

8-25-2024

Artificial intelligence logging: Fundamental, principle, technique, and application

CHENG Xi

School of Earth Sciences and Engineering, Xi'an Shiyou University, Xi'an 710065, China; State Key Laboratory of Oil and Gas Reservoir Geology and Exploitation (Southwest Petroleum University), Chengdu 610500, China; Academician and Expert Workstation, Xi'an Shiyou University, Xi'an 710065, China, chengx@xsyu.edu.cn

REN Zhanli

Department of Geology, Northwest University, Xi'an 710069, China, renzhanl@nwu.edu.cn

Follow this and additional works at: <https://cge.researchcommons.org/journal>



Part of the [Earth Sciences Commons](#), [Mining Engineering Commons](#), [Oil, Gas, and Energy Commons](#), and the [Sustainability Commons](#)

Recommended Citation

C R. (2024) "Artificial intelligence logging: Fundamental, principle, technique, and application," *Coal Geology & Exploration*: Vol. 52: Iss. 8, Article 15.

DOI: 10.12363/issn.1001-1986.23.12.0813

Available at: <https://cge.researchcommons.org/journal/vol52/iss8/15>

This Intelligent Geophysical Exploration is brought to you for free and open access by Coal Geology & Exploration. It has been accepted for inclusion in Coal Geology & Exploration by an authorized editor of Coal Geology & Exploration. For more information, please contact 380940179@qq.com.

智能地球物理 专题编者按 近年来,人工智能与地球物理学科的深度融合已成为推动地球科学领域创新发展的重要驱动力。这一跨学科的结合不仅极大地提升了数据处理的智能化水平,实现了成像精度的显著提升和反演过程的优化,还使得实时监测与灾害预警成为可能,极大地拓展了地球科学研究的视野。在复杂多变的地质环境中,人工智能技术的应用有效辅助了勘探方案的设计,显著提高了勘探效率与准确性。此外,在资源开发与利用领域,智能优化算法的应用促进了资源的高效、绿色开采,为实现可持续发展目标提供了强有力的科技支撑。

为了进一步总结与展示人工智能在地球物理领域取得的最新研究成果,推动该领域的持续发展,并为相关学科研究提供新的思路与方法,《煤田地质与勘探》特别邀请北京大学马坚伟教授、西安交通大学陈文超教授担任专题主编,中国矿业大学(北京)赵惊涛教授、哈尔滨工业大学于四伟教授、西安交通大学王晓凯教授、西安研究院王保利研究员和王云宏副研究员担任专题副主编,共同策划了“智能地球物理”专题。本专题紧密围绕人工智能在地球物理数据处理、地质建模、资源预测等核心领域的创新应用与实用成果展开。本期优选了 5 篇代表性的论文,以期为读者呈现该领域的最新进展。期待更多的创新性研究成果能够投寄本刊,共同推动智能地球物理学的发展。



移动阅读

程希,任战利. 人工智能测井: 基础、原理、技术及应用[J]. 煤田地质与勘探, 2024, 52(8): 145-164. doi: 10.12363/issn.1001-1986.23.12.0813

CHENG Xi, REN Zhanli. Artificial intelligence logging: Fundamental, principle, technique, and application[J]. Coal Geology & Exploration, 2024, 52(8): 145-164. doi: 10.12363/issn.1001-1986.23.12.0813

人工智能测井: 基础、原理、技术及应用

程 希^{1,2,3}, 任战利^{4,*}

(1. 西安石油大学 地球科学与工程学院, 陕西 西安 710065; 2. 油气藏地质及开发工程国家重点实验室(西南石油大学), 四川 成都 610500; 3. 西安石油大学 院士专家工作站, 陕西 西安 710065; 4. 西北大学 地质学系, 陕西 西安 710069)

摘要: 【背景】油气勘探开发的智能化已成为油气工业发展趋势与研究热点。人工智能测井(Artificial intelligence logging, AIL) 具有解决非常规油气资源及深地深海等复杂环境勘探开发难题的巨大潜力。然而, AIL 技术发展的驱动模式, 以及技术发展的基础、实现原理、技术组成以及应用场景还没有开展研究。【目的和方法】为构建完善的 AIL 测井体系生态, 充分挖掘并展现 AIL 技术的潜力与价值, 采用文献分析、理论研究、技术分析以及实例验证的方法。首先从多个维度出发, 深入剖析了测井技术与人工智能(Artificial intelligence, AI) 融合发展的关键因素, 并据此定义了 AIL。随后, 系统探讨了 AIL 的基础理论框架、硬件算力需求以及数据物理模型, 并通过知识发现的视角, 详细阐述了测井方法、仪器、岩石物理及解释等环节在 AIL 体系中的功能实现机制。在技术层面, 深入分析了包括测井大数据技术、智能与快速算法、测井知识图谱、数字孪生、智能仪器及测井物联网在内的多项关键技术, 并指出物理模型与智能算法是推动 AIL 技术发展的核心驱动力。根据 AI 算法的原理与特性, 系统梳理了 AIL 在测井方法、仪器、采集作业及解释等方面的关键技术, 并构建了测井知识图谱树状图及其求解流程。【结果和结论】通过实证研究, 验证了 AIL 在致密砂岩岩性识别及测井模拟中的优势, 其精度达到 93.8%, 明显优于传统方法。在测井评价方面, AIL 可同时实现储层和流体的识别, 这充分说明了 AIL 技术的巨大发展潜力与应用优势。基于 AIL 技术的关键节点, 展望了测井技术发展的第五个发展阶段, 即智能测井。研究成果为 AI 在测井领域的深度

收稿日期: 2023-12-08; 接收日期: 2024-08-09

基金项目: 油气藏地质及开发国家重点实验室(西南石油大学)开放基金项目(PLN2022-14); 国家自然科学基金项目(42272152)

第一作者: 程希, 1971 年生, 男, 陕西礼泉人, 副教授, 博士, 从事地球物理测井以及油气大数据挖掘与人工智能方向研究。

E-mail: chengx@xsyu.edu.cn

*通信作者: 任战利, 1961 年生, 男, 陕西西安人, 教授, 博士, 从事盆地构造热演化史与油气成藏评价、地热资源评价与开发方向研究。

E-mail: renzhanl@nwu.edu.cn

融合与广泛应用提供坚实的理论基础与实践指导,对促进人工智能测井技术的推广及发展具有重要意义。

关键词: 人工智能测井; 测井大数据; 机器学习; 地层参数反演; 复杂岩性识别

中图分类号: P631 **文献标志码:** A **文章编号:** 1001-1986(2024)08-0145-20

Artificial intelligence logging: Fundamental, principle, technique, and application

CHENG Xi^{1,2,3}, REN Zhanli^{4,*}

(1. School of Earth Sciences and Engineering, Xi'an Shiyou University, Xi'an 710065, China; 2. State Key Laboratory of Oil and Gas Reservoir Geology and Exploitation (Southwest Petroleum University), Chengdu 610500, China; 3. Academician and Expert Workstation, Xi'an Shiyou University, Xi'an 710065, China; 4. Department of Geology, Northwest University, Xi'an 710069, China)

Abstract: [Background] Intelligent hydrocarbon exploration and exploitation have become a trend and hot research topic in the oil and gas industry. Artificial intelligence logging (AIL) exhibits considerable potential to address challenges in the explore-exploit of unconventional hydrocarbon resources, as well as resources in complex environments in the deep earth and deep ocean. However, the driving mode, fundamental, implementation principle, structure, and application scenarios of AIL remain understudied. [Objective and Methods] To build a comprehensive ecology of the AIL system and thoroughly explore and reveal the potential and value of AIL, this study employed methods like literature analysis, theoretical research, technical analysis, and verification using cases. First, this study delved into the critical factors influencing the integrated development of logging technology and AI from multiple dimensions, defining AIL accordingly. Subsequently, it systematically explored the general theoretical framework, hardware arithmetic requirements, and data and physical models of AI. From the perspective of knowledge discovery, this study detailed the function implementation mechanisms of logging technology, instrumentation, petrophysics, and interpretation in the AIL system. Furthermore, it conducted an in-depth analysis of several critical technologies including log-related big data techniques, intelligent and fast algorithms, log knowledge graph, digital twins, intelligent instrumentation, and the Internet of things (IoT) of logs. Accordingly, this study posited that physical models and intelligent algorithms emerge as the core force driving the development of AIL. Based on the principles and characteristics of AI algorithms, this study systematically organized critical AIL technologies in terms of logging technology, instrumentation, acquisition operations, and interpretation, constructing the dendrogram and solving process of log knowledge graph. [Results and Conclusions] The empirical research reveals that AIL enjoys advantages in terms of the lithologic identification of tight sandstones and logging simulations, accuracies of up to 93.8%, respectively, significantly exceeding those of conventional methods. Regarding log-based assessment, AIL can simultaneously identify reservoirs and fluids, sufficiently proving the considerable development potential and application advantages of AIL. Based on the critical links of AIL, this study envisions the fifth development stage of logging technology, i.e., artificial intelligence logging. The results of this study provide a solid theoretical foundation and practical guidance for the deep integration and extensive application of AI in the field of logging, holding great significance for the promotion and development of AIL technology.

