

地质力学参数智能预测技术进展与发展方向

马天寿^{1*}, 张东洋¹, 陆灯云², 谢祥锋², 刘阳³

1 西南石油大学油气藏地质及开发工程全国重点实验室, 成都 610500

2 中国石油川庆钻探工程有限公司, 成都 610501

3 西南石油大学石油天然气装备教育部重点实验室, 成都 610500

* 通信作者, matianshou@126.com

收稿日期: 2024-04-12; 修回日期: 2024-05-22

四川省杰出青年科技人才项目(2020JDJQ0055)、四川省自然科学基金重点项目(2024NSFC0023)联合资助

摘要 随着人工智能技术在油气勘探领域应用的不断深入, 地质力学参数预测从传统方法向智能化转型已成为必然趋势。本文系统归纳分析了机器学习算法在岩石力学参数直接与间接预测, 地层孔隙压力钻前预测、随钻监测和钻后评估, 一维地应力和三维地应力场预测中的应用现状, 对比了不同预测任务下的机器学习模型、输入参数、样本数据量、输出参数以及模型预测性能。研究发现: 相比于室内试验、现场测试和经验模型计算, 机器学习算法在地质力学参数预测方面的准确性、时效性和适用性具有明显优势; 集成模型、深度学习模型和物理约束神经网络模型凭借其准确性、鲁棒性、泛化能力和可解释性, 已成为当前研究的热点和重点; 但现有研究以一维地质力学参数的钻后预测为主, 因而无法有效进行钻前和随钻三维地质力学参数预测。为了加快地质力学参数向智能化、数字化转型, 本文提出了一种地质力学参数智能预测框架, 该框架考虑地震、测井、录井等多源数据对地质力学参数预测的影响, 通过数据+物理双驱动的机器学习模型进行三维地质力学参数的预测, 并通过正钻井数据进行模型的实时更新, 从而实现区域三维地质力学参数的钻前预测、随钻监测以及钻后评估。此外, 分析了地质力学参数智能预测面临的关键技术难题: ①实现非结构化数据类型的转换, 降低数据集复杂度, 确保数据的一致性和可比性; ②开展多源数据融合研究, 构建包括地震、测井、录井、室内试验、现场测试等方面的数据集, 并进行数据处理、特征选择等工作; ③加强机器学习模型研究以提升性能, 采用集成模型提升预测精度, 融入机理模型和领域知识提升模型鲁棒性和可解释性。

关键词 地质力学; 智能预测; 机器学习; 岩石力学; 地层压力; 地应力

中图分类号: P618.13; TE321

Progress and development direction of intelligent prediction technology of geomechanical parameters

MA Tianshou¹, ZHANG Dongyang¹, LU Dengyun², XIE Xiangfeng², LIU Yang³

1 National Key Laboratory of Oil and Gas Reservoir Geology and Exploitation, Southwest Petroleum University, Chengdu 610500, China

2 CNPC Chuanging Drilling Engineering Co. Ltd., Chengdu 610051, China

引用格式: 马天寿, 张东洋, 陆灯云, 谢祥锋, 刘阳. 地质力学参数智能预测技术进展与发展方向. 石油科学通报, 2024, 03: 365–382

MA Tianshou, ZHANG Dongyang, LU Dengyun, XIE Xiangfeng, LIU Yang. Progress and development direction of intelligent prediction technology of geomechanical parameters. Petroleum Science Bulletin, 2024, 03: 365-382. doi: 10.3969/j.issn.2096-1693.2024.03.027

3 MOE Key Laboratory of Oil & Gas Equipment, Southwest Petroleum University, Chengdu 610500, China

Received: 2024-04-12; Revised: 2024-05-22

Abstract The progressive application of artificial intelligence technology within oil and gas exploration has resulted in an inevitable shift towards the transformation of geomechanical parameter prediction from a traditional to an intelligent approach. This paper presents a comprehensive review and critical analysis of machine learning algorithms in the direct and indirect prediction of rock mechanics parameters, pre-drilling prediction, monitoring while drilling and post-drilling evaluation of formation pore pressure, 1D in-situ stresses and 3D in-situ stresses field prediction. Furthermore, the paper compared machine learning models, input parameters, sample data volume, output parameters, and model prediction performance under different tasks. It has been demonstrated that machine learning algorithms exhibit superior performance in terms of accuracy, timeliness, and applicability in geomechanical parameter prediction compared to laboratory tests, field tests, and empirical model calculations. The current research emphasis is on hybrid models, deep learning models, and physical-constrained neural network models, which have been validated as highly accurate, robust, capable of generalization, and easily interpretable. However, the existing research primarily concerns the prediction of 1D geomechanical parameters post-drilling. Consequently, it is not possible to effectively predict 3D geomechanical parameters prior to drilling or during the drilling process. In order to facilitate the digital and intelligent transformation of geomechanical parameters, an intelligent prediction framework for geomechanical parameters is proposed in this paper. This framework considers the influence of multi-source data, including seismic, logging, and mud log data on the prediction of geomechanical parameters. The machine learning model, which is driven by data and physics, enables the prediction of 3D geomechanical parameters. This model is updated in real-time through the most recent drilling data, thus allowing for the pre-drilling prediction, monitoring while drilling and post-drilling evaluation of regional 3D geomechanical parameters. In addition, the key technical problems facing the intelligent prediction of geomechanical parameters are identified: (1) The transformation of unstructured data types should be minimized, the complexity of the data set should be reduced, and the consistency and comparability of the data should be ensured. (2) Multi-source data fusion should be conducted, and multi-source data sets, including seismic, logging, mud log, laboratory tests, and field test data, should be constructed. Subsequently, data processing and feature selection should be performed. (3) Machine learning models should be enhanced to improve performance, integrated models should be adopted to improve prediction accuracy, and mechanism models and domain knowledge should be integrated to enhance model robustness and explainability.

Keywords geomechanics; intelligent prediction; machine learning; rock mechanics; formation pressure; in-situ stress

doi: 10.3969/j.issn.2096-1693.2024.03.027

0 引言

地质力学参数通常包括岩石力学参数、地层压力、地应力等，这些参数的准确预测对于井身结构优化、井壁稳定分析、水力压裂设计等具有至关重要的作用，是确保钻完井设计和作业安全的重要基础^[1-3]。目前，获取地质力学参数的方法主要有室内试验、现场测试、经验模型和三维地质力学建模等，但这些方法往往存在过程复杂、成本高、计算困难等问题^[4-5]。特别是随着我国油气钻探向深层、超深层发展，复杂的地质环境使得确定这些参数变得更加困难^[6]。因此，探索更高效、经济的方法以准确获取地质力学参数，对于提高油气勘探开发的效率和安全性具有重要意义。

随着可用数据量的激增和机器学习技术的快速发展，国内外学者在岩性分类、风险监测、井壁稳定分析等多个领域中进行了大量的机器学习研究^[7-10]。利用机器学习方法预测地质力学参数可以简化计算过程、降低所需成本、提高预测精度，其强大的计算能力使

其面对复杂的地质环境也能做出准确的预测，地质力学参数预测向智能化转型已成为必然趋势。目前已经有一部分学者发表了一些综述论文^[11-15]，但这些论文通常仅限于特定领域。例如，程希等^[12]概述了地球物理测井中机器学习算法的应用，Pan 等^[13-14]总结了机器学习在地层孔隙压力预测中的应用现状，Sazid 等^[15]专注于研究机器学习在地应力预测中的应用进展。然而，目前还缺乏对机器学习在地质力学参数预测应用中的全面回顾和深入分析。

笔者根据地质力学参数的类型划分，如图 1 所示，充分调研了使用机器学习方法进行岩石力学参数间接和直接预测，地层孔隙压力的钻前预测、随钻监测和钻后评估，以及地应力的一维和三维预测中的研究现状，分析了地质力学参数智能预测的发展趋势，总结了现有研究的不足之处，提出了一种地质力学参数智能预测框架，以期为地质力学参数预测向数字化、智能化转型提供参考。



图 1 地质力学参数智能预测

Fig. 1 Intelligent prediction of geomechanical parameters

1 岩石力学参数智能预测技术进展

岩石力学参数是地层岩石力学性质的重要表征指标，也是计算地层孔隙压力、构造区块地应力场的关键参数。岩石力学参数主要包括弹性模量(E)、剪切模量(G)、体积模量(K)、泊松比(μ)等弹性参数，以及单轴强度(σ_c)、抗张强度(σ_t)、内摩擦角(C)、内聚力(φ)等强度参数。目前，获取岩石力学参数主要依赖于室内岩石力学试验或测井解释。其中，室内试验可以获取较为准确的岩石力学参数，但其具有实验成本高、耗时长、数据有限且不连续等问题。岩石力学参数的

测井解释可以获取相对连续的参数剖面，但其计算过程涉及横波速度、孔隙度等中间参数，并需要通过实验测量值进行校正，仅适用于特定的岩性和深度范围，普适性较差^[16]。为了解决这些问题，国内外学者开展了大量使用机器学习进行岩石力学参数预测的研究。综合分析现有研究，将机器学习在岩石力学参数预测中的应用分为间接预测和直接预测两类。

1.1 间接预测

岩石力学参数的测井解释方法因其低成本、高精度的特性被广泛应用于工程实际中，但其计算过程涉及到横波速度(V_s)、孔隙度(POR)等岩石物性参数^[17-18]。这类物性参数通常根据经验公式进行估算，然而，在不同区块、不同地层中，需要根据实际地质情况对经验公式进行修正，使得测井解释方法的适用性较差。鉴于此，学者们试图借助机器学习方法预测横波速度、孔隙度等物性参数，将预测结果带入岩石力学参数计算公式当中，实现岩石力学参数的间接预测，从而简化计算过程，优化计算效率。

表 1 和表 2 总结了机器学习在横波速度及孔隙度预测中的应用现状。由表 1 可以看出：绝大多数研究均采用纵波速度(V_p)、自然伽马(GR)、岩性密度(DEN)、井径(CAL)等测井数据作为机器学习模型的输入特征，其中，纵波速度是预测横波速度的关键参数。部分研究以地震数据预测横波速度，如金衍等^[29]和吴超等^[30]考虑到地震属性与测井数据之间的潜在联系，利用神经网络建立了两者之间的非线性映射关系，通过地震记录数据得到了声波时差(AC)和岩性密度测井曲线，进一步建立了地层弹性参数和强度参数的获取方法。随着机器学习技术的不断进步以及地质工程

表 1 机器学习在横波速度预测中的应用

Table 1 Application of machine learning in shear wave velocity prediction

年份	方法	输入参数	样本量	模型性能	文献
2017	SVM	V_p 、GR、DEN、CAL 等	11 500 组	MRE=2.81%、 $R^2=0.7435$	[19]
2019	LSSVM-COA	V_p 、GR、DEN、CAL 等	3674 组	RMSE=0.0373、 $R^2=0.954$	[20]
2020	LSTM	V_p 、GR、DEN、CNL 等	-	$R^2=0.989$ 、MRE<5%	[21]
2020	GRU	V_p 、DEN、GR、POR 等	90 000 组	MRE=3.92%、 $R^2=0.9686$	[22]
2021	CNN	V_p 、DEN、GR、CNL 等	1201 组	RMSE=8.024、 $R^2=0.962$	[23]
2022	MLP	V_p 、GR、DEN、CAL 等	8293 组	$R^2=0.9898$ 、AARE=1.87%	[24]
2022	DFNN	V_p 、DEN、CNL、POR 等	40 000 组	MRE=5.11%	[25]
2022	CNN-LSTM	V_p 、GR、POR、DEN	5 口井	RMSE=0.1843、MAPE=2.1113%	[26]
2023	GA-DNN	V_p 、DEN、GR、POR	11 935 组	RMSE=116.78、MAPE=2.27%	[27]
2023	BiLSTM	V_p 、GR、POR、DEN 等	42 665 组	RMSE=111.4、 $R^2=0.94$	[28]

