

创新点/亮点: 研发了基于变权重组合模型的抽油机井动液面预测方法, 解决了传统测试方法劳动强度大、测试频次低、测试成本高等问题, 在精度可接受的情况下, 较传统人工方法测试效率提升 15 万倍以上、劳动强度降低 90% 以上、测试频次高出 2000 多倍, 测试成本降低 96%。

引用格式: 艾信, 刘天宇, 张浩伟, 曹伟, 周娟, 辛宏. 变权重组合算法预测抽油机井动液面提高测试效益 [J]. 石油钻采工艺, 2024, 46(5): 586-599. // AI Xin, LIU Tianyu, ZHANG Haowei, CAO Wei, ZHOU Juan, XIN Hong. Variable weight combination prediction model improves the efficiency of dynamic liquid level testing in pumping unit wells [J]. Oil Drilling & Production Technology, 2024, 46(5): 586-599.

变权重组合算法预测抽油机井动液面提高测试效益

艾信^{1,2}, 刘天宇^{1,2}, 张浩伟^{1,2*}, 曹伟³, 周娟⁴, 辛宏^{1,2}

1. 中国石油天然气股份有限公司长庆油田分公司油气工艺研究院, 陕西西安
2. 低渗透油气田勘探开发国家工程实验室, 陕西西安
3. 中国石油天然气股份有限公司长庆油田分公司第七采油厂, 陕西西安
4. 中国石油天然气股份有限公司长庆油田分公司第五采油厂, 陕西西安

*通信作者: 张浩伟, 电子邮箱: zhanghaowei_cq@petrochina.com.cn

基金项目: 国家科技重大专项“鄂尔多斯盆地大型低渗透岩性地层油气藏开发示范工程”(编号: 2016ZX05050)。

摘要: (目的意义) 为解决抽油机井动液面传统人工测试方法劳动强度大、测试频次低、测试成本高等问题, (方法过程) 文章利用皮尔逊相关系数分析方法, 分析了 29 项抽油机井自动采集特征参量与实测动液面的相关性, 确定了 13 项主控特征参量; 应用 XGBoost、LightGBM 及 BP 神经网络等机器学习方法, 分别创建了抽油机井动液面预测模型, 通过对三种模型输入 13 项主控特征参量, 评价了三种模型的动液面预测结果, 发现单一预测模型无法适应全部抽油机井, 因此建立了基于上述三种预测模型的变权重组合模型。(结果现象) 长庆油田现场多轮次应用显示: 与传统人工测试方法对比, 平均相对误差在 5% 以内, 测试效率提升 15 万倍以上, 劳动强度降低 90% 以上, 测试频次高出 2000 多倍, 测试成本降低 96%。(结论建议) 变权重组合动液面预测模型切实解决了传统人工测试方法劳动强度大、测试频次低、测试成本高等问题, 为国内油田动液面测试提供了新思路。

关键词/主题词: 油井; 采油; 抽油机井; 动液面; 预测模型; 机器学习; 皮尔逊相关系数; 神经网络

中图分类号: TE355 文献标识码: A DOI: [10.13639/j.odpt.202412009](https://doi.org/10.13639/j.odpt.202412009)

收稿日期: 2024-06-03; 修回日期: 2024-07-03; 录用日期: 2024-08-17; 编辑: 杨春莉

Variable weight combination prediction model improves the efficiency of dynamic liquid level testing in pumping unit wells

AI Xin^{1,2}, LIU Tianyu^{1,2}, ZHANG Haowei^{1,2*}, CAO Wei³, ZHOU Juan⁴, XIN Hong^{1,2}

1. Oil & Gas Technology Research Institute of PetroChina Changqing Oilfield Branch, Xi'an, Shaanxi, 710018, China
2. National Engineering Laboratory for Exploration and Development of Low-Permeability Oil & Gas Fields, Xi'an, Shaanxi, 710018, China
3. No.7 Oil Production Plant of PetroChina Changqing Oilfield Branch, Xi'an, Shaanxi, 710200, China
4. No.5 Oil Production Plant of PetroChina Changqing Oilfield Branch, Xi'an, Shaanxi, 710021, China

*Corresponding author. ZHANG Haowei, E-mail addresses: zhanghaowei_cq@petrochina.com.cn

Abstract: To address the issues of high labor intensity, low testing frequency, and high testing costs associated with traditional manual testing methods for the dynamic liquid level in pumping unit wells, the article employs the Pearson correlation coefficient analysis method to investigate the correlation between 29 automatically collected characteristic parameters of pumping unit wells and the measured dynamic liquid level, ultimately identifying 13 key characteristic parameters. Utilizing machine learning techniques,

including XGBoost, LightGBM, and BP neural network, distinct dynamic liquid level prediction models for pumping unit wells were developed. Through the input of 13 key characteristic parameters into these models, an evaluation of their prediction outcomes was conducted. The evaluation revealed that a singular prediction model was inadequate for all pumping unit wells. Consequently, a variable weight combination model, founded on the three prediction models, was formulated. Numerous field applications in Changqing Oilfield have demonstrated that, in comparison to traditional manual testing methods, this approach achieves an average relative error within 5%, a testing efficiency increase of over 150,000 times, a reduction in labor intensity by over 90%, a testing frequency increase exceeding 2,000 times, and a significant 96% reduction in testing costs. In conclusion, the variable weight combination dynamic liquid level prediction model effectively addresses the challenges posed by high labor intensity, low testing frequency, and high testing costs inherent to traditional manual testing methods, thereby offering novel insights for dynamic liquid level testing in domestic oil fields.

Key words: Oil well; Oil recovery; Pumping unit well; Dynamic liquid level; Predictive model; Machine learning; Pearson correlation coefficient; Neural network

<https://doi.org/10.13639/j.odpt.202412009>

Received 3 June 2024; Revised in revised form 3 July 2024; Accepted 17 August 2024

0 引言

动液面是指抽油机在正常生产时, 油管 and 套管环形空间内形成的液面, 是反映地层供液能力的重要指标^[1]。动液面是评估油藏整体动态性能、优化开发策略的关键依据, 可用于油藏动态分析^[2]。动液面的变化与地层能量和地层供液能力的变化紧密相关, 这种关联性使得动液面成为连接地下油藏动态与地面生产表现的桥梁。在油藏区块的开发过程中, 地层能量的变化是一个复杂而关键的过程, 会受到多种因素的影响, 包括地质构造、流体性质、开采方式等。当地层能量下降时, 动液面会随之下降, 反之亦然。因此, 通过对同一油藏区块内全部抽油机井的动液面进行系统性测试, 可以获取到关于地层能量变化的全面信息。这些信息有助于了解油藏的地质特征, 如渗透率、孔隙度等关键参数, 进而评估油藏的储量和开采潜力。

动液面可用于油藏开发效果评价^[3]。在开发初期, 由于地层能量充足, 动液面较高, 油井产量较高。随着开采的进行, 地层能量逐渐消耗, 动液面逐渐下降, 油井产量也会相应下降。通过对动液面的持续监测和分析, 我们可以及时发现油藏开发过程中存在的问题, 如地层压力下降过快、含水率上升等, 从而及时调整开发策略, 确保油藏的稳定开发和高效动用。

动液面可用于井下工况诊断^[4]。当地层供液稳定时, 动液面会呈现小幅度平稳波动, 但出现卡泵、抽油杆断、油管漏失、游动阀失灵、固定阀失灵、双阀漏失等工况时, 动液面会呈现逐渐上涨趋势, 油井产量“落零”, 造成油井产量损失; 当地层供液波动变化时, 动液面也随之变化, 抽油泵充满度“时高时低”, 抽油机井呈现间歇出液状态。因此在实际生产中, 可通过监测动液面变化, 并结合示功图及其它相关辅助判断措施, 实现对抽油机井井下工况的精准可靠诊断。