Keywords: artificial intelligence logging(AIL); log-related big data; machine learning (ML); stratigraphic parameter inversion; complex lithologic identification

自 1956 年达特茅斯会议首次提出人工智能(Artificial intelligence, AI)的概念以来,这一领域已经历了从理论萌芽至技术成熟的快速发展,其影响力深远地拓宽了机器模仿人类智慧与行动的能力范畴。从 IBM 在 20 世纪 50 年代推出的首台游戏机,到 60 年代贝叶斯理论在通用公司机器人领域的成功应用,再到 70 年代 PROLOG 等逻辑编程语言的诞生,每一次突破都标志着 AI 技术的稳步前行。进入 80 年代,随着计算并行算法的兴起,以及反向传播、卷积神经网络等前沿算法的出现,AI 的发展更是迎来了前所未有的加速期。尤其是深度学习(Deep learning)理念的提出,以 Y. Lecun 等^[1]在 *Nature* 期刊发表的研究为标志性事件,不仅极

大地推动了计算机视觉与机器翻译领域的创新,还在全球范围内激发了人工智能应用的热潮。

在地球科学领域,AI 技术同样引起了广泛的关注与深入探索。Markus R.^[2]、Karianne J.^[3]等分别在 *Nature* 和 *Science* 期刊上发表的论文,提出了利用数据与机器学习(尤其是深度学习)从地球系统科学及固体地球物理学中挖掘新知识的创新范式。国内学者如陈文超^[4]、马坚伟^[5]等也在积极探索机器学习在地球物理勘探中的应用,通过构建数据模型实现地震信号的稀疏化表征,并利用深度网络进行无监督噪声压制研究,这些成果不仅验证了深度学习在地球物理资料反演中的有效性,也说明在地球物理领域具有广泛应用前景^[6-7]。

在测井这一石油勘探与开发的关键环节中, AI 技术的引入给行业带来巨大的变革。基于大数据的递归神经网络被应用于油气井钻探测井传感器的异常检测, 而测井大数据平台的建立则促进了测井方法、仪器制造、作业流程、岩石物理及综合解释的一体化。中石油梦想云平台等项目的实施, 更是推动了测井解释技术的智能化发展^[8-13]。程希等^[14-15]聚焦于预测测井技术发展趋势及机器学习算法在测井中的适用性, 进一步拓宽了 AI 在测井领域的应用边界。国内外学者在地层岩性分类^[16]、页岩气层分析^[17]、裂缝识别^[18]、动态岩石物理属性分析^[19]、油井生产预测^[20]、声学脆性参数预测^[21]、自动岩相分类^[22]、随钻测井电阻率反演^[23]、天然气产量预测^[24]、多井相关性分析^[25]、碳酸盐岩横波预测^[26]、储层参数与特性评估^[27]、油藏特性预测^[28-31]、渗透率预测^[32]、力学参数预测^[33]、测井质量控制^[34]以及测井解释智能化^[35]等多个方面取得了显著进展, 这些研究成果为人工智能在测井技术中的深入应用奠定了坚实的基础。以分类、预测、聚类和关联分析为目标的各类机器学习算法, 为测井新知识的挖掘、潜在特性的发现以及趋势变化的预测提供了强有力的技术支持。尤其是, 有学者提出了数据学习动力系统, 即物理引导的深度学习的^[36], 这一创新理念为 AI 在测井领域的深度融合与应用开辟了新的路径。

然而, 当前的研究仍面临诸多挑战, 如深入理解复杂的岩石地质工程参数与测井参数之间的内在联系, 以及构建完善的人工智能测井生态系统, 包括其基础理论、技术架构及应用场景等方面的全面研究, 是当前亟待解决的问题。鉴于此, 笔者旨在通过引入人工智能测井的定义与发展阶段, 系统阐述其基础、原理及技术组成, 并深入分析人工智能测井(Artificial intelligence logging, AIL) 在复杂岩性识别、地层真电阻率反演、储层流体识别及测井质量控制等方面的应用优势, 以期为人工智能测井研究的进一步深入提供坚实的理论基础与实践支撑。

1 基础

人工智能测井技术的发展, 离不开测井大数据的积累, 信息技术软硬件的发展, 以机器学习为核心的智能算法的开发与物理模拟技术的进步, 以及油气工业对测井技术的的市场需求等为内外驱动力, 推动了人工智能测井时代的来临。

1.1 定义

人工智能测井(AIL) 利用物理传感器, 并结合物理实验、理论模拟、测井作业以及其他多学科形成的测井大数据与人工智能算法, 在人工智能测井系统中并与专家知识互补, 具有增强的学习能力能在融合多学科的大

函数空间中发现复杂的关系和模式, 从而解决地质-工程参数的测井评价, 具有对作业环境、评价对象的感知、认知以及预测能力, 从而组织并通过智能仪器实施决策作业, 最终使测井仪器适用性更强、数据采集质量更可靠、测井作业更安全、测井解释更精准, 从而能解决勘探开发中复杂问题的技术。

1.2 测井大数据

1.2.1 数据来源及特征

1) 测井大数据的来源

测井仪器数据。测井大数据主要由不同类型的测井仪器采集的多种物理或化学属性测井数据及附属传感器产生的数据组成。按照阶段划分, 包括勘探测井数据和生产测井数据, 从采集方式看又包括电缆测井数据和随钻测井数据。

其他数据。录井岩屑数据, 岩心实验数据, 地质-工程数据, 前后校正和处理解释的测井数据, 永久传感器记录数据等。分布式永久传感器数据获取的是实时监测数据, 如温度传感器、应变传感器和声波传感器等分布式井下传感器采集到的数据具有数据量大、物理属性多样和成像的特性。

2) 测井数据的多尺度性

岩心扫描数据分辨率达到微米到毫米级, 而电声成像测井则为毫米到厘米范围。同样, 不同测井仪器的探测深度范围也明显不同, 例如微电阻率、声波、密度、中子和伽马等测井在厘米级探测范围, 而侧向测井类在 1 m 范围, 感应类测井则在 2 m 范围内, 过套管电阻率测井则达到 1-10 m, 远探测声波可达井旁数十米, 井间电磁测井则可探测的范围从数百米到千米。人工智能测井的数据采集、存储、处理、训练学习流程如图 1 所示。

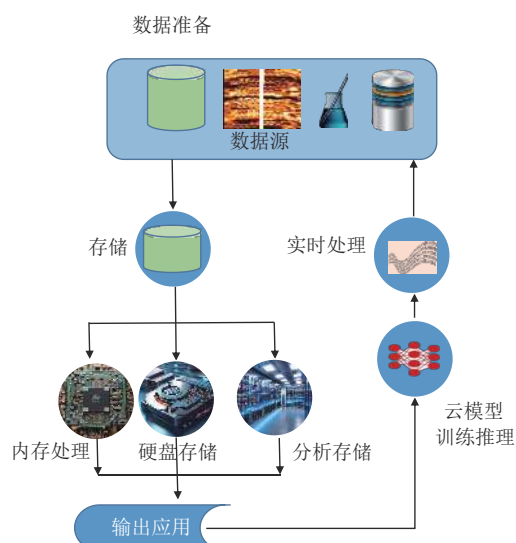


图 1 离散和连续测井数据的处理

Fig.1 Processing of discrete and continuous log data

1.2.2 多学科融合数据

测井数据可以提供关于地层结构、岩石类型、油气储层特性等方面的信息。地质学家在进行地质研究时可以借助测井数据来分析地下岩石的物性和沉积特征,进而推断地层的特征,包括岩石类型、厚度、成分、古地理沉积环境等。测井数据也可以用于确定油气层的位置、评估储量、预测产能等方面。测井数据也可以提供更准确的地质学信息,帮助地质学家更好地理解地下地质条件。

测井与录井的融合能为地质学家和钻井工程师提供重要的地质信息和储层参数,有助于指导油气勘探开发。综合利用测井和录井数据可以提高对地下储层的认识,并为确定最佳的采收策略和生产方案提供支持,并且二者数据可以相互学习与验证。

测井与油藏工程的融合。测井数据可用于识别油藏的油气储层、确定储集层的厚度和孔隙度,评估渗透率、饱和度等参数,从而帮助油藏工程师更好地了解储层的特性并制定钻井和采收计划。测井也可用于监测油藏储层以及井下流体的性质的变化,为油田开发提供实时的数据支持。

测井与地震的融合。当地震勘探确定了油气储集层的可能区域后,测井仪器用于在实际的钻井井眼中验证这些潜在的油气储层。二者融合大大提高了油气勘探与开发的效率和成功率。

测井与钻井的融合。测井技术用来获取有关地下岩石性质、井壁稳定性、孔隙度、渗透率、地层厚度以及地下流体的特性等方面的数据。测井数据不仅为确定钻井目标提供了重要信息,而且还可以帮助工程师们选择适当的钻井技术和工艺,以确保钻井作业的安全和高效进行。测井数据还能够指导井眼轨迹的设计,帮助确定最佳的开发方案。

1.3 测井技术发展阶段

测井技术的发展离不开信息技术的驱动和工程服务市场的需求。下面从测井技术的发展和人工智能测井发展的必然性展开分析。

测井技术的发展分为 5 个阶段:模拟测井、数字测井、数控测井、成像测井和人工智能测井阶段。总之,测井技术的发展受到信息技术发展的推动、油田勘探开发现场的需求和知识发现方式的转变等多方面因素的影响。这 5 个发展阶段,正是满足石油工业对测井数据精度、地层信息精细描述和智能化解释不断追求的结果。

