, 52(2): 134-143.
- XU Zhihua, JIANG Jie, ZHOU Changchun, et al. Research on a rate of penetration (ROP) prediction model based on feature selection integrated with particle swarm optimization (PSO) [J]. Drilling Engineering, 2025, 52(2): 134-143.
- [15] 李谦,周长春,朱海燕,等.生产数据的整合与初步分析在钻井中的应用实例[J]. 钻探工程, 2021, 48(S1): 85-95.
- LI Qian, ZHOU Changchun, ZHU Haiyan, et al. Application of integration and preliminary analysis of production data in drilling [J]. Drilling Engineering, 2021, 48(S1): 85-95.
- [16] Li Q, Li J P, Xie L L. A systematic review of machine learning modeling processes and applications in ROP prediction in the past decade [J]. Petroleum Science, 2024, 21(5): 3496-3516.
- [17] 朱玥.面向智能应用的深水钻井速率优化研究[D].北京:北京邮电大学, 2021.
- ZHU Yue. Research on deepwater drilling rate optimization for intelligent application [D]. Beijing: Beijing University of Post and Telecommunications, 2021.
- [18] 刘瑞霞.大数据环境下钻参优化研究[D].西安:西安石油大学, 2021.
- LIU Ruixia. Research on drilling parameters optimization under big data environment [D]. Xi'an: Xi'an Shiyou University, 2021.
- [19] 屈峰涛.基于大数据和智能算法的钻井参数优选模型与应用研究[D].西安:西安石油大学, 2021.
- QU Fengtao. Research on establishment and application of drilling parameter optimization model based on big data and intelligent algorithms [D]. Xi'an: Xi'an Shiyou University, 2021.
- [20] 蒲先渤,李泽群,尹飞,等.基于PCA-LM-BP神经网络的岩石可钻性预测研究[J]. 钻探工程, 2023, 50(6): 63-68.
- PU Xianbo, LI Zequn, YIN Fei, et al. Research on rock drillability prediction based on PCA-LM-BP neural network [J]. Drilling Engineering, 2023, 50(6): 63-68.
- [21] 周长春,姜杰,李谦,等.基于融合特征选择算法的钻速预测模型研究[J]. 钻探工程, 2022, 49(4): 31-40.
- ZHOU Changchun, JIANG Jie, LI Qian, et al. Research on drilling rate prediction model based on fusion feature selection algorithm [J]. Drilling Engineering, 2022, 49(4): 31-40.
- [22] 李谦,曹彦伟,朱海燕.基于人工智能的钻速预测模型数据有效性下限分析[J]. 钻探工程, 2021, 48(3): 21-30.
- LI Qian, CAO Yanwei, ZHU Haiyan. Discussion on the lower limit of data validity for ROP prediction based on artificial intelligence [J]. Drilling Engineering, 2021, 48(3): 21-30.

(编辑 王跃伟)