的不断深入, 所使用的方法从常规的机器学习方法逐步转变为计算能力更强、预测精度更高的深度学习方法, 其中能够捕捉数据序列特性的循环神经网络方法受到学者的一致青睐。

由表 2 可以看出: 根据输入参数类型, 按照测井数据、录井数据和地震数据进行排序, 不难发现, 随机森林(RF)、支持向量机(SVM)和神经网络是孔隙度预测中应用较多的机器学习算法, 基于纵波时差(DTC)、补偿中子(CNL)等测井数据预测孔隙度的研究较多, 钻压(WOB)、扭矩(T)、钻速(ROP)、立管压力(SPP)等录井数据和波阻抗(PI)、纵横波速比(V_p/V_s)等地震数据的使用较少。整体上看, 使用测井数据和地震数据预测孔隙度所得的误差低于录井数据, 但现有方法预测的准确率普遍较低。

在通过机器学习算法预测得到横波速度、孔隙度

等参数的结果后, 结合其他测井数据, 带入岩石力学参数计算模型当中, 即可计算得到各岩石力学参数结果。该方法简化了中间参数的计算过程, 有效提升了岩石力学参数的计算效率, 但其准确性较为依赖机器学习模型对于中间参数的预测精度。现有研究大多使用某一类型数据作为输入特征进行预测, 未考虑不同类型数据之间的潜在相关性。进行多源数据融合, 可以有效整合不同数据源的数据优势, 提升数据集质量, 从而优化模型预测精度和泛化性能。

1.2 直接预测

为了进一步简化岩石力学参数的计算过程, 国内外学者尝试使用机器学习算法直接预测各岩石力学参数。表 3 总结了机器学习直接预测岩石力学参数的部分相关研究现状。

表 2 机器学习在孔隙度预测中的应用

Table 2 Application of machine learning in porosity prediction

方法	数据类型	输入参数	样本量	模型性能	文献
PCA-SEN		GR、CNL、DEN、DTC	7050 组	MSE=0.000 18	[31]
CNN-BiLSTM		GR、CNL、DEN、DTC	3 口井	RMSE=0.1939、MAE=0.1332	[32]
BiLSTM	测井数据	GR、CNL、DEN、DTC	2 口井	RMSE=0.1277、MAE=0.0979	[33]
GS-PSO-XGBoost		GR、CNL、DEN、DTC 等	39 895 组	RMSE=0.5237、MAPE=0.0202	[34]
RF		GR、CNL、DEN、DTC 等	373 组	$R^2=0.9002$	[35]
PTDNN		GR、CNL、DEN、DTC 等	7533 组	MSE=0.0016、 $R^2=0.8146$	[36]
ELM	录井数据	MET、ETH、PRP、NBU 等	57 组	$R^2=0.929$ 、RMSE=3.325	[37]
XGBoost		WOB、 T 、SPP、ROP 等	9 口井	$R^2=0.935$ 、RMSE=0.848	[38]
RF	地震数据	V_p/V_s 、 PI 、FPA、AL 等	1823 组	RMSE=0.0228、 $R^2=0.9196$	[39]
LightGBM		V_p/V_s 、 PI	7 口井	RMSE=0.0229、 $R^2=0.6140$	[40]

表 3 机器学习在岩石力学参数预测中的应用

Table 3 Application of machine learning in rock mechanical parameters prediction

年份	方法	输入参数	数据量	输出参数	模型性能	文献
1995	ANN	V_p 、 V_s 、 ρ_b	9 组	σ_c 、 μ	$MRE=4.602\%(\sigma_c)$ 、 $5.232\%(\mu)$	[41]
2012	ANN	CFC、Void、Mica、CF	44 组	σ_c	$R^2=0.7663$ 、RMSE=6.23	[42]
2012	ANN	POR、 ρ_b 、 S_w	—	σ_c	$R^2=0.987$ 61	[43]
2019	ANN	ρ_b 、DTC、DTS	120 组	μ	MAPE=2.1%、 $R^2=0.96$	[44]
2022	LSTM	σ_c 、 σ_t 、 σ_3	244 组	C 、 φ	$C: R^2=0.9842$ 、RMSE=1.295 $\varphi: R^2=0.8543$ 、RMSE=1.857	[45]
2022	RF	V_p 、SD、GS、 ρ_b	154 组	σ_c	MAPE=6.2%、RMSE=15	[46]
2023	RBF	WOB、ROP、 T 、 H 等	—	σ_c 、 C 、 φ	RMSE=0.025、MAE=0.018	[47]
2023	PINN	测井数据+矿物组分	210 组	E 、 μ 、 σ_t	$R^2=0.96(E)$ 、 $0.95(\mu)$ 、 $0.95(\sigma_t)$ RMSE=1.64(E)、0.021(μ)、0.44(σ_t)	[48]
2024	GRU	DEN、DTC、DTS	1691 组	μ	RMSE=4.389、 $R^2=0.967$	[49]

岩石力学参数直接预测所使用的输入参数主要包括地震属性、测井数据、录井数据和岩石物性参数，预测对象包括弹性模量(E)、泊松比(μ)、单轴强度(σ_c)、抗张强度(σ_t)、内摩擦角(C)、内聚力(ϕ)等常规岩石力学参数。所使用的机器学习算法中，人工神经网络(ANN)凭借较好的性能以及较强的适用性被广泛应用，其他算法如随机森林和径向基回归模型(RBF)等也表现出较好的预测效果^[46-47]。此外，笔者考虑了不同岩石力学参数之间存在的潜在相关性，使用多任务学习神经网络的方法进行 E 、 μ 、 σ_t 、 σ_c 、 ϕ 等5种岩石力学参数的同时预测。随着技术的发展，部分学者尝试使用深度学习算法进行岩石力学参数的直接预测。虽然这些机器学习方法显示出了较好的预测性能，但其训练过程依赖于数据集的数量和质量，而数据的收集过程往往是费时、费力、高成本的。鉴于此，有学者提出了一种融合物理约束与数据驱动的物理约束神经网络模型(PINN)^[48]，通过将物理模型融入损失函数中，使模型能够通过少量的数据预测得到岩石的力学参数。

使用机器学习算法可以直接通过输入参数得到所需的岩石力学参数结果，省略了中间的计算过程，提升了计算效率，但其精度受训练数据集质量的影响较大。而PINN模型能够通过物理模型和领域知识对预测结果进行约束，使预测结果符合领域知识的要求，从而提升模型预测精度，并且降低对于数据集质量的要求。

2 地层孔隙压力智能预测技术进展

地层孔隙压力是地质分析、钻井设计的基础参数，在石油工程领域，地层孔隙压力的准确预测对井身结构设计、井壁稳定分析、钻井方案设计等具有重要作用^[50-53]。综合分析前人研究，将机器学习在地层孔隙压力预测中的应用分为钻前预测、随钻监测和钻后评估3大类型。

2.1 钻前预测

钻前孔隙压力预测对于钻井施工设计、钻井液密度选取、井身结构设计等具有十分重要的意义。目前单井地层孔隙压力主要通过地震资料获取，其准确性在很大程度上取决于地震数据的分辨率和精度。

吴超等^[54]通过神经网络建立已钻井段地震属性与声波速度之间的非线性关系模型，用以预测未钻地层的声波速度，结合岩石力学模型以及有效应力原理得到了未钻井段的地层孔隙压力。为了实现钻前孔隙压

力的直接预测，Haris等^[55]和Andrian等^[56]以波阻抗、纵横波速比、密度等通过叠前地震资料反演得到的弹性参数作为输入特征参数，分别建立了基于概率神经网络(PNN)和人工神经网络的钻前孔隙压力预测模型，预测精度均在95%以上。为了提升模型的泛化能力，Zhang等^[57]开发了一种自适应物理信息深度学习模型(CGP-NN)，如图2所示，通过选择合适的物理模型对孔隙压力进行约束，使预测结果更加符合工程实际，并通过塔里木盆地某复杂地层验证了模型精度和泛化能力，其预测精度可达94%。

然而，随着钻探深度的不断增加，地震资料的不连续和低分辨率增加了钻前孔隙压力预测的难度。已钻邻井具有完整的测录井数据，可以获得连续、准确的地层孔隙压力剖面，建立邻井测录井数据与地层孔隙压力之间的机理模型，并将其作为约束条件加入钻前孔隙压力预测机器学习模型中，可以使预测结果更加符合领域知识约束，从而增加预测精度。

2.2 随钻监测

在钻井过程中，实时监测地层孔隙压力有助于及时调整钻井策略，降低钻井风险。目前常用的地层孔隙压力随钻监测方法主要包括dc指数法、张氏模型、随钻地层测试、岩石强度法等^[58-62]，这些方法通过构建随钻测量资料与地层孔隙压力之间的关系，实现地层孔隙压力的随钻监测。但随钻数据的获取成本较高，且这些方法受岩性和水力参数的影响较大，计算过程复杂、计算精度有限。因此，亟需一种高效精准的地层压力实时预测方法。鉴于此，学者们使用机器学习方法进行地层孔隙压力实时监测，从而满足地层孔隙压力高效、准确预测的需求。

根据dc指数法可知，地层孔隙压力与钻速、转速、钻压、钻井液密度等录井数据密切相关。因此可以借助机器学习算法建立起录井数据与地层孔隙压力之间的映射关系，从而通过地面录井数据实现孔隙压力的实时预测^[63]。其中，ANN由于其出色的非线性拟合能力得到了广泛的应用^[64]，其他方法还包括SVM、RF等^[65-66]。冗杂的输入参数可能导致模型出现过拟合现象，为了避免该问题，Rashidi等^[67]使用钻进效率(DE)和机械比能(MSE)作为输入参数，降低了数据维度，避免了过拟合现象，并且在测试集上的决定系数达到了0.9964。然而，这些研究并未考虑钻井数据的时序性，并且仅使用钻井数据作为输入特征，忽略了其他数据的作用。宋先知等^[68-69]结合长短期记忆神经网络(LSTM)和误差反馈传播神经网络(BPNN)，基于