人工智能测井是以基于测井大数据的人工智能技术和油气工业的需求为驱动力,改变了测井知识的发现模式。通过机器学习和深度学习等方法,实现对大规模、

复杂测井数据的分析与解释,以适用测井评价对象的日益复杂化(如非常规油气、深层油气等),而传统的砂泥岩、碎屑岩建立的评价模型难以适应现场需求,迫切需要测井技术与人工智能技术结合形成的人工智能测井技术来破解这些难题。当前,人工智能技术无论在硬件技术、算法设计都有了长足的发展,并且正在测井方法、仪器、采集、岩石物理及解释得到广泛的应用而使人工智能测井发展起来。根据测井技术与 AI 结合的程度,应用场景以及发展趋势,得出人工智能测井发展必须经过的 3 个阶段。(1) 机器学习作为助手的人工智能测井发展的初级阶段,主要协助专家解决测井应用中某些数据处理问题。(2) 以综合测井专家知识与大函数空间的机器学习发现知识为特点的增强学习人工智能测井中级阶段,即深度学习+仪器自动作业的物理模拟与数据模型驱动的人工智能测井中级阶段,这个阶段的特点是机器具有了人类的某些学习和思维能力。(3) 集成智能仪器的环境感知、认知与测井作业、测井数据自动处理解释、智能决策、终身学习为特点的人工智能测井高级阶段。该阶段,智能仪器通过对分布式边缘计算、物联网(Internet of things, IoT)等在测井云上形成的测井历史大数据和实时数据流,应用内置的深度学习和大模型等形成的迁移学习模型和反馈学习,形成决策、执行以及具有终生学习的能力,实现其高级阶段的功能。目前刚进入人工智能测井的中级发展阶段。

2 原理及系统

测井科学知识的发现将越来越多地依赖于对大型数据集的分析和学习。近年来,地球物理科学家对机器学习的应用从对大型数据的分析,转向通过物理模拟和数据驱动的“双模型”对储层的声、电、核性质以及它们之间的耦合过程、非常规储层多重属性的描述,如地质-工程属性或“甜点”属性。作为人工智能测井核心的机器学习提供了从信息、感知到认知的测井知识提取过程,它是通向人工智能测井的重要手段之一。机器学习(Machine learning, ML)方法能够具有在大数据函数空间稳健、快速地实现在测井大数据集中发现新测井模式、结构和关系知识的能力,这极大地超出人脑的算力。ML 可以揭示出以前未被识别的信号或物理过程,并提取关键特征来代表、解释或可视化地球物理测井数据,使用 ML 进行建模或反演可能会产生对测井新知识的理解和发现。

2.1 测井统一场

地球物理测井是利用电、声、核以及核磁等多种激发源在地层中产生相应的波场以及其转换波场,通过专门的探测器,探测波场能量在地层中传播时的特性变化,

进而推断出地层的孔隙性、含油性、渗透性以及各向异性等地质-工程特性。具体而言,电磁测井是探测地层中电场和磁场的变化特性;对于震动波场而言,通过测量出机械波在地层中传播时的速度和幅度变化;对于核测井而言,利用粒子(中子/伽马/电子)的输运和相互作用计算粒子的能量和属性变化,包括能量、方向、位置等;核磁测井则主要体现在射频场作用下,地层中的氢原子因能量吸收而在横向和纵向弛豫时间上的不同,从而得到地层中束缚和自由流体的孔隙性和渗透性。测井在探测区域记录地层中不同种类场波的特性,包括宏观微观的波场变化及各种粒子的特性(弛豫时间,粒子总计数率,表面通量,体积通量和脉冲高度频谱等)。其统一场的变化表达式为:

$$\Psi^{(i)}(r-r') = \frac{\partial}{\partial r} F^{(i)} \left[G^{(i)}(\vartheta, E, E') \times \Phi^{(i)}(E') \right] \quad (1)$$

人工智能测井是用于解决测井知识的学习与新知识的发现,以及智能优化决策等问题。主要应用在测井方法、测井仪器与作业采集、岩石物理,以及测井综合解释与分析问题。人工智能测井从本质上看,是解决测井分类、测井回归或预测、聚类以及相关等问题。人工智能测井(AIL)的误差控制通常是由深度神经网络的正反向反馈来控制学习损失函数的精度。对于多层神经网络来说,测井所解决的测井方法、测井仪器、测井解释以及岩石物理,可以看成人工智能测井的分类、回归以及预测问题,问题答案的输出可以用矢量函数 Y 表示。为了保证损失函数最小化,深度神经网络的任意权值 w ,由下式控制:

$$\frac{\partial}{\partial w} |Y - hw|^2 = \frac{\partial}{\partial w} \sum_k (y_k - a_k)^2 \quad (2)$$

2.2 人工智能测井系统

人工智能算法和测井数值模拟技术为人工智能测井的核心驱动力,将其集成到人工智能测井系统中的模拟模块具有统一的可视化输入输出界面、高效快速的运算方法和相应配套的计算硬件基础层(IAAS)支持,可极大缩短测井理论方法的计算周期,为测井方法研究和仪器设计刻度提供有力的支持。

2.2.1 系统设计思想

按照人工智能测井系统的“四化”要求,即数据内存化、运算并行化、程序数据化、算法尺度化等属性进行设计。数据内存化是通过 AIL 云强大的内存,减少数据在 CPU (Central processing unit)、GPU (Graphic processing unit) 与磁盘数据的交换,消除数据总线传输的瓶颈,实现数据的实时处理与显示。运算并行化是通过多节点对任务的分解合成,降低对系统硬件算力的要求。程序数据化是在 AIL 测井大数据云平台上实现小

程序加载到大数据上,降低数据输入输出延迟。算法尺度化是通过研究各种模拟算法和学习算法建立对小、中、大型数据的自适应匹配,实现测井应用的最优化。随着测井大数据的积累、算法和硬件算力的发展,这些为人工智能测井提供了发展基础。

2.2.2 系统结构

根据 Indigo 的研究发现,用深度神经网络时,GPU 的性能比 CPU 快 250 倍。专用的云图形处理器具有强大硬件加速功能,有助于在云中运行应用程序,特别适合处理大规模人工智能和深度学习任务。人工智能测井包括的基础层、软件层、服务层与应用层,以及各组件关系结构,如图 2 所示。对于分布式大数据存储,以及串行处理的机器学习算法一般不用,如集成 Boosting 算法。对于集成装袋法,随机森林,以及深度神经网络一般用 GPU 加速。在人工智能测井中有数据并行存储和算法并行处理两种模式。对于测井大数据分布式存储时,是不需要 GPU 参与,只是 CPU、服务器内存以及磁盘参与命令的发布和数据的传输。输入数据首先进入 CPU 内存,是顺序进入的,然后进入数据节点服务器分布式磁盘。当使用机器学习算法时,分布式文件系统将数据串行进入服务器 CPU 内存,再通过光纤转换器将数据导入 GPU 内存,相同的代码分成线程,进入显卡网格块,并行进入共享内存,然后并行进入 CUDA (Compute unified device architecture) 多线程核处理,输出结果经过组合计算,得到处理结果输出到 GPU 全局内存进行计算。

人工智能测井的实现离不开测井大数据技术、机器学习与物理模拟算法以及云等核心层的支持。人工智能测井技术平台由基础硬件支持层(IAAS)、平台网络层(PAAS)以及软件支持层(SAAS)以及测井应用层(APPS)等四部分架构组成的。它们之间的各种服务是基于云服务层之间的数据协议。测井云协议用于解决服务的可用性、数据的完整、隐私、安全、保护等问题。不同类型的测井云服务用于提供测井解释处理、测井模拟、智能仪器组合以及远程测井等应用问题。由于测井数据的价值性和保密性,人工智能测井(AIL)为私有云平台,它为测井用户提供专用测井模拟、采集、处理、解释软件,终端用户权限管理,任务请求执行和结果反馈。基础支持平台提供硬件支撑,包括 CPU、GPU、大内存、数据高速交换传输、用于分布式大数据存储处理的高速硬盘。平台包括测井大数据的任务的协调调度、节点资源管理、在线离线学习算法库、结构与非结构数据库。虚拟平台服务层提供专有测井用户接口、用户资源配置管理。软件服务层,用于给专有用户提供测井专业软件的应用商店,用户通过互联网接入。