动液面可用于抽油机井生产制度优化^[5]。通过对动液面、示功图、泵效、流压等生产资料进行分析, 可绘制不同油藏区块抽油机井宏观控制图, 宏观控制图将油藏区块内抽油机井划分为参数偏大区、参数合理区、参数偏小区、资料待落实区以及断脱漏失区等 5 个区域, 进而为油井生产制度的优化提供指导依据。当抽油机井处于参数偏小区时, 可通过加大冲次、调大冲程等举措使其落入参数合理区。当抽油机井处于参数偏大区时, 可优先通过减小冲次、调小冲程等举措使其落入参数合理区。

动液面可用于抽油机井智能间抽控制^[6]。抽油机井智能间抽控制依赖于对动液面数据的实时监测与分析, 通过研究动液面变化规律, 可得出抽油机井流入流出动态变化规律, 进而确定合理间抽制度。根据间抽制度, 系统能够自动调整抽油机的启停时间和工作参数, 实现间歇式工作。这种控制方式不仅能够有效降低抽油设备的损耗和电能消耗, 还能提高油井的生产效率和经济效益。

动液面的应用价值是多方面的。不仅能够帮助了解油藏的地质特征和开发效果, 还能为制定合理的开

发策略提供科学依据。因此,在油藏开发和生产过程中,必须充分重视动液面的监测和分析工作,确保油藏的稳定开发和高效利用。目前在实际生产中,动液面测试主要有五种方式:

一是人工动液面测试。人工利用氮气枪在抽油机井油套环空产生声波,利用声波反射原理计算油井动液面^[7]。该方法是目前主要的动液面测试方法,但由于抽油机井数量多、井口环境复杂,人工测试费时费力,且存在一定安全风险;

二是动液面连续监测装置测试。通过研制电控声波发射装置,按照一定的时间间隔自动向油套环空激发声波,利用声波反射原理,自动分析得出抽油机井动液面^[8]。但受油套环空复杂的测试环境影响,设备故障率较高,安装调试复杂,整体投入成本较大,不适宜规模推广;

三是光纤法动液面测试。通过利用多模光纤实时监测井下温度剖面,利用不同介质中的热导率不同的原理,温度剖面拐点位置即为抽油机井动液面位置^[9]。该方法测试精度较高,可以有效避免油套环形空间内泡沫段产生的虚假液面的影响,但光纤入井需井下作业配合,单井投入高,可应用于重点井监测,不利于规模推广应用;

四是井下压力无线传输测试。由于动液面恢复曲线与油层压力恢复曲线具有较高的相关性,因此可通过利用实测压力数据反推抽油机井动液面^[10]。但单井投入高,且受电池储能影响,每隔8h传输一次(可连续应用3年以上),采样频率低,无法及时反映动液面变化趋势;

五是基于功图法的机理模型测试。通过柱塞受力分析,以沉没压力为求解节点,利用井下泵功图推导出抽油机井游动阀与固定阀打开时的柱塞受力,进而实现动液面的求解^[11]。但受井筒多相管流、摩擦力等作用,泵功图求解存在误差,动液面计算也不够精准。上述方法均难以实现抽油机井动液面的低成本、高可靠性、精准性测试。

调研发现,智能传感器与物联网技术的迅猛发展及广泛应用,标志着工业生产已迈入大数据时代。这一转变不仅促进了工业大数据的蓬勃发展,还极大地推动了新一代机器学习技术在工业领域的深入应用,拓宽了利用机器学习技术解决问题的范畴与深度。特别是在油田领域,新一代机器学习技术的应用日益广泛。

刘新社等针对石灰岩储层致密、微断层及流体识别难度大、酸化效果不理想等问题,攻关形成了“导向滤波+人工智能+关键地震信息融合”相结合的微断层刻画技术、基于概率神经网络的含气饱和度地震定量预测技术^[12];杨勇在断层检测、层位提取、岩性识别、测井解释等多个应用场景应用人工智能及大数据技术,断层解释效率提升10倍以上,测井砂泥岩岩性识别准确率超过90%^[13];刘芑辰等针对示功图的图形特征,利用卷积神经网络机器学习技术实现了抽油机井15类工况在线诊断,准确率达到92%以上^[14];王娟等研究了基于长短期记忆神经网络模型的多参数时间序列预测方法及粒子群参数优化算法,构建了随时间动态更新的油藏产量预测模型,从而进一步提升油藏产量预测的准确率与实用性^[15];王相等基于“大数据+深度学习”的新一代人工智能技术,开展油井工况诊断技术升级应用,在现场完成500余万次工况诊断技术试验,准确率达90%^[16]。以上关于机器学习、人工智能在油田领域的成功案例,为抽油机井动液面预测提供了新的方向。

2023年,王通等基于改进生成对抗网络的动液面建模数据进行扩充,提升了动液面预测模型的建模质量,动液面预测精度得到了提升,均方根误差降低了5.99%。但该方法只是对用于训练动液面预测模型的数据样本进行扩充优化,动液面预测模型仍然采用传统单一机器学习方法,预测符合率仍有较大提升空间^[17]。同年,姜春雷等提出了一种基于卷积神经网络和迁移学习的多任务生产预测方法,应用到小样本特高含水油井生产预测,产液量和动液面的平均绝对误差分别降低31.26%和60.81%^[18]。但该方法适合于嵌入油井边缘计算设备,从而实现对抽油机系统的效率优化、油井边缘设备智能化,规模适应能力不强。

为此,通过利用机器学习预测方法,结合大体量的抽油机井实时生产数据,研究抽油机井生产数据变化规律与液面深度的定量关系,建立抽油机井动液面预测模型,实现对油井动液面的实时预测。

1 方法过程

新一代机器学习技术用于抽油机井动液面预测的技术思路: 收集抽油机井全部参量, 并进行数据预处理; 应用 Pearson 相关系数分析方法, 对全部数据参量进行分析, 得到与动液面相关性较高的主控特征参量; 采用 XGBoost、LightGBM、BP 神经网络等机器学习方法, 建立多种抽油机井动液面预测模型, 并利用大体量的现场生产数据进行模型训练及模型测评; 优选动液面预测精度高的模型投入现场生产应用, 以主控特征参量为预测模型的“驱动源”, 实时获得抽油机井动液面预测值。

1.1 方法过程

1.1.1 数据收集及预处理

(1)数据收集。抽油机井数据主要分为三大类, 包括油藏类数据、井筒类数据、采集类数据。油藏类数据包括油藏中深、地层压力、井底油温、气液比等; 井筒类数据包括抽油杆、抽油管、抽油泵、抽油机等设备类数据及井眼轨迹数据等; 采集类数据包括抽油机井示功图、功率图、三相电参、冲程、冲次、产液量、含水率、油压、套压和动液面等。以上数据均在各大油田区域数据湖, 通过开发对应的数据接口便可获得。

(2)数据预处理。主要包括三个环节, 一是异常数据剔除。对于采集错误的功图、功率图采用基于专家经验的校验方法予以剔除。二是采集数据升维。示功图、功率图、抽油机井产液量均包含抽油机井不同特征信息, 通过对这些特征信息发掘, 进而实现数据升维。示功图是抽油机井一个完整冲程运动下的抽油机悬点载荷与其位移关系曲线^[19]。包含抽油机井上冲程最大载荷、上冲程最小载荷、上冲程载荷差、上冲程均方根载荷、下冲程最大载荷、下冲程最小载荷、下冲程载荷差、下冲程均方根载荷、最大载荷、最小载荷、平均载荷、载荷差等 12 个特征参量; 功率图是抽油机井一个完整冲程运动下的抽油机悬点载荷与其位移关系曲线^[20]。包含抽油机井上冲程最大功率、上冲程最小功率、上冲程功率差、上冲程均方根功率、下冲程最大功率、下冲程最小功率、下冲程功率差、下冲程均方根功率、最大功率、最小功率、平均功率、功率差、耗电量等 13 个特征参量; 抽油机井产液量包含有效冲程、冲次、泵效、泵充满系数等 4 个特征参量。三是无因次化处理。为了进一步消除不同油藏区块、不同井型对预测精度的影响, 增强不同井之间特征参量的普适性, 消除数据之间的差异性, 对单井功图电参特征参量进行无因次处理。利用有效冲程除以额定冲程, 利用冲次除以额定冲次, 悬点载荷数据除以地层压力与泵深之积, 功率数据除以电机额定功率, 去除不同特征参量的单位信息, 得到抽油机井动液面预测的无因次特征参量。