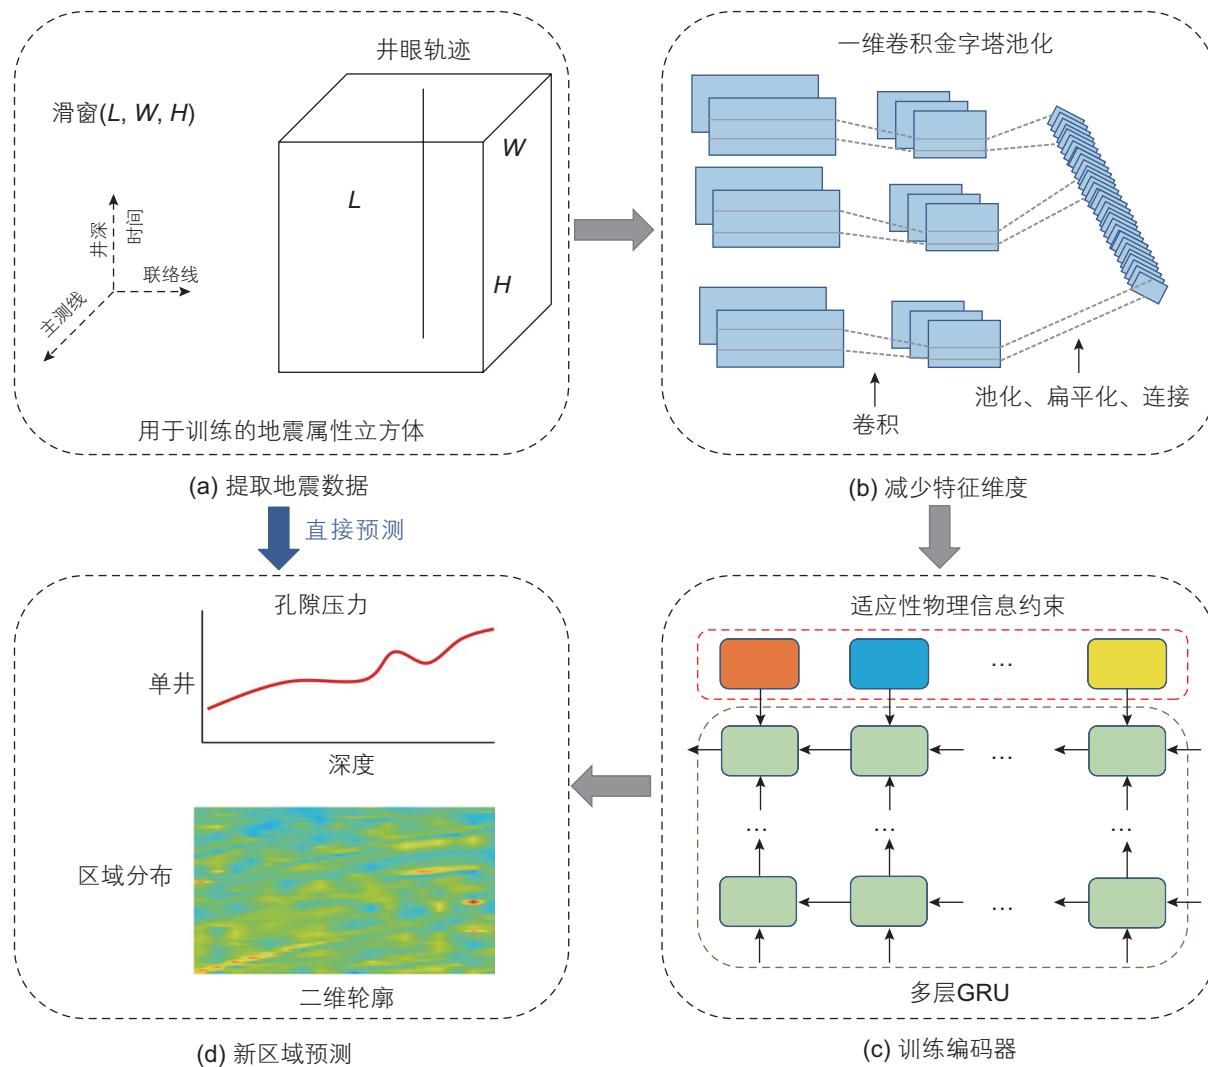
图 2 CGP-NN 模型框架^[57]

Fig. 2 Framework of the CGP-NN model

钻井数据以及邻井测井资料进行了地层孔隙压力的实时预测，预测与实测点的相对误差仅为 1.23%。

但这些研究大多是进行地质力学参数的随钻监测，无法实现钻头下方地质力学参数预测。借助地震资料和邻井数据，实现钻头下方地层压力的准确预测，可以校正钻前预测结果，指导钻井施工设计，确保钻井安全。

2.3 钻后评估

地层孔隙压力的钻后评估方法主要包括等效深度法^[70]、Eaton 法^[71-72]和有效应力法^[73]，这些方法需要计算的中间参数较多，计算过程复杂、计算精度有限。为了解决上述问题，国内外学者使用机器学习进行地层孔隙压力的钻后评估。表 4 统计了部分研究现状。

由表 4 可知，由于测井参数具有数据连续、易于

获取、精度高等优点，因此学者大多使用测井数据作为模型的输入特征进行钻后地层孔隙压力的预测。为了选择最适合用于预测钻后地层孔隙压力的机器学习模型，学者对比了包括 SVM、RF、决策树(DT)、极端梯度提升树(XGBoost)、多层感知器(MLP)等多个机器学习模型，其中，基于决策树的各个集成模型(XGBoost、RF)表现出了较好的预测性能^[79,81]，此外，神经网络模型也能达到较高的预测精度^[76]。

随着研究地层的深度不断增加，地质条件变得更加复杂，单一的测井数据无法使模型学习到全面的地质信息，导致模型可能不能实现准确的孔隙压力预测。因此，学者试图通过融合测井、钻井、地震等多源数据，使模型获得更加全面和综合的地质信息，更好的掌握地层孔隙压力在不同地质层面上的变化规律，提升模型的预测精度和鲁棒性^[82-83]。

3 地应力智能预测技术进展

地应力预测对于石油勘探、煤炭开采、地质资源开发和地下空间建设至关重要。在石油工程领域，地应力大小直接影响维持井筒稳定所需的临界井筒压力和等效泥浆密度。目前获取地应力的方法可分为直接测量和间接预测两种方式。直接测量包括应力应变恢复法、声发射法、水压致裂法等^[84]，间接预测主要通过测井、地震数据，结合地球物理模型进行地应力的预测^[85~86]。然而，直接测量法成本较高，且得到的地应力数据不连续；间接预测法受人为主观影响较大，且精度和泛化能力较差。鉴于此，国内外学者使用机器学习进行地应力的预测，综合分析前人研究，将机

器学习在地应力预测中的应用分为一维地应力和三维地应力场预测。

3.1 一维地应力

地应力机器学习预测是一种正在兴起的方法，主要依靠机器学习强大的非线性拟合能力，建立测井、录井、地震以及各种实验数据等与地应力之间的关系，其具有自主学习、预测精准、快速方便等优点，在地应力预测方面具有独特优势。

表 5 总结了部分机器学习在一维地应力预测中的应用现状。其中神经网络模型是这一领域中应用最广泛的机器学习方法，其他常用的方法还包括RF、SVM等。最常用的输入参数为测井数据(DTC、DTS、GR、DEN等)，其他输入参数如岩石力学参数(E 、 v)

表 4 机器学习在地层孔隙压力钻后评估中的应用

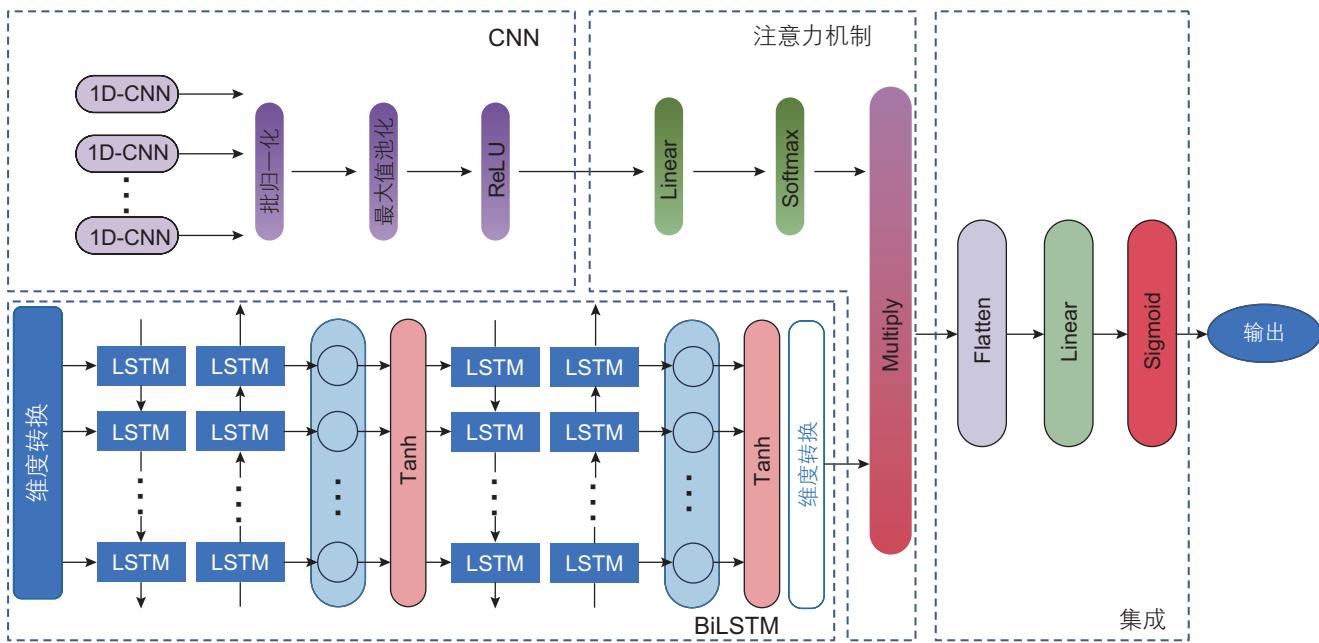
Table 4 Application of machine learning to post-drilling evaluation of formation pore pressure

年份	方法	输入参数	数据规模	模型性能	文献
2019	BNN	DTC、GR、DEN、POR	375 组	$R^2=0.994$	[74]
2021	ELM-PSO	DTC、DEN、CNL	4242 组	RMSE=12.85、 $R^2=0.9929$	[75]
2022	MLP	DTC、DEN、POR、 V_{sh}	2900 组	$R^2=0.9981$ 、RMSE=0.007 09	[76]
2022	DT	DTC、DEN、DTC、DTS 等	25 935 组	RMSE=5.2	[77]
2022	LSTM	DTC、GR、CAL、 H 等	1335 组	MAE=0.035、RMSE=0.052、 $R^2=0.586$	[78]
2023	LightGBM	DTC、GR、DEN、CNL 等	2424 组	RMSE=0.078、MAPE=3.419%、 $R^2=0.647$	[79]
2023	DT	DTC、GR、DEN、 H 等	6 口井	$R^2=0.98$ 、RMSE=0.61	[80]
2023	CatBoost	DTC、GR、DEN、CNL 等	24 983 组	RMSE=0.071、MAPE=3.053%、 $R^2=0.708$	[81]
2023	LSSVM-PSO	录井+测井参数	4 口井	$R^2=0.97$ 、MAPE=1.3%	[82]
2023	CNN-LSTM	钻井参数+测井参数+地震参数	1522 组	MRE=2.70%	[83]

表 5 机器学习在一维地应力预测中的应用

Table 5 Application of machine learning to the prediction of one-dimensional in-situ stress

年份	方法	输入参数	数据规模	输出参数	模型性能	文献
2015	BPNN	H 、DEN、 E 、 μ 等	11 组	σ_h 、 σ_h	MAPE≤5%	[87]
2017	COA-ANN	DTC、DEN、CNL、GR	8600 组	σ_h	$R^2=0.9997$ 、RMSE=0.0557	[88]
2018	PR-GA-ANN	C_{13} 、 C_{24} 、 E 、 μ	1024 组	σ_h 、 σ_h	$R^2>0.99$	[89]
2020	ANN	DTC、DTS、DEN、GR 等	250 组	σ_h	RMSE=1.42、 $R^2=0.93$	[90]
2020	Extra Trees	C_{13} 、 C_{24} 、 E 、 μ 等	100 000 组	σ_h 、 σ_h	$R^2=0.9954$ 、MSE=0.0831	[91]
2021	ANFIS	GR、DEN、DTC、DTS	2307 组	σ_h 、 σ_h	$R^2=0.96$ 、MAPE=0.1%	[92]
2022	SVM	CAL、CNL、GR、DEN	34 组	σ_h	$R^2=0.94$ 、MRE=0.07	[93]
2022	CNN-BiLSTM-Attention	DTC、DTS、GR、DEN 等	2 口井	σ_h	σ_h : RMSE=0.40、 $R^2=0.98$	[94~95]
				σ_h	σ_h : RMSE=0.48、 $R^2=0.97$	
2022	BiLSTM	DTC、GR、DEN、CAL 等	2 口井	σ_h 、 σ_h	σ_h : RMSE=0.06、MAPE=0.48% σ_h : RMSE=0.06、MAPE=0.50%	[96]
				σ_h 、 σ_h	RMSE=0.6658、 $R^2=0.9960$	
2023	XGBoost	ϕ 、 C 、 E 、 μ 等	662 组	σ_h 、 σ_h	RMSE=0.6658、 $R^2=0.9960$	[97]