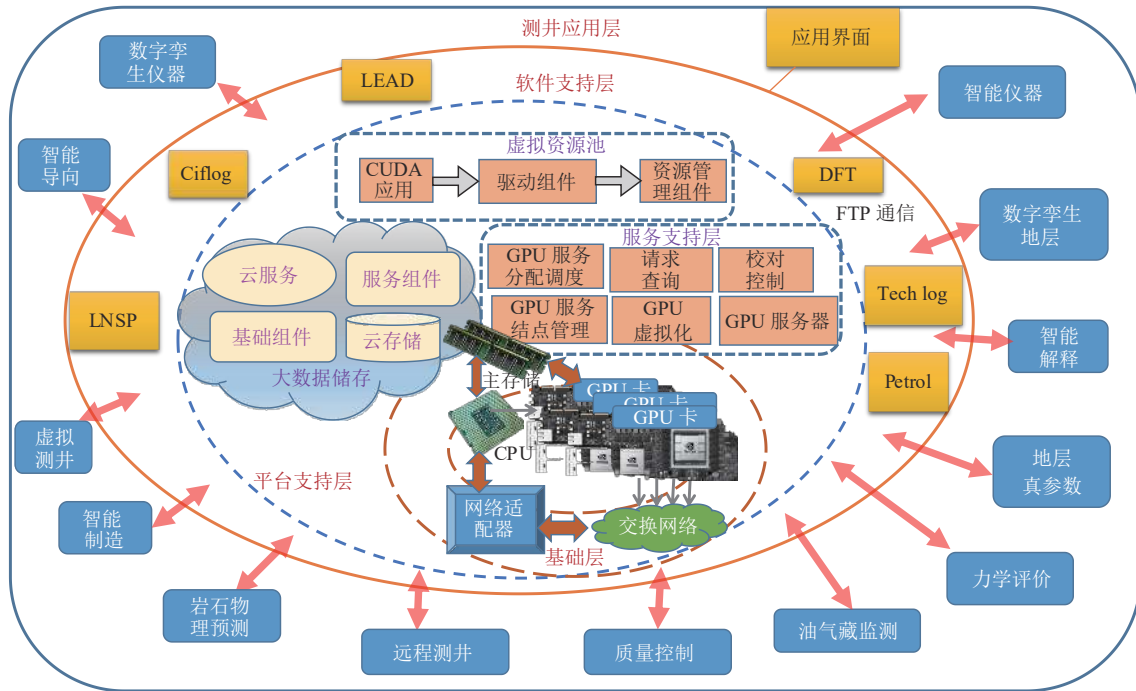


图 2 基于 GPU 的人工智能测井基础层、软件层、服务层与应用层之间结构
 Fig.2 Architecture of GPU-based AIL foundation, software, service, and application layers

2.2.3 硬件实现

在人工智能测井云中,网络接口卡将计算机系统连接到其网络基础设施,并通过以太网或光纤网络等物理连接进行通信。网络接口卡提供计算机与构成网络架构的网络交换机、路由器、集线器等之间的接口。网卡的重要功能是将数据包从网络的一个节点传输到另一个节点的通道,是将输入数据转换成适合主机 CPU 或 GPU 能处理的格式,同时将输出数据转换成与目标网络兼容的格式。在测井云中,编解码器是指在通过网络提供服务的不同阶段用于编码和解码数字信息的算法。在集群配置中通过多台服务器存储大量数据时,也可以使用编解码器来减少冗余,提高存储空间的管理效率。在测井云环境中需要有效管理带宽和延迟限制,编解码器有助于优化云环境中的性能和资源使用。外设组件互连用于将网络适配器、独立磁盘冗余阵列控制器等外设通过扩展插槽直接连接到主板。改进的外设组件互连使用点对点连接而非共享总线,通信速度更快,可扩展性更高。这些外设组件的每个插槽可容纳更多通道,能自适应地提高数据传输速率,特别是那些部署在测井云基础设施中的应用。在部署容器化服务时,它可通过与外部存储阵列的直接连接有效利用计算节点,减少与网络开销相关的延迟。图 3 是人工智能测井软硬件网络结构。

对于 AIL 云而言,内容分发网络(CDN)是一种分布式系统。它是指在终端用户附近存储网络内容副本的服务器分布式网络。内容分发技术的主要目的是提

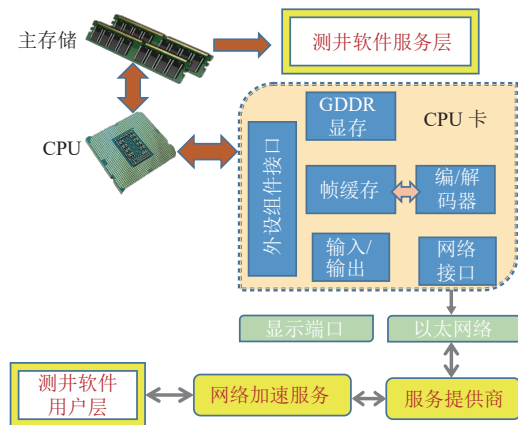


图 3 人工智能测井硬件网络结构
 Fig.3 Hardware network architecture of AIL

高系统网络 API 的数据加载速度,减少服务器负载。网络加速服务,通过缓存经常访问的文件,使其更接近分布各地的用户位置,从而帮助优化端口加载速度。它的工作原理是将各种测井文档等静态数据的副本存储在使用地点附近的服务器上,从而最大限度地减少长途通信造成的延迟。内容分发网络通常集成了负载均衡算法,能够根据可用性、响应时间和拥塞状态等因素智能地路由查询,确保正常运行时间和故障恢复能力。测井云中的帧缓存器是描述在远程运行应用程序的虚拟机中实施的类似机制。由于分配给每个虚拟机的资源有限,对于某些需要密集计算的任务,必须依赖管理程序提供的临时存储空间。

2.3 学习算法

测井建模是为机器学习积累学习数据,为将来的测

井数据流校正服务。人工智能测井的核心技术为学习，而学习的基础是数据。AIL 测井云的数据交换流程，如图 4 所示。

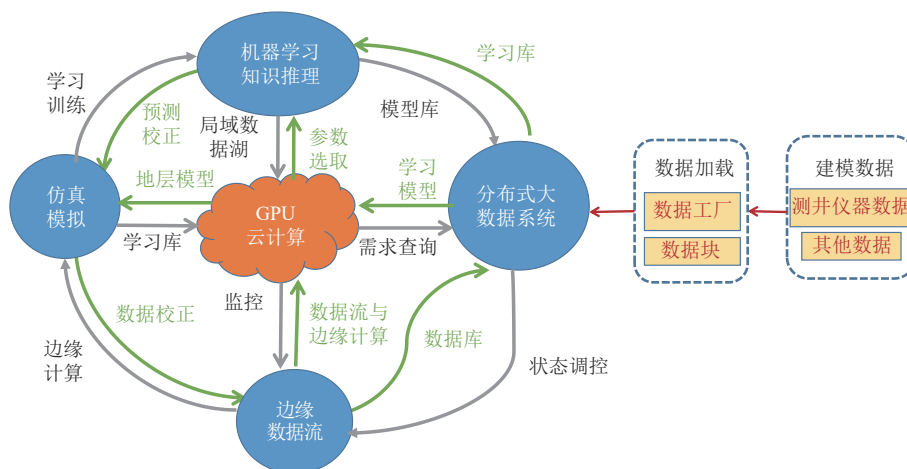


图 4 人工智能测井云的数据流
Fig.4 Data flow of AIL cloud-based logging platform

2.3.1 统计方法

在人工智能测井云平台上可实时或事前调用该模块。测井方法与模拟数据流的多维建模包括对不同时期的测井数据应用一维、二维或 n 维空间可视化技术，并能进行多属性、多参数、多尺度的观察。以评价为目的的聚类分析包括岩石的物性、岩性、含油性，岩石物理、仪器测试和测井采集为对象的建模统计分析。对于测井综合评价大数据，应用大数据可视化技术可发现测井大数据集内同一地层的综合异常信息，乃至发现一个构造，甚至一个盆地的综合异常，如岩性突变、应力突变等。正则化分析法是在岩石物理和测井仪器数据的基础上建立标准数据，正则化其他数据，为下步机器学习做准备。

2.3.2 人工智能算法

测井数据挖掘是在测井历史数据以及现有成果的基础上，根据计算分析技术、机器自我学习与机器学习等新兴的信息技术，它能预测一个地层、构造，甚至盆地等的遗失属性。该方法是能根据已有的测井数据结合其他勘探开发数据，推理新的测井概念与属性。通常应用的算法有神经网络、属性转换、空间分析、基因遗传算法、贝叶斯信念网络以及自学习系统。

1) 神经网络法

它是用于模拟人脑的行为和思维而进行推理的。这项技术用于非线性系统的分类或回归分析技术，同时提取特征值和模式识别，能够预测岩层的岩石物理属性或变化趋势。自适应模糊神经网络技术是将逻辑学与神经网络技术结合的新型技术。它将知识库、解释经验结合，通过神经网络分散任务与学习，其鲁棒性更强。

2) 属性转换法

当测井数据集的属性为时间或深度相关时，可进行时间-深度域转化，在对象频率基础上用来预测对象的未来属性。

3) 空间分析法

当测井数据集地质沉积空间分布与深度变化相对应时，因地质沉积属性会影响地层的地质工程特性，因此通过空间分析法，从而更准确评估地层的工程性质。

4) 基因遗传法

它是依据达尔文的进化论中的自然选择和遗传进化机理建立模型，模拟这一过程来搜索最优解。它将地层评价类比为自然进化中的下一代比上一代更适应自然界，其具有更强的生存能力，对问题经过遗传解码，将问题的解转化为评价对象的最优近似解。

5) 贝叶斯信念网络它是一种基于数学原理的模型，其通过已知参数，获取未知问题的变化过程和变化趋势。其基础为贝叶斯理论，它创造性地把哲学思想应用到自然科学，扩展到工程技术中。

6) 自学习系统

它是为促进测井大数据的挖掘和分析、人工智能、自主学习以及其他技术在油田中的使用，油田公司将传统的地质学、地震学、岩石物理学、油气井学、油藏工程学与计算机科学跨学科融合，而建立一个全新的石油大科学系统，并把数据挖掘、未来预测分析和油田勘探开发技术综合在一起。根据现有的历史测井数据和现有测井数据，依据评价的对象对应不同的数据库，应用包括深度学习算法等，不断筛选优化，形成优化模型。最后，应用在测井解释、油藏监测、地质导向和综合评价上，再经试油试采不断验证，反馈，完善，达到自我学习的目的。其成果可应用在勘探开发中，即岩石物理实