1.1.2 主控特征参量优选

共计收集了长庆油田 5000 口抽油机井、50000 组生产数据, 每组数据包括人工测试动液面对应时刻的抽油机井油藏类数据、井筒类数据及采集类数据。其中, 用于动液面预测的 29 项特征参量均为抽油机井实时采集数据, 并均进行了无因次化处理。同时考虑到耗电量、动液面数值较大, 为了方便计算, 进行了取对数处理。

利用皮尔逊相关系数分析法, 将 29 项特征参量与实测动液面进行相关性分析, 从而确定其主控特征参量。皮尔逊相关系数也称为皮尔逊积矩相关系数。贾俊杰等认为, 皮尔逊相关系数也是一种线性相关系数^[21], 记为 r , 用来反映两个变量 X 和 Y 的线性相关程度, r 值介于 $-1 \sim 1$ 之间, 其绝对值越大表明相关性越强。 r 的计算, 见式(1)。

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (1)$$

r 还可以由样本点 (X_i, Y_i) 的标准分数均值估计得到与式(1)等价的表达式, 式(2)。

$$r = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{X_i - \bar{X}}{\sigma_X} \right) \left(\frac{Y_i - \bar{Y}}{\sigma_Y} \right) \quad (2)$$

式中: $\frac{X_i - \bar{X}}{\sigma_X}$ 和 $\frac{Y_i - \bar{Y}}{\sigma_Y}$ 分别为 X_i 和 Y_i 样本的标准分数; \bar{X} 和 \bar{Y} 分别为 X_i 和 Y_i 样本的平均值; σ_X 和 σ_Y 分别为 X_i 和 Y_i 样本的标准差; n 为样本数量; i 为样本点的序号。

根据皮尔逊相关系数的绝对值,可以判断变量之间的相关强度,相关系数的绝对值 0.8~1.0,表示极强相关;当相关系数的绝对值 0.6~0.8,表示强相关;当相关系数的绝对值 0.4~0.6,表示中等相关;当相关系数的绝对值 0.2~0.4,表示弱相关;当相关系数的绝对值 0.0~0.2,表示极弱相关或无相关。因此,皮尔逊相关系数大于 0.6 时,通常被认为是强相关 [22]。

将每口油井 29 项特征参量与实测动液面之间的皮尔逊相关系数进行平均,分析了抽油机井各项特征参量与动液面的相关性,发现上冲程最大载荷、下冲程最小载荷、最大载荷、最小载荷、载荷差、上冲程最大功率、下冲程最小功率、最大功率、最小功率、耗电量、有效冲程、泵充满系数、泵效等 13 项特征参量相关性系数的绝对值大于 0.6,与抽油机井动液面呈现强相关,可以作为动液面预测模型的输入主控特征参量。

1.1.3 抽油机井动液面预测模型建立

在相关性分析的基础上,结合专业知识和实践经验,总结提炼抽油机井动液面主控特征参量与动液面的变化规律,建立抽油机井动液面预测模型。

将选取的 5000 口抽油机井的对应的主控特征参量作为主控特征数据集,并将对应动液面测试数据作为目标数据集。为了保证数据集的随机性,将主控特征数据集、目标数据集分别以 9:1 的比例划分,分别作为模型训练集、效果测试集,共计得到模型训练集数据约 45000 组(90%)和效果测试集数据约 5000 组(10%)。

基于重新划分得到的模型训练集、效果测试集,分别采用 XGBoost、LightGBM、BP 神经网络等机器学习方法,建立抽油机井动液面预测模型。

(1)XGBoost 动液面预测模型训练及调优。XGBoost 是一种基于决策树的梯度提升框架,康晓非等认为其优势主要包括如下几点:一是在处理大规模数据集时表现出色,能够快速训练模型;二是在相同的数据集和参数设置下,精度较高,尤其在特征数较少或需要平滑决策树时表现更好;三是参数设置较灵活,可适用于各种场景 [23]。应用 XGBoost 机器学习方法时,丁昌伟等认为需要利用贝叶斯优化器对模型参数进行调优 [24]。优化后指定树的最大深度为 5,学习速率为 0.02,树的个数为 375。将模型训练集的 45000 组训练数据输入 XGBoost 动液面预测模型进行训练,最终得到模型判定系数为 0.9577,平均绝对误差为 0.02641。

(2)LightGBM 动液面预测模型训练及调优。LightGBM 同样是基于决策树的梯度提升框架,谢华祥等认为其优势主要包括以下几点:一是使用直方图算法和基于梯度单边采样算法,在大规模数据集上训练速度更快;二是使用高效算法和数据结构,内存消耗较小;三是参数相对较少,大多数情况下使用默认参数即可 [25]。应用 LightGBM 机器学习方法时,李海霞等认为需要利用贝叶斯优化器对模型参数进行调优 [26]。优化后树叶节点个数为 39,迭代次数为 588,学习速率为 0.19。将模型训练集的 45000 组训练数据输入 LightGBM 动液面预测模型进行训练,最终得到模型判定系数为 0.9597,平均绝对误差为 0.02632。

(3)BP 动液面预测模型训练及调优。BP 神经网络是一种强大的工具,由输入层、隐藏层和输出层组成。邹旺等认为其优势主要包括以下几点:一是,强大的自适应和自学习能力,能够处理复杂的输入-输出关系,适用于函数逼近、分类和回归任务;二是,非线性映射能力,能够解决数据少、信息贫、不确定性问题,不受非线性模型的限制;三是广泛的应用领域,可适用于金融预测、销售预测、图像识别、自然语言处理等领域 [27]。应用 BP 神经网络机器学习方法时,邹琼等认为需要利用智能麻雀搜索法对模型参数进行调优 [28]。优化后最佳迭代次数为 83,最佳隐含层神经元节点数为 50。将模型训练集的 45000 组训练数据输

入 BP 动液面预测模型进行训练, 最终得到模型判定系数为 0.7879, 平均绝对误差为 0.0725。

而后将效果测试集的 5000 组主控特征参量分别输入 XGBoost、LightGBM、BP 神经网络动液面预测模型, 分别得到 5000 个动液面预测值。发现 BP 神经网络动液面预测模型的预测精度相对较差, XGBoost、LightGBM 动液面预测模型的预测精度优于 BP 神经网络动液面预测模型, 且二者预测精度基本相当。整体来看基于单一模型很难实现对全部抽油机井动液面的精准预测。

(4)变权重组合预测模型建立。针对上述问题, 提出建立基于变权重组合方法的动液面预测模型。当对多个预测模型进行组合时, 预测模型数量并不是越多越好。因此, 建立了预测模型的评价指标体系, 通过数值计算确定评价指标的主观权重和客观权重, 将两者结合后对模型进行综合评价, 从而优选出参与组合的模型^[29]。最终优选了对 XGBoost、LightGBM 及 BP 三种动液面预测模型的结果进行变权重组合, 进一步提升动液面预测精度, 式(3)。

$$y = ax_1 + bx_2 + cx_3 + k \quad (3)$$

式中: y 是组合模型计算动液面值; a 、 b 和 c 分别为 XGBoost 预测模型权重、LightGBM 预测模型权重、BP 预测模型权重; x_1 、 x_2 和 x_3 分别为 XGBoost 模型预测模型结果、LightGBM 模型预测模型结果、BP 神经网络预测模型结果; k 为变权重组合模型截距。