图 3 CNN-BiLSTM-Attention 混合神经网络结构^[96]Fig. 3 CNN-BiLSTM-Attention hybrid neural network structure^[96]

和井眼变形参数(r)也用于训练机器学习模型。可以看出,预测地应力通常需要使用多个输入特征,这些特征可能是多模态的,并且包含不同类型或尺度的信息。神经网络模型虽然可以处理多尺度、多模态数据,并对其进行有效的整合,但其易受局部极小值的影响,存在一定的局限性。通过使用优化算法对模型的参数进行优化,可以在一定程度上提高模型的性能。Jamshidian 等^[88]从 4 种优化算法中优选出布谷鸟算法(COA)对 ANN 模型进行优化,其预测结果的 R^2 由 0.9312 提升至 0.9997, RMSE 由 0.7488 降低至 0.0557; Han 等^[89]使用遗传算法对 ANN 模型进行了优化,模型预测结果的回归系数均大于 0.99。

此外,由于在某些复杂非均质地层中,不同测井数据之间存在较强的非线性关系,使得传统的机器学习模型难以准确预测地应力。为了解决该问题, Ma 等^[94-95]提出了一种集成了卷积神经网络(CNN)、双向长短记忆神经网络(BiLSTM)和注意力机制(Attention)的混合神经网络模型(图 3)用于地应力预测。该模型利用 CNN 中的卷积层,从测井数据中提取局部特征,捕捉地应力的阶跃变化,利用 BiLSTM 的选择性保留或遗忘相关特征信息,防止梯度消失或梯度爆炸的发生,利用注意力机制从 CNN 和 BiLSTM 中提取关键特征,提高了地应力的预测精度。该模型对于垂向应力、最大水平地应力(σ_h)和最小水平地应力(σ_b)预测结果的 MAPE 分别为 0.49%、0.44% 和 0.44%。该模型解决了传统模型在特殊底层或复杂情况下难以

准确预测地应力的难题,但其需要对多个模型进行参数调整和选择,需要具备丰富的专业知识和经验来确定最优的参数设置和模型组合。

3.2 三维地应力场

由于深部地层横向上的非均质性和变异性,一维地应力剖面并不能反映地应力横向差异特征,而三维地应力场的预测可以更好地反映横向地应力分布特征。目前三维地应力场的预测主要依靠地震预测和数值模拟两种方法,地震预测依靠叠合反演、曲率属性、岩石物理模型等对地震层速度、波阻抗、反射率等地震参数进行处理,实现区域三维地应力场的预测^[98]; 数值模型大多以实测和测井解释地应力数据为基础,同时考虑地形地貌、地质构造、地层岩性等主要特征,利用有限元或离散元对预先构造的三维地质模型进行反演计算,获得三维地应力场预测结果^[99]。然而,地震预测需要对叠前预处理、地震标定、地震子波提取、叠前联合反演等关键环节进行精准质控,其过程繁琐、耗时长、成本高; 数值模拟则高度依赖地质模型、岩性参数及已知地应力的精度,在复杂的地质条件下,简单的边界和初始条件往往很难实现地应力场的准确预测。因此,学者试图使用机器学习进行三维地应力场的预测。

现有研究大多是利用机器学习进行地应力场的反演预测。通过有限元模型建立区块的三维地质模型,生成机器学习模型的训练数据,再根据机器学习模型

建立起边界条件与应力值之间的非线性映射关系，根据实测应力值得到边界条件，进一步带入有限元模型中求解得到应力场^[100-101]。在地应力场的反演预测中，应用最为广泛的为ANN模型^[102]，其他模型还包括BP、SVM等机器学习方法^[103-104]。

为了进一步简化三维地应力场的计算过程，学者尝试进行三维地应力场的直接预测。孔广亚等^[105]以测点的空间位置坐标和岩体质量RQD值作为输入特征，进行三维地应力场的预测，预测结果与实测点的相对误差一般在15%之内，大部分集中在10%左右，满足地下工程的实际需要；袁多等^[106]使用BP神经网络，利用地震数据空间速度信息与岩石力学方法建立了地应力三维数据体，运用模拟退火算法得到了地应力解向量，并通过现场实测数据验证了预测方法的可行性。但是，这些研究均采用纯数据驱动进行预测，对于地质条件复杂的情况，单纯的数据驱动往往会产生不符合物理规律的预测^[107]。基于此，笔者^[108]提出了一种如图4所示的基于物理约束的分布式神经网络三维地应力预测方法，以测井数据和三维空间坐标为输入，在神经网络中引入地应力物理约束条件，对神经网络模型进行数据和物理的双约束，进而通过三维空间坐标实现三维地应力场的预测，在测试集预测得到的垂向地应力、最大水平地应力、最小水平地应力和孔隙压力的最大相对误差分别为0.63%、7.59%、7.16%和3.21%。

4 地质力学参数智能预测技术发展方向

目前国内外学者已经开展了大量使用机器学习预测岩石力学参数、地层孔隙压力、地应力等地质力学参数的相关研究。但现有研究大多存在以下问题：①仅针对地层孔隙压力进行了钻前、随钻、钻后的预测研究，对于岩石力学参数和地应力大多都基于钻后得到的数据进行预测；②大多数研究只考虑了某一类型数据进行地质力学参数预测，少部分研究使用了多源数据进行研究但只进行了简单的数据融合；③现有关于随钻预测的研究大多基于地面钻井数据进行地质力学参数的随钻监测，难以实现钻头前方参数的预测；④除地应力场的预测外，其余地质力学参数大多只针对单井进行预测，较少见到针对整个区块的三维预测。

针对上述问题，笔者提出了一种如图5所示的地质力学参数智能预测框架，其具体流程如下：①根据研究区块的地震数据和已有的测井解释结果建立区块的三维地质力学参数模型；②根据已钻井的地震、测井、录井、室内岩石力学试验、现场测试等数据，进行数据处理和多源数据融合，构建多源数据集；③将多源数据集带入三维地质模型，生成岩石力学参数、孔隙压力、地应力等数据，以多源数据集中的参数作为输入特征，生成的地质力学参数作为标签，建立机器学习模型的训练数据集；④建立基于数据驱动+物理约束的机器学习模型，使用训练数据集对模型进行

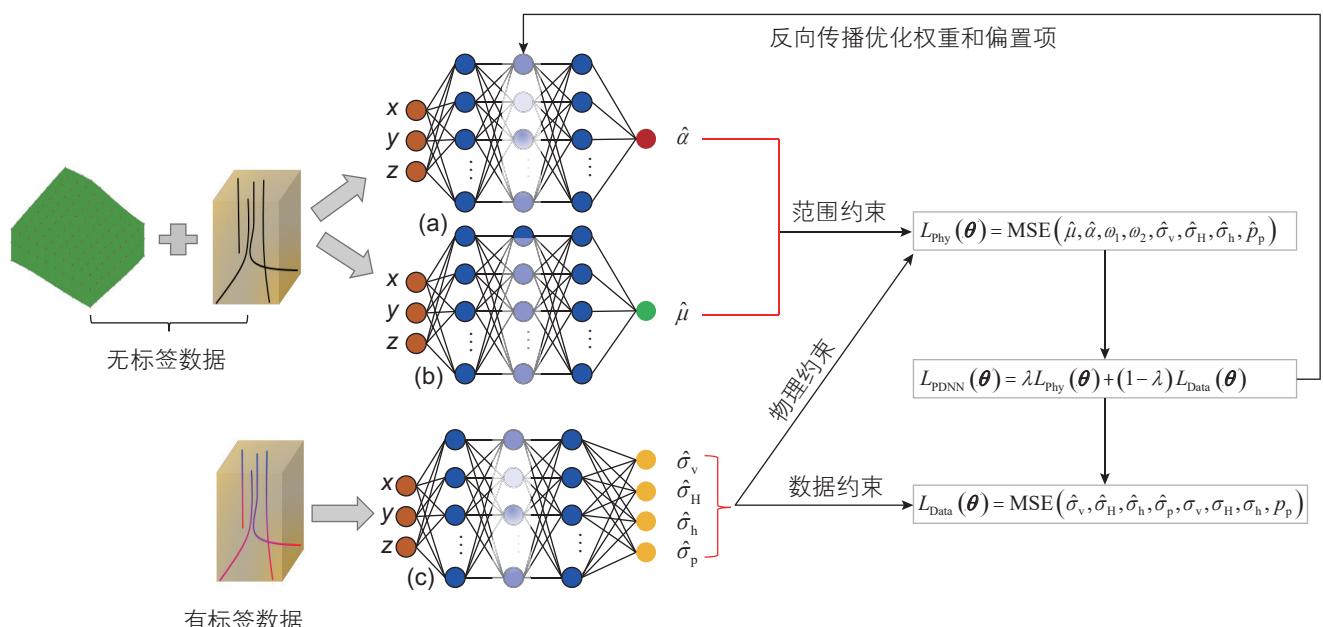


图4 物理约束的分布式神经网络(PDNN)框架^[108]

Fig. 4 Framework of the physics-constrained distributed neural network (PDNN) model^[108]

训练，并根据该区块正钻井的数据进行模型的动态更新；⑤利用训练好的机器学习模型，根据未钻井的地震数据和邻井数据进行地质力学参数的钻前预测，从而利用预测结果知道钻井施工设计；⑥利用目标井的随钻数据进行地质力学参数的随钻监测，并使用预测结果校正钻前预测结果，从而实现对钻头下方地质力学参数的预测；⑦钻完井后，利用测井和录井数据进行地质力学参数的钻后评估，并使用随钻预测结果对钻后评估进行约束。并将钻后的预测结果以及震、测、录等数据加入到多源数据集中，更新数据集，加强三维地质模型的精度。

为了实现上述地质力学参数的智能预测，需要对以下三方面进行深入研究：

(1) 数据类型转换

与地质力学参数相关的特征参数除了常规测井数据、地震资料、录井数据等结构化数据外，还包括图像数据(如成像测井、声发射试验数据等)、传感器数据等非结构化数据，以及日志文件(如钻井日志、井史日志等)等半结构化数据。将非结构化数据转换为结构化数据可以更容易地实现数据整合，降低数据集

的复杂度，确保数据的一致性和可比性，从而更容易被计算机系统理解和处理。常见的转换方法包括：自然语言处理、正则表达式、数据建模、机器学习等。

(2) 多源数据融合

融合多个数据来源的多源数据集可以为模型提供更全面的信息、增加模型的泛化能力、减少过拟合的风险、提高模型的鲁棒性。而现有地质力学参数预测研究较少见到多源数据集的应用，少数研究也只是把几种数据简单的合并在一起。因此，需要进一步开展多源数据融合的研究。根据融合程度的不同，通常将多源数据融合方法分为数据级融合、特征级融合以及决策级融合，如图 6 所示^[109-110]。表 6 总结了不同融合方法的优缺点以及常用的融合算法。因此，在进行多源数据融合时，应充分考虑数据特征，选择不同的融合方法，保证数据的精度从而提升模型性能。