验得到岩性及孔隙类型信息,可描述毛管压力及流体性质,测井资料评价提供储量、流动能力和流动单元信息, 如图 5 所示。

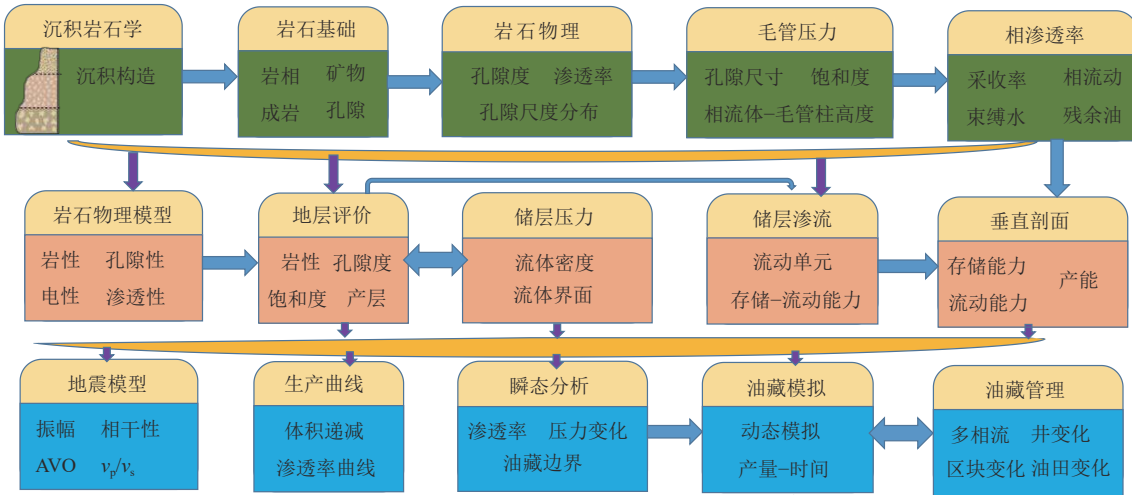


图 5 测井在油藏开发综合评价流程

Fig.5 Flow chart showing logging-based comprehensive assessment during oil reservoir exploitation

7) 测井大模型

由于从数据中提取特性知识,以构建精确的机器学习模型。自编码器主要用于测井数据的降维、测井特征工程提取与学习、数据质量控制,测井知识的发现与

表示等。其内置于人工智能测井系统的数据层。测井问题求解与知识发现的数据流程包括数据降维、机器学习特征工程提取、智能算法的优选、测井问题求解与输出。其测井问题求解与知识发现的流程,如图 6 所示。

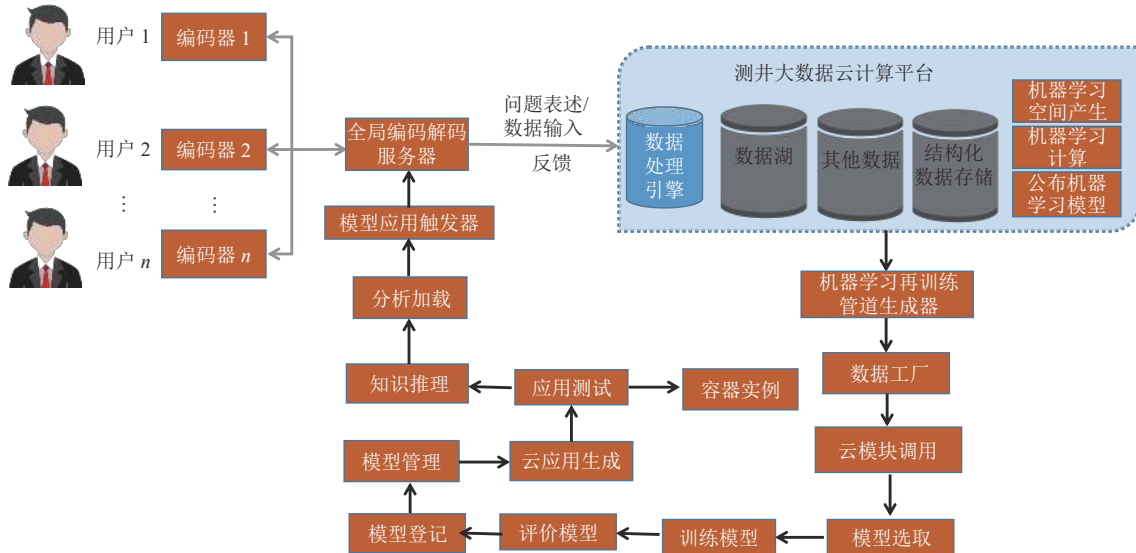


图 6 测井问题求解与知识发现的数据流程

Fig.6 Flow chart for logging problem solving and knowledge discovery

测井信息格式复杂多样,需要大模型进行学习处理。基于大模型的人工智能测井硬件架构,如图 7 所示。

测井大模型的构建使用编码器-解码器架构。它是根据所需解决测井问题的复杂程度和计算资源选择合适的神经网络结构,通常是 Transformer 架构。根据当前应用的类型,考虑修改现有模型或设计专门满足测井问题求解的新模型。构建测井大模型需要自然语言

处理、机器学习和专业知识等技能。LLM (Large language model) 的 Transformer Encoder 包含以下几个主要模块: (1) 编码器网络由多个嵌入层组成,其中每个嵌入层都负责提取不同层次的信息特征。这些特征可以用于后续的任务,例如实体识别等。(2) 自注意力机制是 Transformer 模型的核心部分之一,主要用于捕捉文本中的局部依赖关系。(3) 变换器是对经过编码后的向

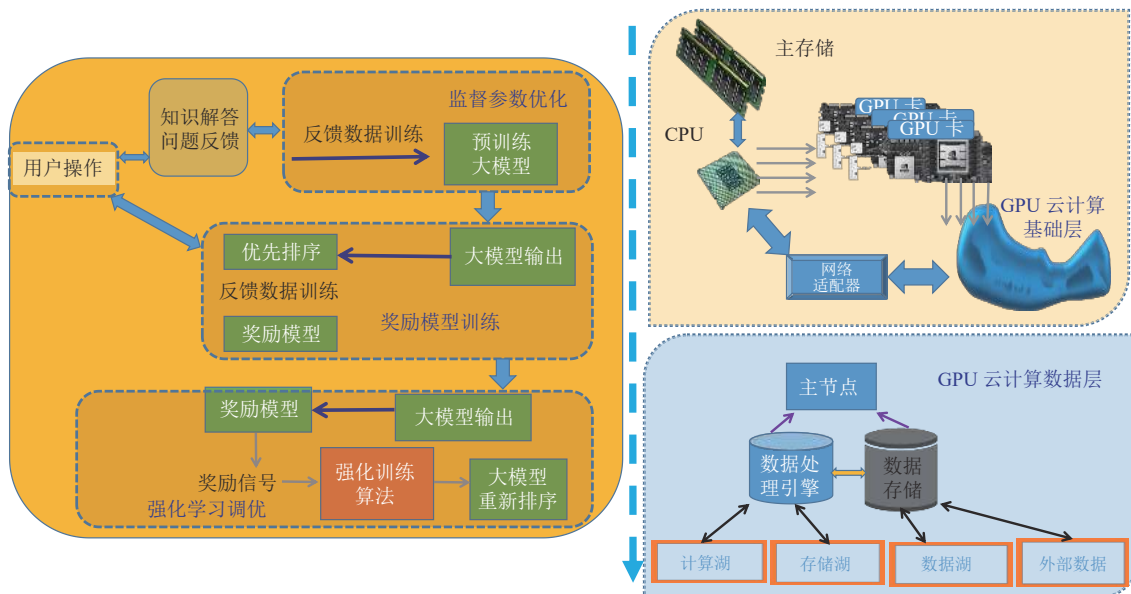


图 7 基于大模型的人工智能测井架构

Fig.7 Big model-based AIL architecture

量进行一些简单的运算，比如求和、卷积、矩阵乘法等等，以进一步增强模型表达力。(4) 全连接层是把前面各个模块产生的向量组合起来，形成一个新的向量表示，以便后面的分类或者回归任务使用。大模型编码器不仅具备了传统神经网络的一些优点，还结合了 Transformer 模型的特点，使得模型更加灵活、可扩展且表现更出色。交叉注意力机制有效地解决了长期依赖问题，提高了模型的准确性和鲁棒性，同时也大幅降低了模型的复杂度。相比传统的 RNN/CNN 模型，Transformer 模型可以通过跨度更大的注意力机制直接从整个序列中学习到更多的信息，这有助于解决长期依赖问题以及减少参数数量等问题。在 LSTM 模型中，每一个时间步都需要单独存储过去时刻的状态，而这种方式会占用

大量的内存空间；而在 Transformer 模型中，只需要一次读取整个序列即可，这样就大大降低内存消耗。此外，在 Transformer 模型中，不需要像 LSTM 那样设置门控单元，因为 Transformer 模型可以直接学习到两个位置之间存在的依赖关系。在 LLM Transformer 中，交叉注意力机制通常应用于 Encoder 和 Decoder 两端，即在编码时考虑相邻位置上的信息，并在解码时考虑前后位置上的信息。