利用灰色关联度对传统层次分析法权重计算进行改进, 实现各单一预测模型对应权重值的自适应计算^[30]。而后将三种单一预测模型的预测值进行加权求和, 便可得到变权重组合模型的最终预测值。

通过将效果测试集的 5000 组主控特征参量输入变权重组合动液面预测模型, 得到 5000 个动液面预测值。发现基于变权重组合模型的动液面预测结果误差相对较小, 优于 XGBoost、LightGBM、BP 神经网络动液面预测模型, 能够相对准确的预测动液面, 因此可作为优选方法应用于抽油机井动液面预测应用。

1.2 成果应用过程

1.2.1 试验井的选择

为了更加科学、客观的评价变权重组合动液面预测模型的预测精度, 选取长庆油田某作业区 165 口井开展试验, 试验井泵挂范围 800~2300 m, 产液量范围 0.5~15 m³/d, 且分属不同油藏区块, 包含有常开油井及间抽油井, 也包括直井、定向井及水平井。可以较好的评价动液面预测模型对不同油藏区块、不同井型、不同泵挂深度、不同产量的抽油机井的适应性以及对抽油机井生产制度的指导作用。

1.2.2 试验流程设计

(1)变权重组合动液面预测模型重复性误差及准确性误差评价试验

第 1 步, 安排测试人员分别对 165 口抽油机井开展动液面测试工作, 每口井连续测试 5 次, 共记录 825 条测试数据及对应测试时刻;

第 2 步, 再将对应测试时刻的 165 口抽油机井 13 项主控特征参量, 输入变权重组合动液面预测模型, 得到 825 条动液面预测结果;

第 3 步, 最后对人工测试的 825 条动液面数据与对应预测结果进行对比分析。

通过对上述测试数据分析, 一方面可以评价变权重组合模型动液面预测结果的重复性; 另一方面可以评价变权重组合模型动液面预测结果的整体符合率。

为了进一步评价变权重组合动液面预测模型准确性, 对 Y18-34、Y18-35 两口油井开展人工油套环空注水试验, 并进行人工动液面测试与预测结果对比分析。

第 1 步, 开始注水前, 记录人工测试动液面数据与对应时刻模型预测动液面数据;

第 2 步, 向油套环空先后注水 4 次, 记录每次注水后的人工测试动液面数据与模型预测动液面数据。

通过对上述测试数据进行分析, 可以进一步确定预测结果准确性及动液面变化趋势符合程度。

(2) 变权重组合动液面预测模型用于优化间抽油井生产制度试验

Y15-35 油井日产液量 $1.72 \text{ m}^3/\text{d}$, 泵挂 2300 m, 间抽制度为开 2 h 停 6 h。对 Y15-35 间抽油井进行实时预测, 科学优化间抽制度。

第 1 步, 对 Y15-35 井安装油井动液面连续测试仪器, 并设置好测试起始时刻(2023 年 11 月 21 日 0 时 0 分 0 秒)及测试间隔(8 h), 间隔 8 h 获得抽油机井动液面数据;

第 2 步, 应用变权重动液面预测模型, 在 Y15-35 油井开井时间段(00:00:00—02:00:00; 8:00:00—10:00:00; 16:00:00—18:00:00)实时进行动液面预测;

第 3 步, 根据测试结果, 对 Y15-35 进行间抽制度优化及效果跟踪。

通过对上述测试数据进行分析, 可以评价动液面预测结果对间抽油井生产制度优化的效果。

1.2.3 试验结果分析

(1) 预测模型的重复性误差分析。为了评价变权重组合动液面预测模型的重复性误差, 随机从 165 口油井中选取 3 口油井(Y15-31、Y15-32、Y15-33), 对连续测试的 15 组动液面数据进行分析, 如图 1 所示。

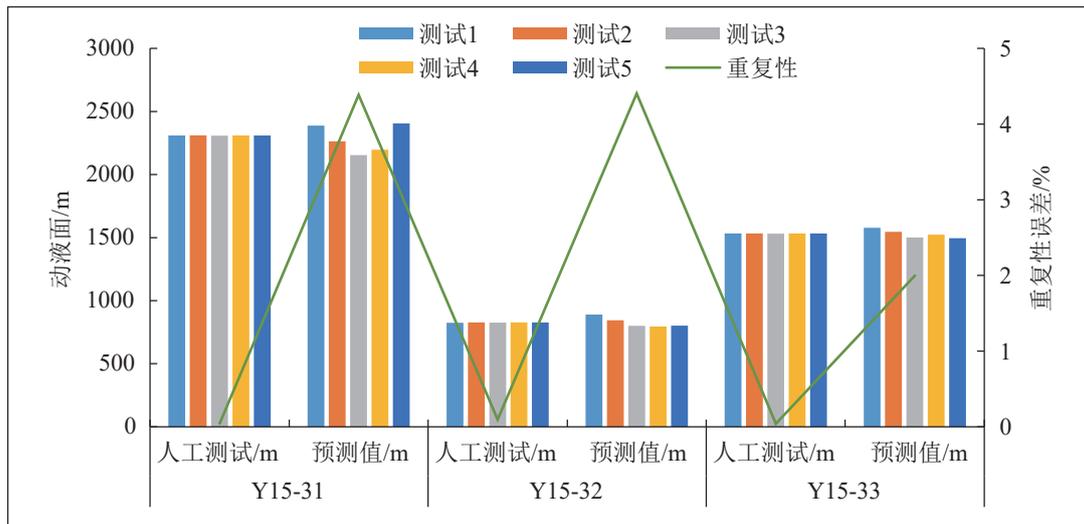


图 1 模型预测与人工测试动液面的重复性误差分析

Fig. 1 Analysis of Repeatability Error between Model Prediction and Manual Testing of Dynamic Liquid Level

从图 1 中可以看出, 人工测试动液面的平均重复性误差 0.06%, 模型预测动液面的重复性误差 3.60%。人工动液面测试的重复性误差远小于模型预测动液面的重复性误差。主要原因如下: 对于人工动液面测试, 依据回声波的信号分析数据获得动液面, 无其它干扰因素, 因此测试重复性较好。对于模型预测动液面, 受到井筒复杂的多相流态影响, 用于动液面预测的 13 项主控特征参量会呈现一定程度的波动, 因此测试重复性较差, 但也在可接受范围之内。

(2) 预测模型的准确性误差分析。为了评价动液面预测结果的整体符合率, 选取 165 口油井的人工测试结果与预测结果进行分析, 如图 2 所示。

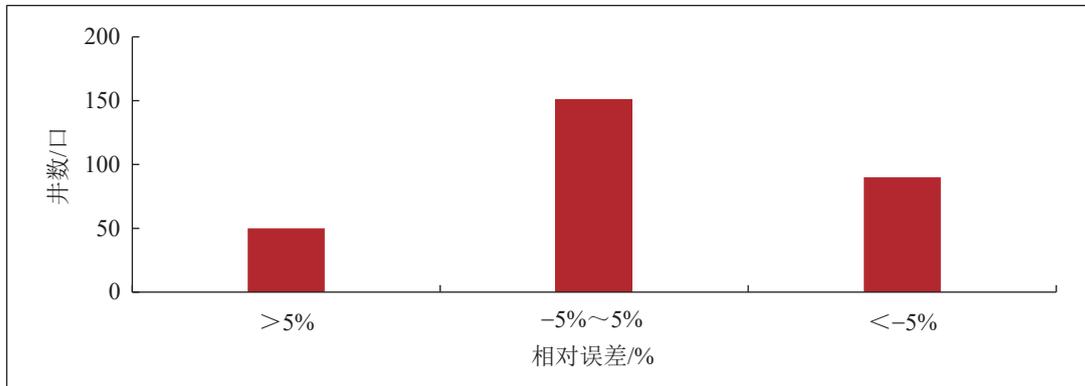


图2 模型预测与人工测试动液面的相对误差分布

Fig. 2 Relative Error Distribution between Model Prediction and Manual testing of Dynamic Liquid Level