(3) 机器学习模型

随着石油地质工程向深层、超深层挺进，所面临的地质环境变得越发复杂。地质力学参数受高温、高压影响，与其对应的特征参数之间的映射关系变得更加复杂，传统的机器学习算法模型可能无法很好的捕

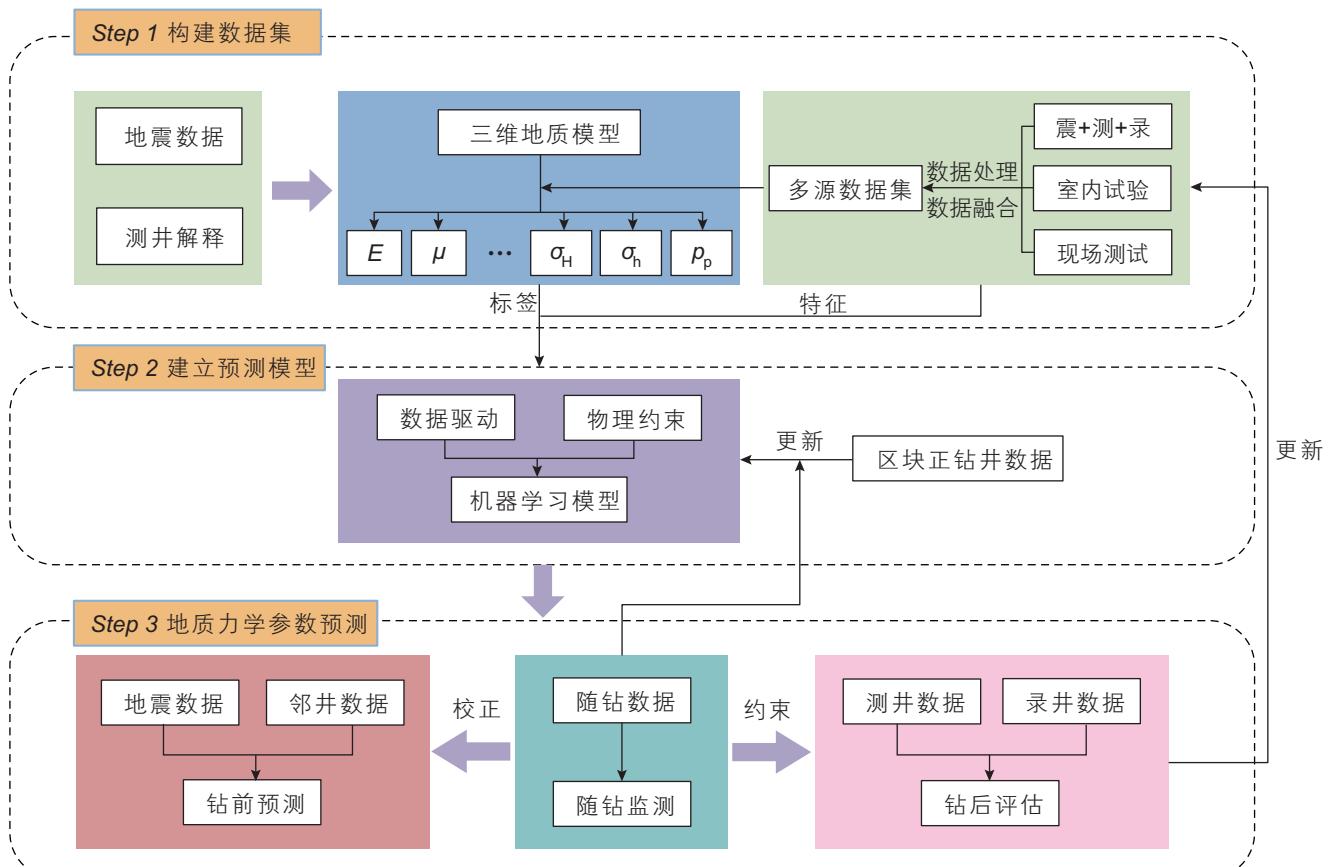


图 5 地质力学参数智能预测框架

Fig. 5 Framework for intelligent prediction of geomechanical parameters

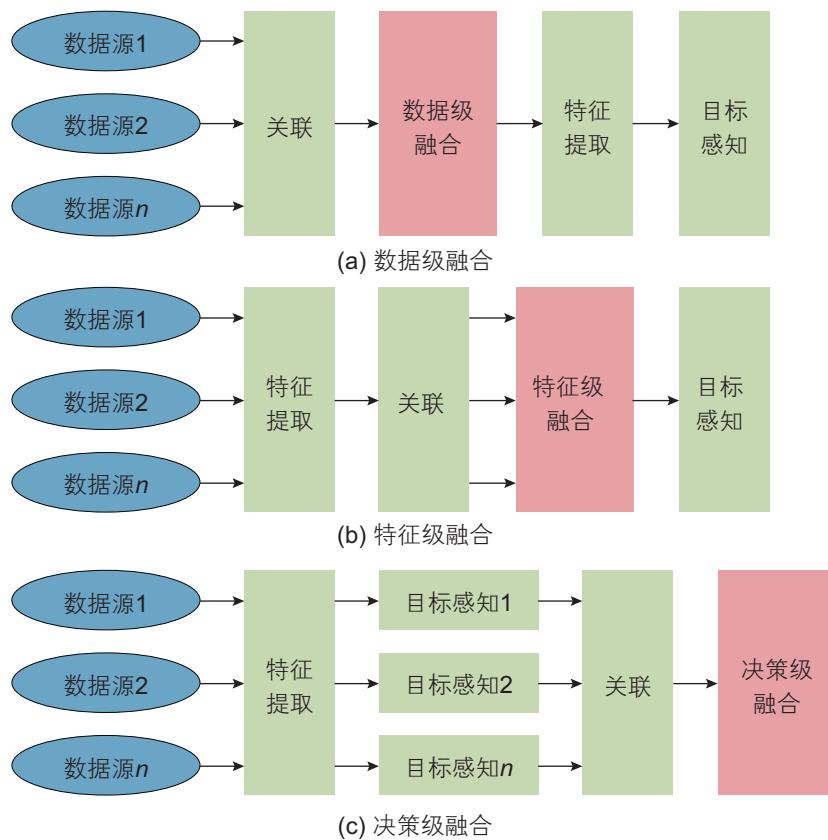


图 6 多源数据融合方法示意图

Fig. 6 Diagram of multi-source data fusion method

表 6 多源数据融合方法及特点^[111-114]Table 6 Methods and characteristics of multi-source data fusion^[111-114]

融合类型	优点	缺点	融合算法
数据级融合	保留原始信息，信息损失较少	只能对单个或相同类型的数据信息进行处理，计算量较大	加权平均法 卡尔曼滤波法 统计统计法
特征级融合	对原始数据进行了提取和处理，降低了计算量	信息损失会带来数据精度的降低	模糊推理法 产生式规则法 神经网络法
决策级融合	可对不同类型数据进行融合，计算量小，鲁棒性强	数据信息损失较大，导致精度较低	贝叶斯推理法 D-S 证据理论法

捉复杂环境下地质力学参数与特征参数之间的非线性映射关系。因此，需要加强对于混合模型的研究，通过集成多个模型的优点，弥补单一模型的局限性，提高预测的准确性和稳定性。此外，在机器学习算法中加入优化算法来调节模型的超参数，可以进一步提升模型精度和计算效率。

复杂的地质环境可能导致纯数据驱动进行地质力学参数预测的结果可能不符合物理规律，并且纯数据驱动对训练样本的数量和质量都有很高的要求。此外，

目前大多数机器学习算法直接将输入参数与输出参数联系起来，其内部运行过程无法知悉，不利于了解数据之间的关联规律。通过在机器学习算法中加入相关领域知识和物理规律，可以更清晰地理解模型预测结果的依据，并且能够使模型预测结果遵循已知的物理约束，显著提高模型的可解释性和准确性。其次，利用物理规律对模型进行约束，能够有效地限制模型的搜索空间，降低模型过拟合的风险，更有效地利用物理规律对模型进行指导和约束，减少对大量标注数据

的依赖，提升模型的泛化能力和计算效率。

5 结论

(1) 地质力学参数是描述岩石和地层在受力作用下力学性质的重要参数，在岩石稳定性评价、地质灾害风险评估、钻井施工设计、井壁稳定性分析等方面发挥着至关重要的作用。然而，传统的基于物理模型计算地质力学参数的方法往往过程繁琐、误差大、适用性差，难以满足工程实际需求。随着石油行业向数字化转型，机器学习技术在石油工程领域的应用日益成熟，地质力学参数的智能预测已成为必然发展趋势。

(2) 地震、测井、录井等多种工程地质参数已广泛应用于地质力学参数的机器学习预测中。然而，现有研究大多基于某一类型数据进行预测。由于单一类型数据的局限性，可能使机器学习模型难以准确捕捉地质力学参数的变化规律。此外，随着石油工程向深部地层进发，复杂的地质环境对于机器学习模型的计算能力提出了更为严苛的要求，常规的机器学习模型可能无法满足工程实际的需求。为进一步提升地质力学参数机器学习预测模型的准确性和鲁棒性，降低训练数据对模型性能的影响，需重点开展多源数据融合以及数据+物理双驱动的机器学习模型研究。

(3) 机器学习技术在石油地质工程中的应用飞速发展，但距离现场需求仍存在较大差距，尤其是深部、复杂地层的地质力学参数预测还需进一步研究。随着现场地震、测井、录井等工具的不断更新，相关理论的日益成熟，模型算法的不断进步，地质力学参数的智能化预测技术定会迎来跨越式发展，为我国深层、非常规等油气勘探开发工作奠定坚实基础。

符号说明

AARE——绝对平均相对误差

AC——声波时差

AL——弧长

ANN——人工神经网络

ANFIS——自适应模糊神经网络

BiLSTM——双向长短期记忆神经网络

BPNN——误差反馈传播神经网络

BNN——贝叶斯神经网络

C——内聚力

C_{13} ——井眼长轴

C_{24} ——井眼短轴

CAL——井径

CatBoost——类别增强树

CF——铁质胶结物

CFC——含铁方解石胶结物

CNL——补偿中子

CNN——卷积神经网络

CGP-NN——自适应物理信息深度学习神经网络

COA——布谷鸟优化算法

DE——钻进效率

DEN——密度测井

DFNN——深度前馈神经网络

DNN——深度神经网络

DTC——纵波时差

DTS——横波时差

E——弹性模量

ELM——极限学习机

ETH——能量半衰期

FPA——首峰振幅

G——体积模量

GA——遗传算法

GR——自然伽马

GRU——门控神经网络

GS——晶体粒度

K——体积模量

LightGBM——轻量级梯度提升树

LSSVM——最小二乘支持向量回归机

LSTM——长短期记忆神经网络

MET——甲烷

Mica——云母

MLP——多层感知器

MSE——机械比能

NBU——正丁烷

PCA——主成分分析

PDNN——物理约束分布式神经网络

PI——波阻抗

PINN——物理约束神经网络

PNN——概率神经网络

POR——孔隙度

PR——概率重组

PRP——丙烷

PSO——粒子群优化算法

RF——随机森林

ROP——钻速

RQD——岩石质量指标

PTDNN——迁移深度神经网络

SD	晶体尺寸	R^2	决定系数
SEN	选择性集成学习	$RMSE$	均方根误差
SPP	立管压力	S_w	含水饱和度
SVM	支持向量机	V_p	纵波速度
T	扭矩	V_s	横波速度
$Void$	井眼空隙	V_p/V_s	纵横波速比
WOB	钻压	V_{sh}	泥质含量
$XGBoost$	极端梯度提升树	ρ_b	岩石密度
H	井深	μ	泊松比
MAE	绝对平均误差	σ_c	抗压强度
$MAPE$	绝对评价百分比误差	σ_t	抗拉强度
MRE	平均相对误差	φ	内摩擦角
MSE	均方误差	σ_h	最大水平主应力
r	井眼半径	σ_b	最小水平主应力