图 8 是基于 AIL 测井问题的大模型流水线处理过程。

3 技术

人工智能测井集成了外部物联网装置的数据，经过边缘物联网处理、数据缓存及 AIL 中枢集成后，进入数

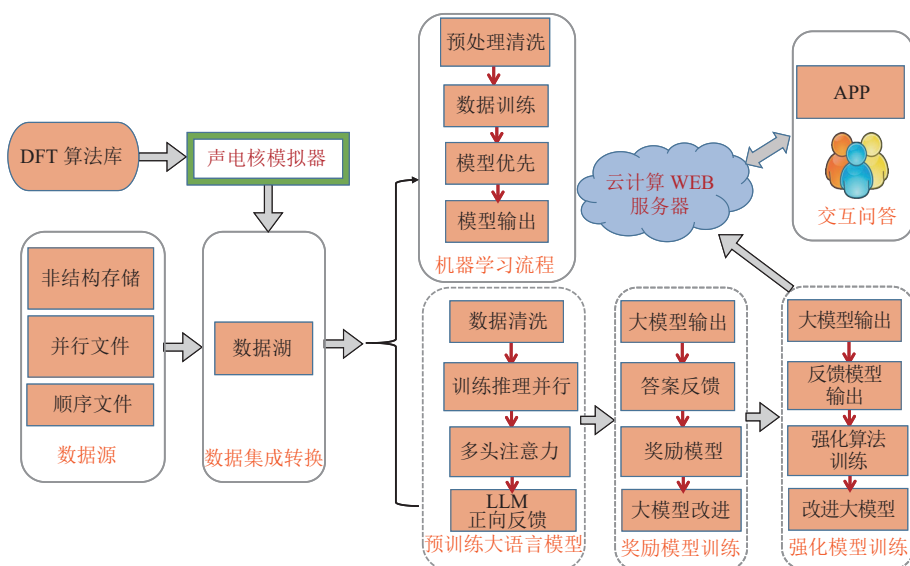


图 8 基于 AIL 测井的问题处理流程

Fig.8 Flow chart showing AIL-based problem solving

据工厂精细加工。随后,利用先进模型进行数字孪生模拟,并通过机器学习深入挖掘数据价值。处理后的数据将同步至数据湖,满足测井模拟、仪器采集、综合评价及岩石物理分析等多样化应用需求。AIL 的技术体系由以下方面组成:大数据技术,涵盖深度学习的学习技术,地层真参数提取,测井知识图谱,智能仪器与数字地层的数字孪生技术,边缘传感计算,智能仪器等技术。

3.1 测井大数据技术

对测井大数据的挖掘、感知和认知,从而实现测井价值,这将成为人工智能测井实现的关键。建立在测井大数据基础上的 AIL 测井是通过分布式存储和处理的大数据系统,实现测井知识发现和学习功能的。依据 Hadoop 大数据系统的设计思想建立起来的数据存储、文件管理、进程控制、任务分配与汇集的平台。它通常由 Hadoop 分布式文件管理系统,资源管理,提供数据查询和分析和任务分解合成组成。分布式文件管理系统是一种可伸缩分布式存储文件管理系统,在无须事先组织的情况下,即可跨多台计算机存储数据。HDFS 具有高度的数据容错能力,可低成本地部署在本地家用微机上。HDFS 提高数据访问吞吐量,并且适用于具有大数据集的学习应用程序。Hadoop 平台中的 YARN 则为平台上运行的进程提供资源管理。系统中的 MapReduce 模块则提供并行任务处理系统框架。它的主节点用于获取输入并将其存储在分区较小的子空间,并将它们分发到子节点上用于完成任务。完成映射后,主节点将获取所有子问题的答案,并组合生成输出结果。这是人工智能测井的大数据存储、处理和输出的实现原理。

测井大数据的安全也是 AIL 测井必须关注的问题。由于测井数据的价值性和保密性,通常采用文件传输协议以保障数据的安全。在控制连接上,用户向 AIL 系统服务器发送登录、密码验证、目录列表、文件创建和删除等命令。当验证完成,数据连接就会打开,并在终端和服务器之间传输数据。另外,FTP 服务器通过 SSL/TLS、SSH 隧道等加密方法和其他技术,提供对文件的安全远程访问。它们还支持配额、带宽节流、虚拟目录和脚本执行功能等高级选项。

3.2 学习技术

学习技术是人工智能测井模仿人类学习知识和再学习的过程,从而实现其提升能力。通过测井大数据挖掘学习,与测井专家交互学习,形成增强学习能力,并从现场应用效果中反馈学习等。AIL 强大的算力支持保障了系统不间断地学习和解决测井问题能力的提升。

3.2.1 机器学习

机器学习通常按照专家知识的介入程度,分为监督

式学习、无人监督式学习和强化学习。集成学习方法是许多弱学习算法融合到一种高质量的整体预测器中。这些方法是使用相同的语法,因此改动较小的参数,根据输出要求,寻找出精度最好的算法。评价机器学习算法性能的流程,首先在独立的测试集数据上评估整体算法,可把测试集数据分为不同部分,用于交叉验证来评估整体算法效果。

对于电声成像测井来说,裂缝或岩相等识别的学习过程,包括数据采集与预处理。从电声成像仪输出数据,并对数据进行预处理,即去噪、滤波、几何校正等步骤,以提高数据质量和可用性。图像的特征提取。利用深度学习模型,如卷积神经网络(CNN),对预处理后的数据进行特征提取。CNN 等深度学习模型能够自动学习并提取数据中的特征,有助于把目标(如裂缝和溶洞)与背景区分开。训练模型是使用已标注的电声成像数据(包含裂缝和溶洞的区域)来训练深度学习模型。模型验证与调优。通过验证数据集对训练好的深度学习模型进行验证,评估模型的性能。根据验证结果,进行模型的调优,以提高对裂缝和溶洞的识别准确性和鲁棒性。当模型训练完成且学习指标达到要求时,将其应用于实际电声成像数据,进行裂缝和溶洞的识别。模型将会自动识别并标记出潜在的裂缝和溶洞区域,为地质勘探和工程评估提供有用的信息。

学习算法的优选,需要综合考虑要解决的测井问题、数据的特性、模型性能指标等多方面因素。(1) 测井问题的匹配。要确保所选算法能够很好地解决测井特定的问题,如岩相划分、储层识别、力学评价、流体剖面、油藏监测等。不同的算法适用于不同类型的任务,如分类、回归、聚类或相关等。(2) 测井数据的规模。考虑测井数据集的规模和特征维度。对于大规模数据集采用分布式学习框架;对于高维度特征,采用稀疏数据处理算法更适用。(3) 模型复杂度。根据测井问题的复杂性和所需的精度,选择适当复杂度的模型。(4) 可解释性。通常需要对模型的预测结果进行解释。如岩相的划分或油藏开发的预测等,有时模型的可解释性比准确率更为关键。特别是,涉及到作业或环境安全问题。(5) 训练效率。考虑学习算法的训练时间和计算资源消耗。(6) 数据标记和标签。对于监督学习任务,需要有足够的标记数据。如果标记数据少,则需要选择半监督学习或迁移学习的方法。学习算法的选择也需要考虑测井专业知识,测井专家的知识能帮助指导选择更适用的学习算法。测井问题解决与学习算法的选择,如图 9 所示。

3.2.2 强化学习

强化学习(Reinforcement learning, RL)是在深度学习基础上发展起来的。它主要是以测井智能仪器为对

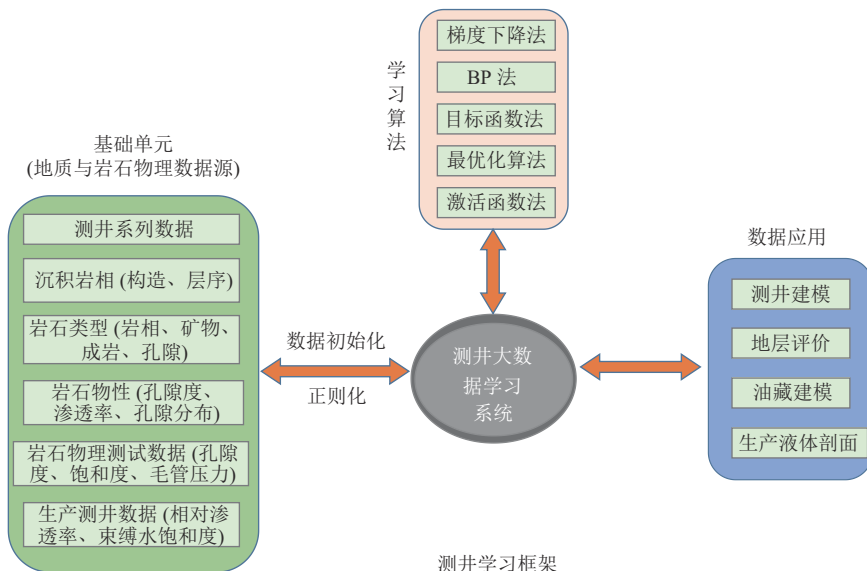


图 9 测井问题解决与学习算法的选择

Fig.9 Solving of logging problems and selection of learning algorithms

象, 涉及测井智能仪器如何在井孔环境下动态组合传感器, 采集数据, 仪器动作, 以最大限度地提高累积奖励。测井智能仪器是通过强化学习从现场和测井解释专家获取经验, 以提高地层属性数据获取、测井资料处理解释应用和现场测井决策的准确度。