从图2中可以看出,模型预测动液面与人工实测动液面相对误差在 $\pm 5\%$ 以内的油井151口,占比91.5%。对相对误差超出5%的油井进行排查,发现主要原因有三点:一是传感器故障。抽油机井载荷、位移、电参传感器故障后,导致无法获得准确的示功图与功率图,进而使得模型预测误差变大;二是载荷传感器漂移。载荷传感器漂移时,采集示功图的最大载荷与最小载荷时而大时而小,模型预测动液面也呈现较大幅度的波动;三是气液比高。气液比过高时,井筒呈现复杂的多相管流状态,抽油机井液柱载荷时而大时而小,模型预测动液面同样会呈现一定程度的波动。

为了进一步确定动液面预测结果与人工测试的准确性误差,选取Y18-34、Y18-35两口油套环空“注水试验”油井的5次测试结果进行分析,如图3所示。

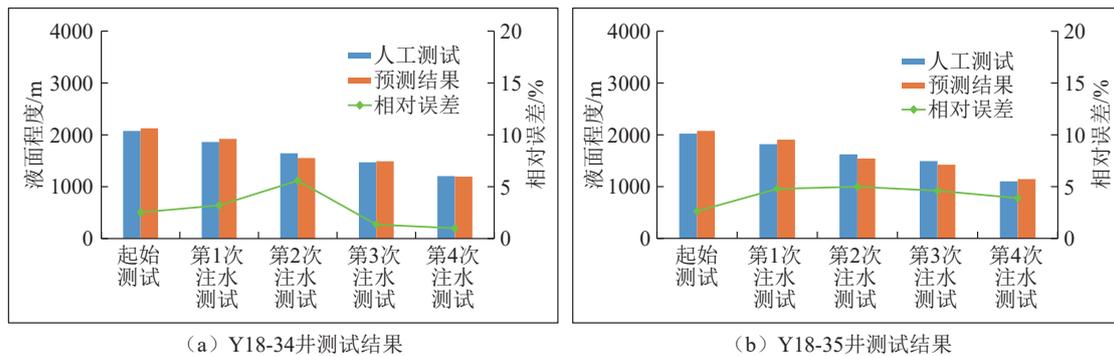


图3 抽油机井油套环空注水试验过程中动液面变化趋势分析

Fig. 3 Analysis of the Trend of Dynamic Liquid Level Changes During the Water Injection Test in the Oil Casing Annulus of a Pumping Unit Well

从图3中可以看出,预测动液面与实测动液面平均相对误差3.5%,且预测动液面与实测动液面变化趋势一致,均能准确反映“油套环空注水量不断增加,动液面数据不断变小”的现象。究其根源,主要得益于以下三点:一是用于预测动液面的抽油机特征参量做了无因次化处理。一定程度上消除了不同井型、不同油藏物性的影响,增强不同井之间特征参量的普适性,消除数据之间的差异性,提升了模型预测在不同抽油井上的适应性;二是用于模型训练的数据样本量较大且质量较高。模型训练样本数据多达45000组,来自于5000口抽油机井,内部包含有不同抽油机井的主控特征参量,也包含有同一口抽油机井的多组主控特征参量。通过不同抽油机井的训练样本数据,可以训练出动液面预测模型的“共性”;通过同一抽油机井的训练样本,可以训练出动液面预测模型的“个性”。整体实现了“共性”与“个性”的协调统一,使得模型预测精度得到提升;三是采用了变权重组合的动液面预测模型。综合了XGBoost预测模型、LightGBM预测模型、

BP神经网络预测模型的优势,因此在复杂数据处理、非线性映射、高精度需求、高效性能要求的动液面预测场景下较为适用。

(3)预测模型用于优化间抽井生产制度分析。选取 Y15-35 油井的 3 天 9 组动液面测试数据进行分析,发现该井动液面整体呈现上涨趋势,说明 Y15-35 油井的间抽制度(开 2 h 停 6 h)不够合理,抽油机井停井时间过长,油藏渗流速度大于井筒排液速度,且处于“供”大于“排”的状态,导致该井实施间抽后产液量下降。因此,需要延长开井时间,使抽油机井进入供排协调状态。最终,确定 Y15-35 油井的间抽制度为开 3 h 停 5 h。实施后,发现该井动液面整体平稳,说明 Y15-35 油井的间抽制度(开 3 h 停 5 h)科学合理,抽油机井当下处于供排协调状态。综上所述,利用变权重组合动液面预测模型可实时分析抽油机井动液面变化趋势,制定较为合理的间抽生产制度。

2 结果现象讨论

2.1 测试效率及劳动强度综合分析

传统人工动液面测试方法,测试效率较低,主要体现在以下 3 个方面。

(1)测试过程繁琐。在每次动液面测试操作过程中,工作人员需要开关套压控制阀门、拆装套压取压装置和井口连接器等工序。这些工序繁琐且复杂,需要花费大量的时间和精力。尤其是在一些特殊环境下,如冬季井口有油水留存,受低温影响,闸门及套压取压装置极易发生冻堵现象,这进一步增加了测试的难度和时间成本。

(2)安全风险较高。人工测试动液面过程中,工作人员需要接触各种设备和井口装置,这存在一定的安全风险。特别是在拆装套压取压装置和井口连接器时,如果操作不当或设备出现故障,很容易导致人员受伤或设备损坏。此外,由于测试过程中需要接触高压流体和电气设备,因此还需要特别注意电气安全和防火防爆等问题。

(3)劳动强度大。由于测试过程繁琐、安全风险高等问题,人工测试动液面的劳动强度非常大。工作人员需要长时间在井口进行高强度的工作,这不仅需要良好的身体素质和专业技能,还需要高度的责任心和耐心。长期的高强度工作容易导致工作人员疲劳和注意力分散,从而引发较高安全风险,同时测试液面数据出现较大误差的可能性变大。

总体来看,人工动液面测试需要两名技术人员共同开展,一天大概能测试 50 口井,测试效率较低。

基于变权重组合动液面预测模型的测试效率及劳动强度分析如下。

(1)测试效率分析。动液面预测模型可以通过连续的数据采集和预测算法,实现动液面的实时监测和预测。这大大提高了测试效率,使得技术人员能够及时了解油井的工况变化。同时,随着大数据和云计算技术的发展,动液面预测模型的数据处理能力得到了显著提升。模型能够快速处理大量数据,并实时输出预测结果。这进一步提高了测试效率,使得技术人员能够更快速地做出生产决策。

(2)劳动强度分析。动液面预测模型的应用大大减少了人工干预。传统的动液面测量方法需要人工定期到现场进行测量和记录,而预测模型则可以通过远程监控和自动化采集数据,实现无人值守的监测和预测。这大大降低了劳动强度,提高了工作效率。

随着自动化和智能化技术的发展,动液面预测模型应用场景将会进一步拓展。例如,通过自适应动态规划方法对抽油机冲次进行优化控制,可以根据动液面的变化自动调节抽油机的冲次,从而保持采油量与地层供给量的平衡。自动化和智能化的控制方式进一步降低了劳动强度,提高了生产效率。

虽然动液面预测模型的应用降低了技术人员现场测量的劳动强度,但数据管理与分析的工作量却有所增加。模型需要处理大量数据,并进行复杂的计算和预测。因此,需要配备专业的数据管理和分析人员来确保数据的准确性和可靠性。然而,与现场测量的劳动强度相比,这种数据管理与分析的工作量相对较小。

综上所述, 动液面预测模型的测试效率较高, 能够实现实时监测和预测。以一个 5 万口油井的大油田为例, 10 min 内可完成全油田所有油井的动液面测试工作。因此, 相较于传统人工测试方法, 测试效率提升 15 万倍以上。同时, 劳动强度较低, 相较于传统人工测试方法, 技术人员劳动强度下降 90% 以上。