参考文献

- [1] 桑树勋, 郑司建, 王建国, 等. 岩石力学地层新方法在深部煤层气勘探开发“甜点”预测中的应用[J]. 石油学报, 2023, 44(11): 1840–1853. [SANG S X, ZHENG S J, WANG J G, et al. Application of new rock mechanical stratigraphy in sweet spot prediction for deep coalbed methane exploration and development[J]. Acta Petrolei Sinica, 2023, 44(11): 1840–1853.]
- [2] 蔡文军, 邓金根, 冯永存, 等. 泥页岩地层区域三维地质力学建模与应用[J]. 钻采工艺, 2023, 46(1): 8–14. [CAI W J, DENG J G, FENG Y C, et al. Three-dimensional geomechanical modeling and application in shale formation[J]. Drilling & Production Technology, 2023, 46(1): 8–14.]
- [3] 范翔宇, 蒙承, 张千贵, 等. 超深地层井壁失稳理论与控制技术研究进展[J]. 天然气工业, 2024, 44(1): 159–176. [FAN X Y, MENG C, ZHANG Q G, et al. Research progress in the evaluation theory and control technology of wellbore instability in ultra-deep strata[J]. Natural Gas Industry, 2024, 44(1): 159–176.]
- [4] 刘建华, 吴超, 陶兴华. 钻井岩石力学参数三维建模方法及其现场应用[J]. 钻采工艺, 2020, 43(1): 13–16. [LIU J H, WU C, TAO X H. Three-dimensional modeling method for drilling rock mechanics and its field application[J]. Drilling & Production Technology, 2020, 43(1): 13–16.]
- [5] 龚斌, 王虹雅, 王红娜, 等. 基于大数据分析算法的深部煤层气地质—工程一体化智能决策技术[J]. 石油学报, 2023, 44(11): 1949–1958. [GONG B, WANG H Y, WANG H N, et al. Integrated intelligent decision-making technology for deep coalbed methane geology and engineering based on big data analysis algorithms[J]. Acta Petrolei Sinica, 2023, 44(11): 1949–1958.]
- [6] 郭旭升, 胡宗全, 李双建, 等. 深层—超深层天然气勘探研究进展与展望[J]. 石油科学通报, 2023, 8(4): 461–474. [GUO X S, HU Z Q, LI S J, et al. Progress and prospect of natural gas exploration and research in deep and ultra-deep strata[J]. Petroleum Science Bulletin, 2023, 8(4): 461–474.]
- [7] 杨磊, 熊昶, 刘文超, 等. 基于改进ResNet深度残差网络的岩屑岩性识别研究[J]. 长江大学学报(自然科学版), 2023, 20(2): 11–19. [YANG L, XIONG C, LIU W C, et al. Lithology identification of cuttings based on improved ResNet deep residual network[J]. Journal of Yangtze University (Natural Science Edition), 2023, 20(2): 11–19.]
- [8] 郭建春, 任文希, 曾凡辉, 等. 非常规油气井压裂参数智能优化研究进展与发展展望[J]. 石油钻探技术, 2023, 51(5): 1–7. [GUO J C, REN W X, ZENG F H, et al. Unconventional oil and gas well fracturing parameter intelligent optimization: research progress and future development prospects[J]. Petroleum Drilling Techniques, 2023, 51(5): 1–7.]
- [9] 马天寿, 张东洋, 陈颖杰, 等. 基于神经网络模型的水平井破裂压力预测方法[J]. 中南大学学报(自然科学版), 2024, 55(1): 330–345. [MA T S, ZHANG D Y, CHEN Y J, et al. Fracture pressure prediction method of horizontal well based on neural network model[J]. Journal of Central South University (Science and Technology), 2024, 55(1): 330–345.]
- [10] 马天寿, 张东洋, 杨赟, 等. 基于机器学习模型的斜井坍塌压力预测方法[J]. 天然气工业, 2023, 43(9): 119–131. [MA T S, ZHANG D Y, YANG Y, et al. Machine learning model based collapse pressure prediction method for inclined wells[J]. Natural Gas Industry, 2023, 43(9): 119–131.]
- [11] 邱艺, 马天寿, 陈颖杰, 等. 泥质粉砂储层欠平衡水平井井壁稳定性演化规律[J]. 中南大学学报(自然科学版), 2023, 54(3),

- 967–983. [QIU Y, MA T S, CHEN Y J, et al. Wellbore stability evolution of underbalanced horizontal well in argillaceous siltstone reservoirs[J]. Journal of Central South University (Science and Technology), 2023, 54(3): 967–983.]
- [12] 程希, 周军, 傅海成, 等. 机器学习算法在地球物理测井中的适用性及应用[J]. 西北地质, 2023, 56(4): 336–348. [CHENG X, ZHOU J, FU H C, et al. Applicability and application of machine learning algorithm in logging interpretation[J]. Northwestern Geology, 2023, 56(4): 336–348.]
- [13] PAN H, DENG S, LI C, et al. Research progress of machine-learning algorithm for formation pore pressure prediction[J]. Petroleum Science and Technology, 2023: 1–19.
- [14] FRANCISCA O O, CHUKWUDALU C E, DELIGHT C M, et al. The application of deep learning in pore pressure prediction and reservoir optimization: A brief review[J]. Asian Journal of Geological Research, 2023, 6(3): 160–171.
- [15] SAZID M, HUSSEIN K, ABUDURMAN K. Rock Stress measurement methods in rock mechanics—A brief overview[J]. World Journal of Engineering and Technology, 2023, 11(2): 252–272.
- [16] KHAKSAR A, TAYLOR P G, FANG Z, et al. Rock strength from core and logs, where we stand and ways to go[C]. SPE Europe featured at EAGE Conference and Exhibition. Amsterdam, 2009. SPE-121972-MS.
- [17] 王建强, 张丽君. 利用横波时差计算孔隙度的方法研究[J]. 石油天然气学报, 2007, 29(6): 92–94. [WANG J Q, ZHANG L J. Method for computing porosity by using shear moveout[J]. Journal of Oil and Gas Technology, 2007, 29(6): 92–94.]
- [18] 归榕, 万永平. 基于常规测井数据计算储层岩石力学参数——以鄂尔多斯盆地上古生界为例[J]. 地质力学学报, 2012, 18(4): 418–424. [GUI R, WAN Y P. Rock mechanics parameter calculation based on conventional logging data: A case study of upper Paleozoic in Ordos Basin[J]. Journal of Geomechanics, 2012, 18(4): 418–424.]
- [19] 倪维军, 李琪, 郭文惠, 等. 基于支持向量机的页岩储层横波速度预测[J]. 西安石油大学学报(自然科学版), 2017, 32(4): 46–49. [NI W J, LI Q, GUO W H, et al. Prediction of shear wave velocity in shale reservoir based on support vector machine[J]. Journal of Xi'an Shiyou University (Natural Science Edition), 2017, 32(4): 46–49.]
- [20] ANEMANGELY M, RAMEZANZADEH A, AMIRI H, et al. Machine learning technique for the prediction of shear wave velocity using petrophysical logs[J]. Journal of Petroleum Science and Engineering, 2019, 174: 306–327.
- [21] ZHANG Y, ZHONG H, WU Z, et al. Improvement of petrophysical workflow for shear wave velocity prediction based on machine learning methods for complex carbonate reservoirs[J]. Journal of Petroleum Science and Engineering, 2020, 192: 107234.
- [22] 孙宇航, 刘洋. 利用GRU神经网络预测横波速度[J]. 石油地球物理勘探, 2020, 55(3): 484–492. [SUN Y H, LIU Y. Prediction shear wave velocity using GRU neural network[J]. Oil Geophysical Prospecting, 2020, 55(3): 484–492.]
- [23] 马乔雨, 张欣, 张春雷, 等. 基于一维卷积神经网络的横波速度预测[J]. 岩性油气藏, 2021, 33(4): 111–120. [MA Q Y, ZHANG X, ZHANG C L, et al. Shear wave velocity prediction based on one-dimensional convolutional neural network[J]. Lithologic Reservoirs, 2021, 33(4): 111–120.]
- [24] EBRAHIMI A, IZADPANAHI A, EBRAHIMI P, et al. Estimation of shear wave velocity in an Iranian oil reservoir using machine learning methods[J]. Journal of Petroleum Science and Engineering, 2022, 209: 109841.
- [25] 王树华, 杨国杰, 穆星. 基于深度前馈神经网络方法的横波速度预测[J]. 油气地质与采收率, 2022, 29(1): 80–89. [WANG S H, YANG G J, MU X. S-wave velocity prediction based on deep feedforward neural network[J]. Petroleum Geology and Recovery Efficiency, 2022, 29(1): 80–89.]
- [26] 王俊, 曹俊兴, 赵爽, 等. 基于深度混合神经网络的横波速度反演预测方法[J]. 中国科学: 地球科学, 2022, 52(6): 1151–1169. [WANG J, CAO J X, ZHAO S, et al. S-wave velocity inversion and prediction using a deep hybrid neural network[J]. Science China Earth Sciences, 2022, 52(6): 1151–1169.]
- [27] 刘涛, 田仁飞, 张伟. 基于遗传算法优化深层神经网络的测井横波速度预测[J]. 物探化探计算技术, 2023, 45(3): 289–297. [LIU T, TIAN R F, ZHANG W. Shear wave velocity prediction based on deep neural network optimized by genetic algorithm[J]. Computing Techniques for Geophysical and Geochemical Exploration, 2023, 45(3): 289–297.]
- [28] 何运康, 李庆春, 刘兴业. 基于注意力机制和双向长短时记忆网络的横波预测方法及应用[J]. 石油物探, 2023, 62(2): 225–235. [HE Y K, LI Q C, LIU X Y. Shear wave velocity prediction based on bidirectional long short-term memory networks with attention mechanism[J]. Geophysical Prospecting for Petroleum, 2023, 62(2): 225–235.]
- [29] 金衍, 陈勉. 利用地震记录钻前预测井壁稳定性研究[J]. 石油学报, 2004, 25(1): 89–92. [JIN Y, CHEN M. Prediction of borehole stability by seismic records[J]. Acta Petrolei Sinica, 2004, 25(1): 89–92.]
- [30] 吴超, 陈勉, 金衍. 基于地震属性技术的井壁稳定随钻预测新方法[J]. 中国石油大学学报(自然科学版), 2007, 31(6): 141–146. [WU C, CHEN M, JIN Y. A new method of prediction borehole stability while drilling based on seismic attribute technology[J]. Journal of China University of Petroleum (Edition of Natural Science), 2007, 31(6): 141–146.]
- [31] 段友祥, 王言飞, 孙岐峰. 选择性集成学习模型在岩性–孔隙度预测中的应用[J]. 科学技术与工程, 2020, 20(3): 1001–1008. [DUAN Y X, WANG Y F, SUN Q F. Application of selective ensemble learning model in lithology-porosity prediction[J]. Science Technology and Engineering, 2020, 20(3): 1001–1008.]