3.2.3 测井大模型学习技术

在测井大语言模型中, 通过解码, 变换中的自注意力、嵌入等技术实现。嵌入是一种将测井无格式文本表示为向量或张量的技术。通过使用嵌入矩阵和词袋化方法来实现这个过程。嵌入是大模型的核心组成部分之一, 也是它能够产生测井文本的重要原因之一。自注意力机制是一种用于处理序列数据的新型计算方式。自注意力机制的基本技术思路是在给定的序列数据上应用一种注意力权重函数。由于自注意力机制的应用, 使得 Transformer 模型可以在不需要全连接层的情况下直接从输入序列中学习特征表达式。这有助于减少模型参数数量, 提高推理速度和降低内存消耗。

3.3 真参数技术

通常获取校正后的真参数的方法是正迭代法。其原理是通过正演计算的电声核参数, 与实际测井得到的参数进行比较, 得到偏差量 ΔP , 通过调整地层模型和井眼参数, 减少偏差量。当偏差量可接受时, 反推出复杂的井况和地层参数。它的缺点是测量和模拟值的误差容易出现发散, 迭代次数受人为影响大。通过对地层电声核特性和地层构造进行建模得到地层的电、声、核响应图版, 以实现与实际测井数据进行校正。这种方法不是通过调整模型学习参数或特征工程获取真参数。机器学习获取地层真参数电阻率的流程, 如图 10 所示。这个流程同样适应于获取地层真声、电、核以及核磁等

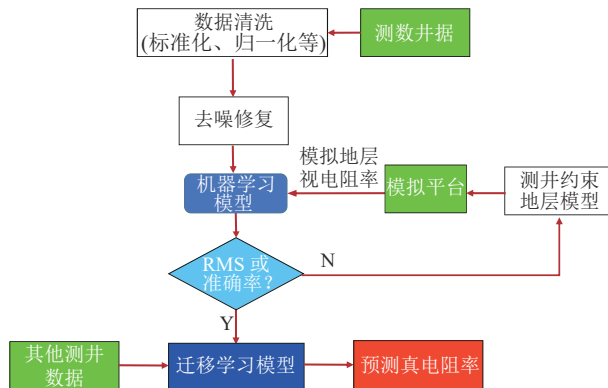


图 10 真电阻率反演流程

Fig.10 Flow chart showing the inversion of true formation resistivity

参数。AIL 则通过机器学习算法, 通过物理建模与实际测井数据, 通过端到端(End to End)学习出地层声、电、核以及核磁等真参数, 从而利用这些参数综合描述地层的孔隙性、渗透性、含油气性与各向异性。地层“新四性”参数的获取流程, 如图 11 所示。

3.4 数字孪生

数字孪生是对测井仪器、地层、岩心、井筒, 乃至油藏等实体对象, 进行数字动态模拟、描述, 从而建立测井实体与数字体的对应关系。数字孪生体, 通过对测井大数据或测井知识的动态收集, 数字孪生与来自传感器的更多实时输入数据流而不断更新发展的。数字与物理世界之间的连接增强了测井物理实体的生命周期、明智的决策和预测能力。意义在于降低测井任务解决的时间, 达到测井作业提质增效的目的。

测井数字孪生的关键组件包括: 仪器、地层、井筒、岩心多场参数以及它们的孪生体, 物联网传感器, 模型刻度与优化。基于机器学习的孪生动态处理与可视化




图 11 地层“新四性”参数的获取流程

Fig.11 Flowchart showing the calculation of the porosity, permeability, oil and gas-bearing properties, and anisotropy (parameters of “new four properties”) of strata

分析与警告。数字孪生服务和优化包括测井孪生体的诊断、预测以及评价。其产生过程:判断是产生新的数字孪生或调用已存在数字孪生;AIL 系统收集从物联网,传感器,或从仪器或地层实体得到的数据,对数据分类或进入数据湖;可视化分析确认数字孪生与数据的特征值差异;如果有差异,产生新的数字孪生,并存储新模型,

标记新版本,并在管理模块中标记,否则,重新进行判断;产生新的数字孪生模拟或调用原有版数字孪生;置换数字孪生模拟中的特征参数,保留其他参数;校对模拟参数,执行模拟;输出模拟结果,保持在管理模块中。具体的数字孪生处理流程、内部结构以及产生和更新流程,如图 12、图 13 所示。

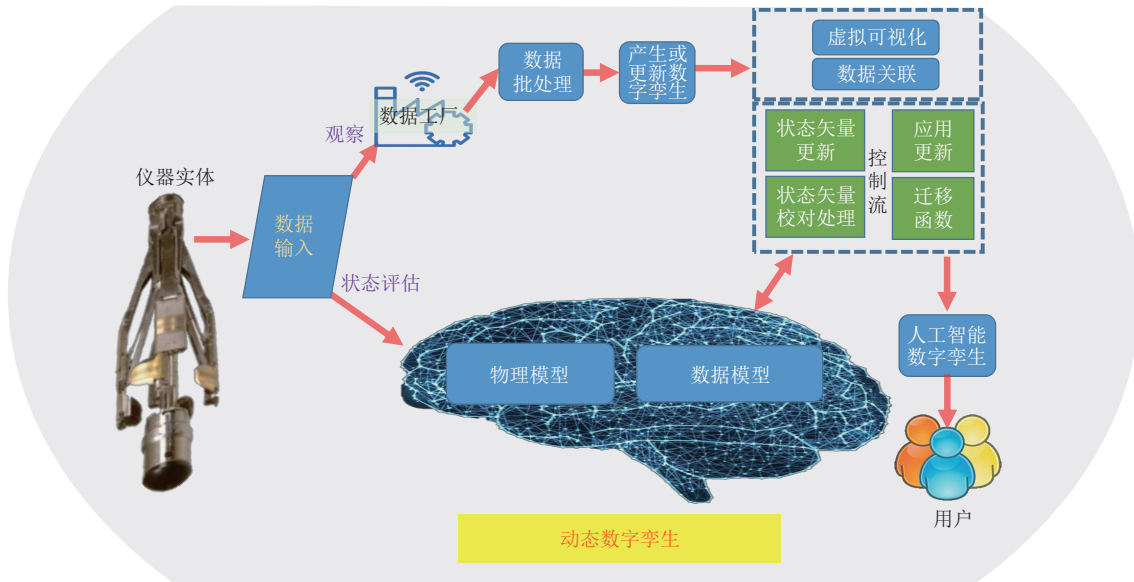


图 12 基于物理模型和数据模型的数字孪生

Fig.12 Digital twinning based on physical and data models

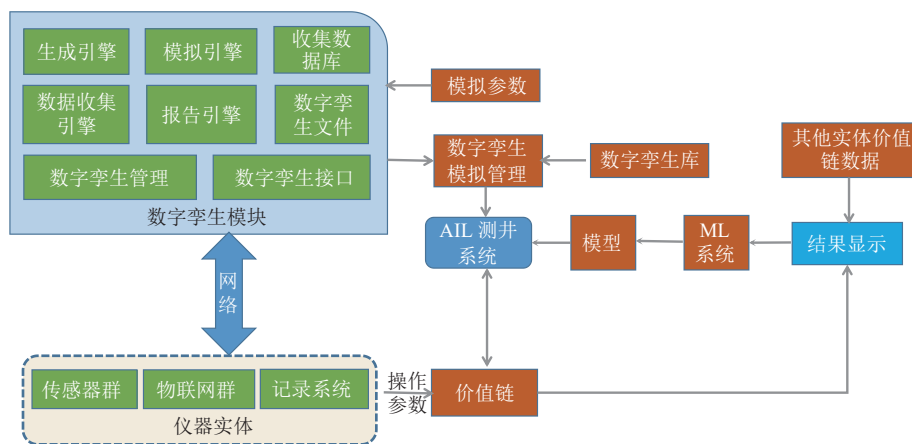


图 13 数字孪生技术关系结构

Fig.13 Relationship structure of digital twinning technology

3.5 知识图谱

测井知识图谱法是通过明确地表示测井实体及其关系,从而实现跨多个信息源的高效查询和推理。利用现有的知识库来构建知识图谱,并从中提取相关事实。然后,应用自然语言理解技术来分析这些图的结构,并得出概念之间关系的结论。

测井知识图谱是为油田现场技术人员和测井专业学生,提供一个动态、实时更新的知识平台。通过这一平台,能够掌握测井实体的实体属性,以及它们之间的复杂的相互关系,从而加深对测井领域的理解。同时,这为人工智能测井在测井数据基础上存储知识和发现知识奠定了基础。测井知识图谱的构建,包括知识提取、

知识的融合、知识学习和应用等步骤。由于测井技术发展过程中,存在大量的非结构化数据,测井知识的提取就是从测井非结构化、结构化以及半结构化数据中,发现规律,获取知识及其关系。知识图谱通过知识融合,将从不同来源的测井知识,建立本体、属性以及关系之间的关联,实现知识快速获取的能力。知识图谱将学习到的知识进行归纳、总结、存储以及应用。其组件包括命令接收器,实体管理模块,调度模块,分类引擎,模型训练,学习平台,决策行动引擎,自编码器,测井知识域特征提取,模块接口。所建立的人工智能测井(AIL)知识图谱,如图 14 所示。测井知识图谱答案的求解过程,如图 15 所示。