2.2 测试频次量化分析

传统的动液面测试方法依赖于人工操作, 其测试频率设定为每月两次, 具体安排在每月的上旬和下旬各进行一次。这种测试方式虽然在一定程度上能够满足对油井动态液面监测的基本需求, 但受限于测试频次, 对于油井实时状态变化的捕捉能力相对有限, 难以实现对油井生产状况的即时反馈和精细管理。

相比之下, 变权重组合动液面预测模型的引入则彻底改变了这一状况。该模型的创新之处在于, 它将测试频次与抽油机井的功图、功率图采样频次紧密结合起来, 实现了测试频率的大幅提升。目前, 抽油机井的功图和功率图采样已经达到每 10 分钟一次的频率, 这意味着每天可以进行多达 144 次的测试, 换算到每月, 测试次数高达 4 320 次。这一数字相较于传统的人工测试方式, 提升了 2 000 余倍, 极大地提高了数据获取的密度和准确性, 为油井的动态管理和优化提供了强有力的数据支撑。

更为值得一提的是, 这一模型的潜力还远未被完全挖掘。未来, 如果能够将这一先进的预测模型嵌入到边缘端的智能 RTU(远程终端单元)中, 那么其测试频次将有望实现进一步的飞跃。届时, 动液面的测试将不再受限于固定的时间间隔, 而是与抽油机井的冲次直接挂钩。每当抽油机井完成一个完整的冲次, 就能立即进行一次动液面的测试, 这种实时性的提升, 意味着测试频次相较于当前水平还能再提升几十倍之多。

这样的改变, 不仅将油井的监测精度和实时性推向了一个新的高度, 更为油井的高效运行、故障预防以及生产优化提供了前所未有的可能。通过实时、高频次的动液面数据, 技术人员可以更加精准地掌握油井的工作状态, 及时发现潜在问题, 采取相应措施, 从而有效提升油井的生产效率和安全性, 为油田的数字化转型和智能化发展奠定坚实基础。

2.3 测试成本量化分析

传统人工测试动液面成本高的问题确实比较突出, 主要表现在人力成本高昂、设备成本与维护费用高等 3 个方面。

(1)人力成本高昂。人工测试动液面需要专业的工作人员进行操作, 这些工作人员不仅需要具备丰富的经验和技能, 还需要接受专门的培训。随着人力资源成本的不断提高, 这些工作人员的薪资报酬也呈现上升趋势。此外, 测试过程中需要的人工时间成本也相对较高, 因为测试过程繁琐, 需要花费大量的时间和精力。

(2)设备成本与维护费用高昂。虽然动液面测试设备本身不属于人力成本范畴, 但属于人工测试过程中不可或缺的一部分。这些设备通常价格昂贵, 包括声波液面测试装置(分为移动式手动和固定式自动两种)、井口连接器、测试仪主机等。同时, 设备的维护和校准也需要定期投入资金, 以确保设备的准确性和可靠性。长期使用的设备还可能出现老化现象, 导致测试结果不准确, 需要更换新设备, 进一步增加了成本。

(3)间接成本不容忽视。除了直接的人力成本和设备成本外, 人工测试动液面还会产生一些间接成本。例如, 测试过程中可能需要使用各种耗材, 如声波发射器、接收器、线缆等, 这些耗材的消耗和更换也会增加成本。此外, 测试过程中还需要考虑安全风险和质量控制等因素, 这些都需要投入相应的资金来确保测试的顺利进行和结果的准确性。

综合考虑人力成本、设备成本、耗材成本以及间接成本等因素, 每口井单次测试费用 200 元。以一个 5 万口油井的大油田为例, 采用传统人工动液面测试方法, 每年每口井测试 24 次, 单次测试费用 200 元, 5 万口油井大约年发生费用 2.4 亿元。由此可见, 人工测试动液面的成本确实相对较高。这些成本不仅增加了企业的运营负担, 还可能影响企业的竞争力和可持续发展能力。

变权重组合动液面预测模型预测动液面成本分析是一个复杂的过程, 涉及多个方面的成本考虑。以下

是对这一过程的详细分析。

(1)模型开发与维护成本。主要包括5个方面。一是数据收集与处理成本。为了建立动液面预测模型,需要收集大量的历史数据,包括日产液量、井口套压、泵效等与动液面相关的参数。这些数据的收集、清洗、整理和处理都需要耗费一定的时间和资源。二是模型选择与优化成本。根据数据的特征和趋势,选择合适的预测模型,并使用统计方法对模型的参数进行估计和优化。这一过程需要专业的知识和技能,以及相应的投入。三是模型开发成本。也既是软件与硬件投入成本,模型开发过程中可能需要使用特定的软件工具(如MATLAB等)和硬件设备(如高性能服务器等)。这些软件和硬件的购置、安装和维护都需要成本投入。四是模型的更新与迭代成本。随着油井工况的变化和数据的积累,模型需要不断更新和迭代以保持其预测精度。这包括重新收集数据、调整模型参数、优化算法等步骤。五是技术支持与培训成本。为了确保模型的稳定运行和有效应用,需要为相关人员提供技术支持和培训。这包括模型的使用说明、故障排除、参数调整等方面的培训。

(2)数据获取与存储成本。主要包括2个方面。一是数据获取成本。为了获取与动液面预测相关的数据,可能需要购买第三方数据服务或与其他机构进行数据共享。都需要一定的成本投入。二是数据存储成本。随着数据的不断积累,需要相应的存储设备和存储空间来保存这些数据。这包括硬盘、云存储等存储介质的购置和维护成本。

(3)预测与应用成本。主要包括2个方面。一是预测成本。在进行动液面预测时,需要消耗一定的计算资源(如CPU、内存等)。这些资源的消耗会导致电力消耗和硬件磨损等成本。预测过程的时间消耗和效率也会影响成本。高效的预测模型可以缩短预测时间,从而降低预测成本。二是应用成本。动液面预测结果可以为油田生产决策提供支持。但决策过程中可能需要考虑多个因素,包括预测结果的准确性、可靠性、成本效益等。同时,在应用预测模型时,需要相应的操作和维护人员来确保模型的稳定运行和有效应用。这些人员的工资、福利等成本也需要考虑在内。

总体来看,固定成本包括模型开发与维护成本中的软件与硬件投入、技术支持与培训等固定投入。变动成本包括数据获取与存储成本中的数据购买费用、数据存储费用等随数据量变化的成本,以及预测与应用成本中的计算资源消耗费用、操作与维护人员工资等随预测次数和应用规模变化的成本。按照5万口油井的大油田为例,利用变权重组合动液面预测模型开展动液面测试工作,预估年发生费用1000万,相较于传统人工测试方法,测试成本降低96%。

3 结论建议

(1)按照“数据收集与预处理、主控特征参量优选、模型构建及训练评价、模型现场验证”的技术思路,形成了基于变权重组合动液面预测模型技术成果,与传统人工测试方法对比,平均相对误差在5%以内,测试效率提升15万倍以上,劳动强度降低90%以上,测试频次高出2000多倍,测试成本降低96%。切实解决了传统人工测试方法劳动强度大、测试频次低、测试成本高等问题,为国内油田动液面测试提供了新思路。

(2)变权重组合动液面预测模型充分发挥了XGBoost、LightGBM、BP神经网络深度学习方法的优势,降低模型复杂度、提高模型泛化能力,实现了抽油机井动液面的低成本、高可靠性、精准性测试,并对抽油机井生产制度优化起到重要作用,可以有效提升抽油机井生产效率与效益。截止2023年底,仅中国石油机采井达23.9万口,其中抽油机井21.6万口,若全面推广应用该技术,预估生产效益近10亿元。