- [32] 王俊, 曹俊兴, 周欣. 基于深度双向循环神经网络的储层孔隙度预测[J]. 地球物理学进展, 2022, 37(1): 267–274. [WANG J, CAO J X, ZHOU X. Reservoir porosity prediction based on deep bidirectional recurrent neural network[J]. Progress in Geophysics, 2022, 37(1): 267–274.]
- [33] 刘俊, 曹俊兴, 丁蔚楠, 等. 基于双向长短期记忆神经网络的储层孔隙度预测方法研究[J]. 地球物理学进展, 2022, 37(5): 1993–2000. [LIU J, CAO J X, DING W N, et al. Research on reservoir porosity prediction method based on bidirectional longshort-term memory neural network[J]. Progress in Geophysics, 2022, 37(5): 1993–2000.]
- [34] 潘少伟, 郑泽晨, 雷建永, 等. 基于混合优化XGBoost算法的砂岩储层孔隙度预测[J]. 计算机应用与软件, 2023, 40(5): 103–109. [PAN S W, ZHENG Z C, LEI J Y, et al. Porosity prediction of sandstone reservoirs based on hybrid optimization XGBoost algorithm[J]. Computer Applications and Software, 2023, 40(5): 103–109.]
- [35] 崔俊峰, 杨金路, 王民, 等. 基于随机森林算法的泥页岩孔隙度预测[J]. 油气地质与采收率, 2023, 30(6): 13–21. [CUI J F, YANG J L, WANG M, et al. Shale porosity prediction based on random forest algorithm[J]. Petroleum Geology and Recovery Efficiency, 2023, 30(6): 13–21.]
- [36] 汪敏, 杨桃, 唐洪明, 等. 迁移深度神经网络的页岩总孔隙度预测[J]. 西南石油大学学报(自然科学版), 2023, 45(6): 69–79. [WANG M, YANG T, TANG H M, et al. Prediction for total porosity of shale based on transfer deep neural network[J]. Journal of Southwest Petroleum University (Science & Technology Edition), 2023, 45(6): 69–79.]
- [37] AMEUR-ZAIMECHE O, KECHICHE R, HEDDAM S, et al. Real-time porosity prediction using gas-while-drilling data and machine learning with reservoir associated gas: Case study for Hassi Messaoud field, Algeria[J]. Marine and Petroleum Geology, 2022, 140: 105631.
- [38] OULADMANSOUR A, AMEUR-ZAIMECHE O, KECHICHE R, et al. Integrating drilling parameters and machine learning tools to improve real-time porosity prediction of multi-zone reservoirs. Case study: Rhoud Chegga oilfield, Algeria[J]. Geoenergy Science and Engineering, 2023, 223: 211511.
- [39] ZOU C, ZHAO L, XU M, et al. Porosity prediction with uncertainty quantification from multiple seismic attributes using random forest[J]. Journal of Geophysical Research: Solid Earth, 2021, 126(7): e2021JB021826.
- [40] ZOU C, ZHAO L, HONG F, et al. A comparison of machine learning methods to predict porosity in carbonate reservoirs from seismic-derived elastic properties[J]. Geophysics, 2023, 88(2): B101–B120.
- [41] 刘向君, 罗平亚. 利用神经网络技术建立岩石强度预测模型[J]. 西南石油学院学报, 1995, 17(3): 66–70. [LIU X J, LUO P Y. Rock strength prediction model established by nerve network technique[J]. Journal of Southwestern Petroleum Institute, 1995, 17(3): 66–70.]
- [42] MANOUCHEHRIAN A, SHARIFZADEH M, MOGHADAM R H. Application of artificial neural networks and multivariate statistics to estimate UCS using textural characteristics[J]. International Journal of Mining Science and Technology, 2012, 22(2): 229–236.
- [43] RABBANI E, SHARIF F, KOOLIVAND S M, et al. Application of neural network technique for prediction of uniaxial compressive strength using reservoir formation properties[J]. International Journal of Rock Mechanics and Mining sciences, 2012, 56: 100–111.
- [44] TARIQ Z, MAHMOUD M, ABDULRAHEEM A. Core log integration: a hybrid intelligent data-driven solution to improve elastic parameter prediction[J]. Neural Computing and Applications, 2019, 31: 8561–8581.
- [45] MAHMOODZADEH A, MOHAMMADI M, GHAFOOR S S, et al. Machine learning techniques to predict rock strength parameters[J]. Rock Mechanics and Rock Engineering, 2022, 55(3): 1721–1741.
- [46] WEI M, MENG W, DAI F, et al. Application of machine learning in predicting the rate-dependent compressive strength of rocks[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2022, 14(5): 1356–1365.
- [47] WEI M, QIU D, YUE T, et al. New method prediction of rock mechanics parameters in drilling process based on machine learning[J]. Petroleum Science and Technology, 2023: 1–24.
- [48] 李玉伟, 李子健, 邵力飞, 等. 基于物理信息约束的页岩油储层可压性评价新方法[J]. 煤田地质与勘探, 2023, 51(10): 37–51. [LI Y W, LI Z J, SHAO L F, et al. A new physics-informed method for the fracability evaluation of shale oil reservoirs[J]. Coal Geology & Exploration, 2023, 51(10): 37–51.]
- [49] ALAKBARI F S, MOHYALDINN M E, AYOUB M A, et al. A gated recurrent unit model to predict Poisson's ratio using deep learning[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2024, 16(1): 123–135.
- [50] 马天寿, 曹刚, 彭念, 等. 各向异性地层中随钻地层测试压力响应数值模拟[J]. 长江大学学报(自然科学版), 2024, 21(1), 66–78. [MA T S, CAO G, PENG N, et al. Numerical simulation on pressure response of formation testing while drilling in anisotropic formations[J]. Journal of Yangtze University (Natural Science Edition), 2024, 21(1), 66–78.]
- [51] PENG N, MA T, XU H, et al. Finite element simulation of formation testing while drilling accounting for thermal-hydro-mechanical coupling[J]. Geoenergy Science and Engineering, 2023, 228, 211983.
- [52] DUTTA N C. Geopressure prediction using seismic data: Current status and the road ahead[J]. Geophysics, 2002, 67(6): 2012–2041.
- [53] ZHANG J. Pore pressure prediction from well logs: Methods, modifications, and new approaches[J]. Earth-Science Reviews, 2011, 108(1–2): 50–63.

- [54] 吴超, 陈勉, 金衍. 基于地震属性分析的地层孔隙压力钻前预测模型[J]. 石油天然气学报, 2006, 28(5): 66–69. [WU C, CHEN M, JIN Y. Model used for pre-drilling prediction of formation pore pressure based on seismic attribute[J]. Journal of Oil and Gas Technology, 2006, 28(5): 66–69.]
- [55] HARIS A, SITORUS R J, RIYANTO A. Pore pressure prediction using probabilistic neural network: case study of South Sumatra Basin[C]//IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2017, 62(1): 012021.
- [56] ANDRIAN D, ROSID M S, SEPTYANDY M R. Pore pressure prediction using ANFIS method on well and seismic data field "Ayah" [C]//IOP Conference Series: Materials Science and Engineering. IOP Publishing, 2020, 854(1): 012041.
- [57] ZHANG X, LU Y H, JIN Y, et al. An adaptive physics-informed deep learning method for pore pressure prediction using seismic data[J]. Petroleum Science, 2023.
- [58] JORDEN J R, SHIRLEY O J. Application of drilling performance data to overpressure detection[J]. Journal of Petroleum Technology, 1966, 18(11): 1387–1394.
- [59] ZHANG J, YIN S. Real-time pore pressure detection: indicators and improved methods[J]. Geofluids, 2017, 2017: 3179617.
- [60] MA T, PENG N, CHEN P, et al. Study and verification of a physical simulation system for formation pressure testing while drilling[J]. Geofluids, 2018, 2018: 1–18.
- [61] 杨进. 地层孔隙压力评估新方法研究及其应用[D]. 北京: 中国石油大学(北京), 1996. [YANG J. Research and application of a new method for evaluating formation pore pressure[D]. Beijing: China University of Petroleum(Beijing), 1996.]
- [62] 杨进. 岩石抗钻强度与地层压力关系模型及其应用[J]. 石油大学学报(自然科学版), 2001, 25(2): 1–2. [YANG J. Correlation model of rock strength and formation pore pressure and application of the model[J]. Journal of China University of Petroleum(Edition of Natural Sciences), 2001, 25(2): 1–2.]
- [63] AHMED A, ELKATATNY S, ALI A, et al. New model for pore pressure prediction while drilling using artificial neural networks[J]. Arabian Journal for Science and Engineering, 2019, 44(6): 6079–6088.
- [64] REILLY M, TAYLOR G, DE JESUS O, et al. Estimating real-time pore pressure at the bit via machine learning[C]//SPE/AAPG/SEG Unconventional Resources Technology Conference, Denver, 2023: D031S063R003.
- [65] ABDELAAL A, ELKATATNY S, ABDULRAHEEM A. Data-driven modeling approach for pore pressure gradient prediction while drilling from drilling parameters[J]. ACS omega, 2021, 6(21): 13807–13816.
- [66] BRUNA T S B S, CLAUDIO R C R, CRISTIAN M C M, et al. Neural network model to predict pore pressure and wellbore stability from LWD log and drilling parameter[C]//ARMA US Rock Mechanics/Geomechanics Symposium, Atlanta, 2023: ARMA–2023–0916.
- [67] RASHIDI M, ASADI A. An artificial intelligence approach in estimation of formation pore pressure by critical drilling data[C]//ARMA US Rock Mechanics/Geomechanics Symposium. Seattle, 2018: ARMA–18–1098.
- [68] 宋先知, 姚学皓, 李根生, 等. 基于LSTM-BP神经网络的地层孔隙压力计算方法[J]. 石油科学通报, 2022, 7(1): 12–23. [SONG X Z, YAO X Z, LI G S, et al. A novel method to calculate formation pressure based on the LSTM-BP neural network[J]. Petroleum Science Bulletin, 2022, 7(1): 12–23.]
- [69] YAO X, SONG X, HAN L, et al. Real-time prediction of formation pore pressure using hybrid LSTM-BP model[C]//ARMA US Rock Mechanics/Geomechanics Symposium, Atlanta, 2023: ARMA–2023–0130.
- [70] HOTTMANN C E, JOHNSON R K. Estimation of formation pressures from log-derived shale properties[J]. Journal of Petroleum Technology, 1965, 17(6): 717–722.
- [71] EATON B A. The effect of overburden stress on geopressure prediction from well logs[J]. Journal of Petroleum Technology, 1972, 24(8): 929–934.
- [72] EATON B A. The equation for geopressure prediction from well logs[C]//SPE Annual Technical Conference and Exhibition. SPE, 1975: SPE–5544–MS.
- [73] TERZAGHI K, PECK R B, MESRI G. Soil mechanics in engineering practice[M]. John wiley & sons, 1996.
- [74] KARMAKAR M, MAITI S. Short term memory efficient pore pressure prediction via Bayesian neural networks at Bering Sea slope of IODP expedition 323[J]. Measurement, 2019, 135: 852–868.
- [75] FARSI M, MOHAMADIAN N, GHORBANI H, et al. Predicting formation pore-pressure from well-log data with hybrid machine-learning optimization algorithms[J]. Natural Resources Research, 2021, 30: 3455–3481.
- [76] HUANG H, LI J, YANG H, et al. Research on prediction methods of formation pore pressure based on machine learning[J]. Energy Science & Engineering, 2022, 10(6): 1886–1901.
- [77] RADWAN A E, WOOD D A, RADWAN A A. Machine learning and data-driven prediction of pore pressure from geophysical logs: A case study for the Mangahewa gas field, New Zealand[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2022, 14(6): 1799–1809.
- [78] 罗发强, 刘景涛, 陈修平, 等. 基于BP和LSTM神经网络的顺北油田5号断裂带地层孔隙压力智能预测方法[J]. 石油钻采工艺, 2022, 44(4): 506–514. [LUO F Q, LIU J T, CHEN X P, et al. Intelligent method for predicting formation pore pressure in No. 5 fault