(3)变权重组合动液面预测模型在应用过程中,随着应用时间的延长,由于载荷传感器长期受压,存在“数据飘移失真”现象,一定程度上导致动液面预测精度变差。因此,需建立记忆神经网络模型,预测载荷传感器漂移规律,进一步对动液面预测模型的关键载荷类主控特征参量进行修正,以提升测试精度。当传感

器出现“严重数据漂移失真”现象时, 建议及时更换载荷传感器。

(4)考虑到预测模型在动液面预测应用方面取得的显著成效, 下步拟计划将其应用于抽油机井含水率预测。载荷、电参信息均包含有液柱载荷信息, 与井液密度密切相关, 通过将变权重预测模型与多相管流模型融合, 有望实现抽油机井含水率的精准预测; 亦可用于工况诊断及超前治理。当抽油机井出现结蜡、偏磨工况时, 其载荷、电参等数据会出现比较明显的规律性变化, 通过应用机器学习方法, 可对结蜡、偏磨程度进行定量化预测, 及时进行干预, 延长抽油机井检泵周期; 还可应用于油气生产设备预测性维护。通过对关键设备加装能够采集振动、温度、音频的传感器, 研究不同工况下关键设备的振动、温度、音频信息, 可实现油气生产设备的预测性维护。

致谢

长庆油田分公司油气工艺研究院对科技成果给予大力支持并且允准发表科技论文, 低渗透油气田勘探开发国家工程实验室为科技成果提供了较好的实验环境, 在此谨致谢忱。

稿件申明

作者排名已征得全部作者的同意, 学术观点方面全部作者的观点均一致, 文章涉及的内容不存在学术不端的问题。

署名贡献声明

艾信, 项目负责人, 提出了研究课题以及论文的修改。

刘天宇, 样本数据收集及处理, 为论文撰写提供技术性支持。

张浩伟, 模型训练及评价优选, 为论文撰写提供技术性支持。

曹伟, 现场测试数据收集与处理, 为论文撰写提供技术性支持。

周娟, 现场测试数据收集与处理, 为论文撰写提供技术性支持。

辛宏, 试验数据处理, 为论文撰写提供技术性支持。

利益冲突说明

论文发表的技术与观点与其他机构不存在利益冲突。涉及的专利已经征得所有发明人的同意且已签字确认, 发表的论文不涉及企业技术商业秘密, 专家审稿无要求避讳问题。

数据可用性声明

本研究中涉及的所有原始数据、分析脚本及研究过程中产生的其他相关数据资料, 均已妥善保存并可通过合理请求获得。为确保数据的隐私与安全, 以及遵守相关伦理与法律要求, 部分敏感或个人信息已进行脱敏处理。研究者鼓励并欢迎其他学者基于本研究数据进行进一步的探索与分析。如有数据访问需求, 请通过电子邮件联系本研究的通信作者, 并在邮件中明确说明数据使用目的、研究计划以及预期的研究成果。我们将在收到请求后的合理时间内, 根据数据共享政策与程序, 对请求进行评估并作出回应。

参考文献

- [1] 王振龙, 何岩峰, 王相, 等. 基于数据驱动的油井生产参数智能调控方法 [J]. 断块油气田, 2022, 29(6): 859-864. //WANG Zhenlong, HE Yanfeng, WANG Xiang, et al. Intelligent control method for oil well production parameters based on data-driven approach [J]. Block Oil and Gas Field, 2022, 29(6): 859-864.
- [2] 聂仁仕, 贾冉, 蔡明金, 等. 双孔双渗油藏斜井压力动态特征分析 [J]. 深圳大学学报: 理工版, 2022, 39(6): 8. //NIE Ren-shi, JIA Ran, CAI Mingjin, et al. Analysis of dynamic characteristics of inclined well pressure in dual hole and dual permeability reservoirs [J]. Journal of Shenzhen University: Science and Engineering Press, 2022, 39(6): 8.
- [3] 胡书勇, 郑冰洋, 阴艳芳. 基于模糊评判决策的天然气驱油藏开发效果评价 [J]. 西南石油大学学报 (自然科学版), 2024, 46(1): 105-114. //HU Shuyong, ZHENG Bingyang, YIN Yanfang. Evaluation of natural gas drive reservoir development effect based on fuzzy evaluation decision-making [J]. Journal of Southwest Petroleum University (Natural Science Edition), 2024,

- 46(1): 105-114.
- [4] 魏勇, 成崑, 王路平, 等. 动液面深度检测中两个关键问题的研究进展 [J]. *科学技术与工程*, 2023, 23(20): 8473-8483. //WEI Yong, CHENG Jun, WANG Luping, et al. Research progress on two key issues in dynamic liquid level depth detection [J]. *Science, Technology and Engineering*, 2023, 23(20): 8473-8483.
- [5] 汪玉祥, 魏勇, 王路平, 等. 井下动液面深度测量系统的设计与实现 [J]. *仪表技术与传感器*, 2022(10): 81-87. //WANG Yuxiang, WEI Yong, WANG Luping, et al. Design and implementation of underground dynamic liquid level depth measurement system [J]. *Instrumentation Technology and Sensors*, 2022(10): 81-87.
- [6] 陈俊荣, 甘如飴, 魏勇, 等. 一种用于动液面测量仪自检的井下声信号模拟器 [J]. *仪表技术与传感器*, 2024(8): 25-29, 52. //CHEN Junrong, GAN Ruyi, WEI Yong, et al. A downhole acoustic signal simulator for self checking of dynamic liquid level measuring instrument [J]. *Instrumentation Technology and Sensors*, 2024(8): 25-29, 52.
- [7] 李翔宇, 高宪文, 李琨, 等. 基于多源信息特征融合的抽油井动液面集成软测量建模 [J]. *化工学报*, 2016, 67(6): 11. //LI Xiangyu, GAO Xianwen, LI Kun, et al. Integrated soft sensing modeling of dynamic liquid level in pumping wells based on multi-source information feature fusion [J]. *Journal of Chemical Engineering*, 2016, 67(6): 11.
- [8] 张乃禄, 盛盟, 颜瑾, 等. 集散式油井动液面监测井场集中监控器研制 [J]. *西安石油大学学报: 自然科学版*, 2020, 35(3): 7. //ZHANG Nailu, SHENG Meng, YAN Jin, et al. Development of centralized monitoring system for dynamic liquid level in distributed oil wells [J]. *Journal of Xi'an Petroleum University: Natural Science Edition*, 2020, 35(3): 7.
- [9] 张洪涛, 付威, 王春骞, 等. 光纤温压法实现油井动液面的实时监测 [J]. *哈尔滨理工大学学报*, 2018, 23(6): 6. //ZHANG Hongtao, FU Wei, WANG Chunqian, et al. Real time monitoring of oil well dynamic liquid level using fiber optic temperature pressure method [J]. *Journal of Harbin Institute of Technology*, 2018, 23(6): 6.
- [10] 邓虎. 油气井中电磁波无线传输技术研究及应用 [J]. *钻采工艺*, 2022, 45(4): 19-25. //DENG Hu. Research and application of electromagnetic wave wireless transmission technology in oil and gas wells [J]. *Drilling and Production Technology*, 2022, 45(4): 19-25.
- [11] 周志军, 张文博, 朱智欣, 等. 利用地面功图对抽油机井动液面计算方法的优化研究 [J]. *数学的实践与认识*, 2019, 49(24): 8. //ZHOU Zhijun, ZHANG Wenbo, ZHU Zhixin, et al. Optimization study on calculation method of dynamic liquid level in pumping unit wells using ground power diagram [J]. *Practice and Understanding of Mathematics*, 2019, 49(24): 8.
- [12] 刘新社, 张涛, 黄道军, 等. 鄂尔多斯盆地中东部太原组石灰岩天然气勘探新突破及勘探方向 [J]. *天然气工业*, 2023, 43(5): 1-11. //LIU Xinshe, ZHANG Tao, HUANG Daojun, et al. New breakthroughs and exploration directions in natural gas exploration of Taiyuan Formation limestone in the central and eastern Ordos Basin [J]. *Natural Gas Industry*, 2023, 43(5): 1-11.
- [13] 杨勇. 胜利油田勘探开发大数据及人工智能技术应用进展 [J]. *油气地质与采收率*, 2022, 29(1): 1-10. //YANG Yong. Progress in the application of big data and artificial intelligence technology in the exploration and development of Shengli Oilfield [J]. *Oil and Gas Geology and Recovery*, 2022, 29(1): 1-10.
- [14] 刘芑辰, 冯子明, 蒋国斌, 等. 基于卷积神经网络模型的抽油机系统故障诊断 [J]. *石油钻采工艺*, 2021, 43(6): 777-781. //LIU Qichen, FENG Ziming, JIANG Guobin, et al. Fault diagnosis of pumping unit system based on convolutional neural network model [J]. *Petroleum Drilling and Production Technology*, 2021, 43(6): 777-781.
- [15] 王娟, 梅启亮, 邹永玲, 等. 基于多参数时间序列及粒子群优化算法的油藏产量动态建模预测方法 [J]. *石油钻采工艺*, 2023, 45(2): 190-196. //WANG Juan, MEIQiliang, ZOU Yongling, et al. Dynamic modeling and prediction method for reservoir production based on multi parameter time series and particle swarm optimization algorithm [J]. *Petroleum Drilling and Production Technology*, 2023, 45(2): 190-196.
- [16] 王相, 杨耀忠, 何岩峰, 等. 基于深度学习的油井工况智能诊断技术研究及应用 [J]. *油气地质与采收率*, 2022, 29(1): 9. //WANG Xiang, YANG Yaozhong, HE Yanfeng, et al. Research and application of intelligent diagnosis technology for oil well working conditions based on deep learning [J]. *Oil and Gas Geology and Recovery*, 2022, 29(1): 9.
- [17] 王通, 陈延彬. 基于改进生成对抗网络的动液面建模数据扩充 [J]. *电子测量与仪器学报*, 2023, 37(2): 99-109. //WANG Tong, CHEN Yanbin. Expansion of dynamic liquid surface modeling data based on improved generative adversarial networks [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(2): 99-109.

- [18] 姜春雷, 方硕, 刘伟, 等. 基于卷积神经网络和迁移学习的特高含水油井生产预测 [J]. 中国石油大学学报 (自然科学版), 2023, 47(6): 162-170. //JIANG Chunlei, FANG Shuo, LIU Wei, et al. Production prediction of ultra-high water cut oil wells based on convolutional neural networks and transfer learning [J]. Journal of China University of Petroleum (Natural Science Edition), 2023, 47(6): 162-170.
- [19] 周斌, 邢林林, 张敏. 基于八链码形状匹配的抽油机井地面示功图凡尔开闭点识别 [J]. 科学技术与工程, 2022, 22(12): 4788-4796. //ZHOU Bin, XING Linlin, ZHANG Min. Identification of valve opening and closing points on the surface indicator diagram of pumping unit wells based on eight chain code shape matching [J]. Science, Technology and Engineering, 2022, 22(12): 4788-4796.
- [20] 高小永, 李晨龙, 檀朝东, 等. 无储能光-电微网下的抽油机井群间抽混合整数非线性优化方法 [J]. 石油钻采工艺, 2023, 45(6): 773-782. //GAO Xiaoyong, LI Chenlong, TAN Chaodong, et al. A mixed integer nonlinear optimization method for inter well pumping of pumping units in a microgrid without energy storage [J]. Petroleum Drilling and Production Technology, 2023, 45(6): 773-782.
- [21] 贾俊杰, 刘春海, 管桐, 等. 基于 CNN-BiGRU 混合神经网络的电潜螺杆泵产液量预测方法 [J]. 石油钻采工艺, 2022, 44(6): 784-790. //JIA Junjie, LIU Chunhai, GUAN Tong, et al. Prediction method for liquid production of electric submersible screw pump based on CNN BiGRU hybrid neural network [J]. Petroleum Drilling and Production Technology, 2022, 44(6): 784-790.
- [22] 周纲, 黄瑞, 刘度度, 等. 基于改进 K-means 聚类 and 皮尔逊相关系数户变关系异常诊断 [J]. 电测与仪表, 2024, 61(3): 76-82,152. //ZHOU Gang, HUANG Rui, LIU Dudu, et al. Abnormal diagnosis of household variable relationship based on improved K-means clustering and Pearson correlation coefficient [J]. Electrical Measurement and Instrumentation, 2024, 61(3): 76-82,152.
- [23] 康晓非, 曾璇, 乔威. 基于 XGBoost 预测及弹性网误差补偿的室内定位算法 [J]. 系统仿真学报, 2022, 34(4): 719-726. //KANG Xiaofei, ZENG Xuan, QIAO Wei. Indoor positioning algorithm based on XGBoost prediction and elastic network error compensation [J]. Journal of System Simulation, 2022, 34(4): 719-726.
- [24] 丁昌伟, 王新, 陈同俊, 等. 贝叶斯优化的 XGBoost 在小断层地震解释中的应用 [J]. 煤炭学报, 2023, 48(6): 2530-2539. //DING Changwei, WANG Xin, CHEN Tongjun, et al. Application of bayesian optimized XGBoost in seismic interpretation of small faults [J]. Coal Journal, 2023, 48(6): 2530-2539.
- [25] 谢华祥, 高建华, 黄子杰. 基于 SDL-LightGBM 集成学习的软件缺陷预测模型 [J]. 计算机工程与设计, 2024, 45(3): 769-776. //XIE Huaxiang, GAO Jianhua, HUANG Zijie. Software defect prediction model based on SDL LightGBM ensemble learning [J]. Computer Engineering and Design, 2024, 45(3): 769-776.
- [26] 李海霞, 宋丹蕾, 孔佳宁, 等. 传统机器学习模型的超参数优化技术评估 [J]. 计算机科学, 2024, 51(8): 242-255. //LI Haixia, SONG Danlei, KONG Jianing, et al. Evaluation of hyperparameter optimization techniques for traditional machine learning models [J]. Computer Science, 2024, 51(8): 242-255.
- [27] 邹旺, 刘军, 柳福祥. 基于灰关联的 $GOM^{(p,q)}(1,2)$ -BP 神经网络模型及 AQI 预测 [J]. 数学的实践与认识, 2023, 53(4): 151-161. //ZOU Wang, LIU Jun, LIU Fuxiang. $GOM^{(p,q)}(1,2)$ -BP neural network model and AQI prediction based on grey correlation [J]. Practice and Understanding of Mathematics, 2023, 53(4): 151-161.
- [28] 邹琼, 吴曦, 张杨, 等. 基于麻雀搜索算法优化的 BP 神经网络模型对 2 型糖尿病肾病的预测研究 [J]. 中国全科医学, 2024, 27(8): 961-970. //ZOU Qiong, WU Xi, ZHANG Yang, et al. Prediction of type 2 diabetes nephropathy based on BP neural network model optimized by sparrow search algorithm [J]. Chinese General Practice, 2024, 27(8): 961-970.
- [29] 李文博, 丁勇, 李登华. 基于变权重大坝预测模型的组合告警方法研究 [J]. 人民长江, 2023, 54(12): 233-240. //LI Wenbo, DING Yong, LI Denghua. Research on Combination Alarm Method Based on Variable Weight Dam Prediction Model [J]. People's Yangtze River, 2023, 54(12): 233-240.
- [30] 马骁雨, 张慧芬, 刘宗杰, 等. 基于变权重组合的电气设备温度预测模型 [J]. 控制工程, 2023, 30(4): 694-702. //MA Xiaoyu, ZHANG Huifen, LIU Zongjie, et al. Temperature prediction model for electrical equipment based on variable weight combination [J]. Control Engineering, 2023, 30(4): 694-702.