- zone in Shunbei oilfield based on BP and LSTM neural network[J]. Oil Drilling & Production Technology, 2022, 44(4): 506–514.]
- [79] LI H, TAN Q, DENG J, et al. A comprehensive prediction method for pore pressure in abnormally high-pressure blocks based on machine learning[J]. Processes, 2023, 11(9): 2603.
- [80] ZHAO X, CHEN X, LAN Z, et al. Pore pressure prediction assisted by machine learning models combined with interpretations: A case study of an HTHP gas field, Yinggehai Basin[J]. Geoenergy Science and Engineering, 2023, 229: 212114.
- [81] 李华洋, 谭强, 朱施杰, 等. 基于CatBoost算法的孔隙压力预测方法及其在井壁稳定分析中的应用[J]. 中国安全生产科学技术, 2023, 19(2): 136–142. [LI H Y, TAN Q, ZHU S J, et al. Prediction method of pore pressure based on CatBoost algorithm and its application in wellbore stability analysis[J]. Journal of Safety Science and Technology, 2023, 19(2): 136–142.]
- [82] DELAVAR M R, RAMEZANZADEH A. Pore pressure prediction by empirical and machine learning methods using conventional and drilling logs in carbonate rocks[J]. Rock Mechanics and Rock Engineering, 2023, 56(1): 535–564.
- [83] 许玉强, 何保伦, 王龚舒, 等. 深度学习与Eaton法联合驱动的地层孔隙压力预测方法[J]. 中国石油大学学报(自然科学版), 2023, 47(6): 50–59. [XU Y Q, HE B L, WANG G S, et al. A novel prediction method of formation pore pressure driven by deep learning and Eaton method[J]. Journal of China University of Petroleum (Edition of Natural Science), 2023, 47(6): 50–59.]
- [84] 蔡美峰. 岩石力学与工程[M]. 北京: 科学出版社, 2002. [CAI M F. Rock mechanics and engineering[M]. Beijing: Science Press, 2002.]
- [85] 李志明, 张金珠. 地应力与油气勘探开发[M]. 北京: 石油工业出版社, 1997. [LI Z M, ZHANG J Z. In-situ stress and petroleum exploration & development[M]. Beijing: Petroleum Industry Press, 1997.]
- [86] 印兴耀, 马妮, 马正乾, 等. 地应力预测技术的研究现状与进展[J]. 石油物探, 2018, 57(4): 488–504. [YIN X Y, MA N, MA Z Q, et al. Review of in-situ stress prediction technology[J]. Geophysical Prospecting for Petroleum, 2018, 57(4): 488–504.]
- [87] 陈晨, 朱希安, 王占刚. 神经网络在地应力预测中的应用研究[J]. 山东煤炭科技, 2015(11): 156–158. [CHEN C, ZHU X A, WANG Z G. Study on application of neural network in in-situ stress prediction[J]. Shandong Coal Science and Technology, 2015(11): 156–158.]
- [88] JAMSHIDIAN M, MANSOURI Z M, HADIAN M, et al. Estimation of minimum horizontal stress, geomechanical modeling and hybrid neural network based on conventional well logging data—a case study[J]. Geosystem Engineering, 2017, 20(2): 88–103.
- [89] HAN H X, YIN S. Determination of in-situ stress and geomechanical properties from borehole deformation[J]. Energies, 2018, 11(1): 131.
- [90] ABBAS A K, ALSABA M, AL DUSAISHI M F, et al. Determination of minimum horizontal stress magnitudes from conventional well logging data using artificial neural network[C]//ARMA US Rock Mechanics/Geomechanics Symposium. ARMA, 2020: ARMA-2020-1495.
- [91] ALTAMMAR M J, ALRUWAILI K M. Integrating Monte Carlo simulation, machine learning and physics-based solutions to estimate in-situ stresses[C]//ARMA/DGS/SEG International Geomechanics Symposium. ARMA, 2020: ARMA-IGS-20-049.
- [92] IBRAHIM A F, GOWIDA A, ALI A, et al. Machine learning application to predict in-situ stresses from logging data[J]. Scientific Reports, 2021, 11(1): 23445.
- [93] 冯鹏, 李松, 汤达祯, 等. 支持向量机在煤层地应力预测中的应用[J]. 现代地质, 2022, 36(5): 1333–1340. [FENG P, LI S, TANG D Z, et al. Application of support vector machine in prediction of coal seam stress[J]. Geoscience, 2022, 36(5): 1333–1340.]
- [94] MA T, XIANG G. In-situ stresses prediction by using a CNN-BiLSTM-Attention hybrid neural network[C]//ARMA/DGS/SEG International Geomechanics Symposium. ARMA, 2021: ARMA-IGS-21-021.
- [95] MA T, XIANG G, SHI Y, et al. Horizontal in situ stresses prediction using a CNN-BiLSTM-attention hybrid neural network[J]. Geomechanics and Geophysics for Geo-Energy and Geo-Resources, 2022, 8(5): 152.
- [96] 马天寿, 向国富, 石榆帆, 等. 基于双向长短期记忆神经网络的水平地应力预测方法[J]. 石油科学通报, 2022, 7(4): 487–504. [MA T S, XIANG G F, SHI Y F, et al. Horizontal in-situ prediction method based on the bidirectional long short-term memory neural network[J]. Petroleum Science Bulletin, 2022, 7(4): 487–504.]
- [97] GARAVAND A, HADAVIMOGHADDAM F. In situ stress assessment based on plastic behavior of borehole breakouts and machine learning[J]. International Journal for Numerical and Analytical Methods in Geomechanics, 2023, 47(2): 241–260.
- [98] 朱伯芳. 岩体初始地应力反分析[J]. 水力学报, 1994, 25(10): 30–35. [ZHU B F. Back analysis of initial stresses in rock masses[J]. Journal of Hydraulic Engineering, 1994, 25(10): 30–35.]
- [99] 郭怀志, 马启超, 薛玺成, 等. 岩体初始应力场的分析方法[J]. 岩土工程学报, 1983, 5(3): 64–75. [GUO H Z, MA Q C, XUE X C, et al. The analytical method of the initial stress field for rock masses[J]. Chinese Journal of Geotechnical Engineering, 1983, 5(3): 64–75.]
- [100] 蒋中明, 徐卫亚, 邵建富. 基于人工神经网络的初始地应力场三维反分析[J]. 河海大学学报, 2002, 30(3): 52–26. [JIANG Z M, XU W Y, SHAO J F. ANN-based 3-D back analysis of initial stress in rock masses[J]. Journal of Hohai University, 2002, 30(3): 52–56.]
- [101] 裴启涛, 李海波, 刘亚群, 等. 复杂地质条件下坝区初始地应力场二次反演分析[J]. 岩石力学与工程学报, 2014, 33(S1): 2779–2785. [PEI Q T, LI H B, LIU Y Q, et al. Two-stage back analysis of initial geostress field of dam areas under complex geological conditions[J]. Chinese Journal of Rock Mechanics and Engineering, 2014, 33(S1): 2779–2785.]

- [102] 易达, 徐明毅, 陈胜宏, 等. 人工神经网络在岩体初始应力场反演中的应用[J]. 岩土力学, 2004, 25(6): 943–946. [YI D, XU M Y, CHEN S H, et al. Application of artificial neural network to back analysis of initial stress field of rock masses[J]. Rock and Soil Mechanics, 2004, 25(6): 943–946.]
- [103] 戴荣, 李仲奎. 三维地应力场BP反分析的改进[J]. 岩石力学与工程学报, 2005, 24(1): 83–88. [DAI R, LI Z K. Modified BP back analysis of 3D in-situ stresses[J]. Chinese Journal of Rock Mechanics and Engineering, 2005, 24(1): 83–88.]
- [104] 赵小龙. 基于支持向量机的深层地应力预测模型[J]. 特种油气藏, 2016, 23(1): 139–141. [ZHAO X L. SVM deep geo-stress prediction model[J]. Special Oil and Gas Reservoirs, 2016, 23(1): 139–141.]
- [105] 孔广亚, 蔡美峰, 白晨光. 基于神经网络的仿真输出方法在地应力场分析中的应用[J]. 黄金, 1996, 17(11): 22–25. [KONG G Y, CAI M F, BAI C G. The application of the simulation output methods based on artificial neural networks in rock stress field analysis[J]. Gold, 1996, 17(11): 22–25.]
- [106] 袁多, 吴超, 卢运虎, 等. 基于智能算法的油田地应力三位预测[J]. 西南石油大学学报(自然科学版), 2021, 43(2): 84–92. [YUAN D, WU C, LU Y H, et al. Three-dimensional prediction of in-situ stress in oil and gas field based on intelligence algorithms[J]. Journal of Southwest Petroleum University (Science & Technology Edition), 2021, 43(2): 84–92.]
- [107] CHEN Y, HUANG D, ZHANG D, et al. 2021. Theory-guided hard constraint projection (HCP): A knowledge-based data-driven scientific machine learning method. Journal of Computational Physics, 445: 110624.
- [108] 向国富, 马天寿, 石榆帆, 等. 基于物理约束的并联式神经网络的三维地应力预测方法: 中国, 202211695646.7[P/OL]. 2022-12-28[2023-06-06]. [XIANG G F, MA T S, SHI Y F, et al. Three-dimensional in-situ stresses prediction method based on parallel neural networks under physical constraints: China, 202211695646.7[P/OL]. 2022-12-28[2023-06-06].]
- [109] 王臻, 刘东, 徐重西, 等. 新型电力系统多源异构数据融合技术研究现状及展望[J]. 中国电力, 2023, 56(4): 1–15. [WANG Z, LIU D, XU C Y, et al. Status quo and prospect of multi-source heterogeneous data fusion technology for new power system[J]. Electric Power, 2023, 56(4): 1–15.]
- [110] 张新曼, 韩九强. 基于矩阵分析的一种不确定性推理的数据融合方法[J]. 西安交通大学学报, 2002, 36(8): 851–854. [ZHANG X M, HAN J Q. Data fusion method of uncertainty reasoning based on matrix analysis[J]. Journal of Xi'an Jiaotong University, 2002, 36(8): 851–854.]
- [111] 杨红军, 张遂安, 秦菁, 等. 基于多源信息融合的煤层气水平井随钻判识技术[J]. 煤炭科学技术, 2016, 44(5): 100–105. [YANG H J, ZHANG S A, QIN J, et al. Identification technology of coalbed methane horizontal well while drilling based on multi-information integration[J]. Coal Science and Technology, 2016, 44(5): 100–105.]
- [112] 郑路佳, 管闯, 李含阳, 等. 基于U型卷积神经网络的微地震信号降噪方法[J]. 东北石油大学学报, 2023, 47(5): 111–124. [ZHENG L J, GUAN C, LI H Y, et al. Microseismic noise suppression method based on U-Net[J]. Journal of Northeast Petroleum University, 2023, 47(5): 111–124.]
- [113] 张好林, 杨传书, 李昌盛, 等. 钻井数字孪生系统设计与研发实践[J]. 石油钻探技术, 2023, 51(3): 58–65. [ZHANG H L, YANG C S, LI C S, et al. Design and research practice of a drilling digital twin system[J]. Petroleum Drilling Techniques, 2023, 51(3): 58–65.]
- [114] 王俊林, 张剑云. 采用Bayes多传感器数据融合方法进行目标识别[J]. 传感器技术, 2005, 24(10): 91–93. [WANG J L, ZHANG J Y. Recognition of target using Bayesian data fusion method[J]. Journal of Transducer Technology, 2005, 24(10): 91–93.]

(编辑 付娟娟)