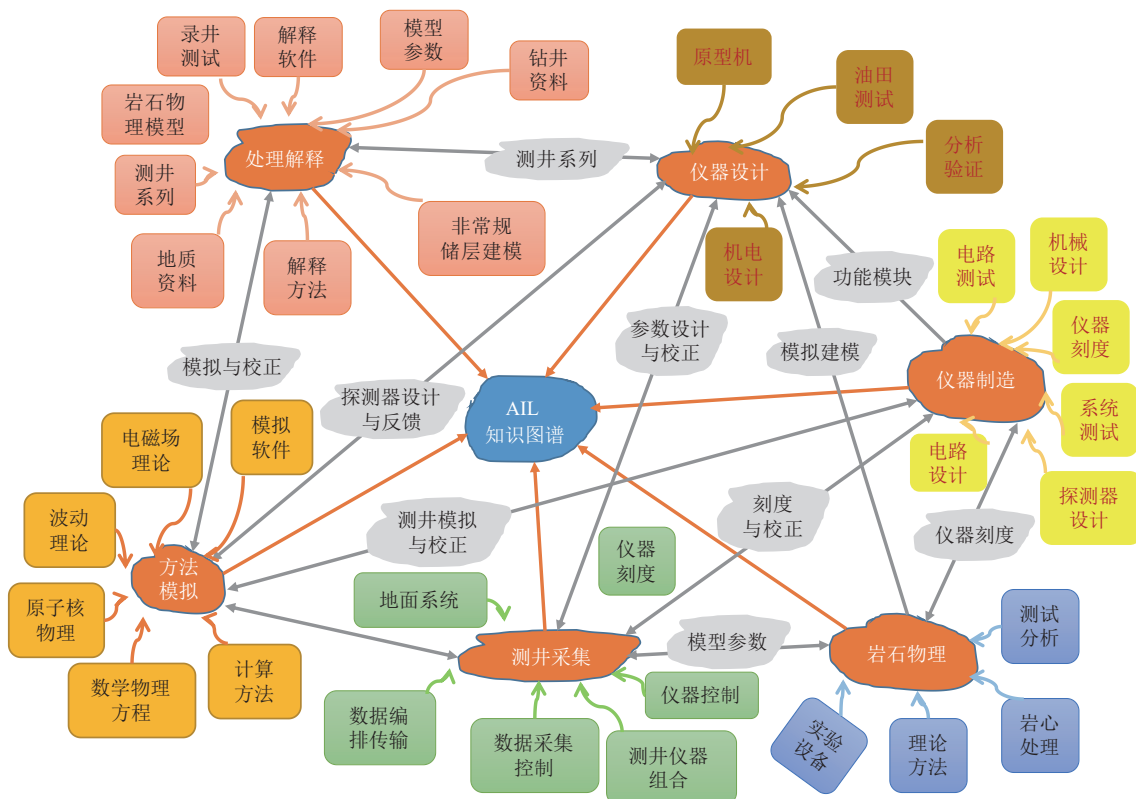


图 14 人工智能测井(AIL)知识图谱
Fig.14 Knowledge graph of AIL

3.6 边缘传感计算

AIL 系统是通过互联网或其他通信网络与其他设备和系统的连接传感器实体对象,并进行数据计算和交换。边缘传感计算使测井方法、测井仪器、岩石物理、数据采集、测井解释、录井、地质、地震、钻井以及永久监测传感器数据都通过物联网,与人工智能测井平台的各功能模块进行通信作业。通过边缘计算设备,上传到人工智能系统的大数据云端,可以使用 ML 管道,完成数据准备、功能提取、超参数优化、模型评估等模型训练过程。以上步骤可以作为统一的处理管道定制,也可

以在本地边缘计算中调用已有的模型,验证和分析,以便确定部署的合适的 CPU(GPU) 和内存等资源。将模型打包到容器(Docker)映像中以方便在节点服务器上部署,从而进行模拟、多学科大数据分析、学习、任务资源调配、测井作业解释决策。利用传感器、边缘计算以及云三级结构实现数据的存储、计算、处理和大数据分析,结构如图 16 所示。使用容器还可以通过将每个组件相互隔离来提高安全性,防止未经授权的访问并减少潜在漏洞。测井物联网边缘计算是将相对较小的中央处理单元和磁盘嵌入固定的边缘设备中,或产生数据

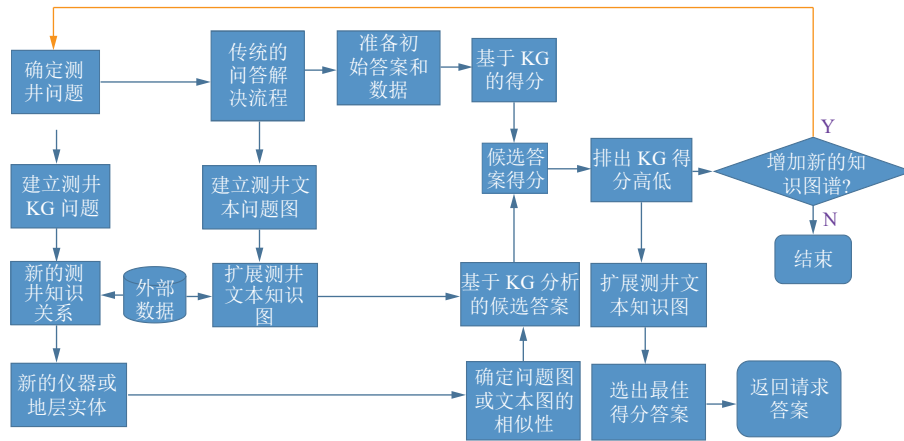


图 15 测井知识图谱答案的求解过程

Fig.15 Solving process of the logging knowledge graph

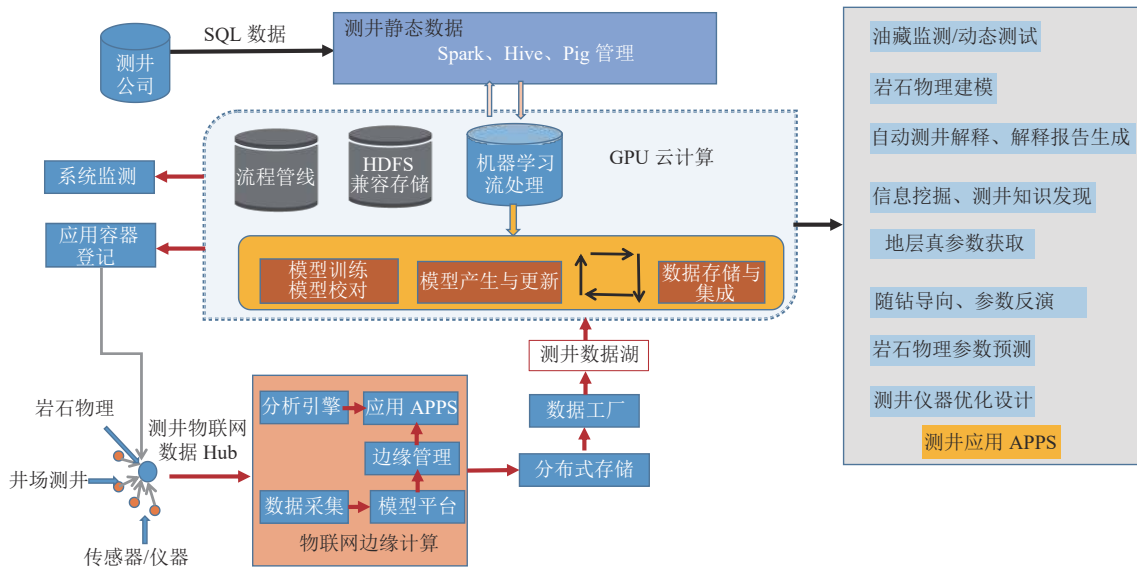


图 16 测井物联网数据流处理流程及应用

Fig.16 Flow chart showing the processing of logging-related IoT data flow and its applications

的油田设备连接到可以进行无线通信的计算机上与其他地方的井、站、场点连接通信。

3.7 智能仪器

智能仪器是具有利用类人神经科学的跨学科学习能力。AIL 通过对专家经验和知识的学习,赋予具有人的柔韧性和机器的持久性等特性的测井装置计算分析、决策和执行能力。测井智能仪器是根据油气勘探开发的现场需求,按以下步骤进行:提炼出测井问题,形成测井系列,生成测井作业环境,确定奖励准则,产生智能仪器的行动准则和环境域,训练测井智能仪器,验证测井智能仪器,使用策略,生成处理结果,智能决策,生产验证,循环强化学习提升。

测井智能仪器是通过在 AIL 系统上实现智能仪器控制,强化学习,智能决策实施和反馈组成。测井智能仪器包括内置的学习和控制芯片完成仪器的作业控制。它的控制器是运行控制智能机器的单元,其中包括 AI 微控制器,单片机,或者其他发送和接收的处理器命令

的装置。智能仪器的臂和可以应用可编程逻辑控制器,模仿人的操作。控制站或人机界面是智能仪器执行专业人员要求任务的交换装置,测井专家或工程师通过视频或语音监督智能仪器的行为是否正确,并反馈信息到 AIL 系统。AIL 控制平台向智能仪器发送命令,并且接收来自测井智能仪器的传感器数据。气动传动,液压传动,旋转线性转换移动器为智能仪器提供运动功能。伺服器具有反馈机制和控制回路,能以特定方式保持位置或速度。伺服器能驱动变速箱的电动机,变速箱由一系列齿轮组成,降低速度并增加电动机的扭矩。传感器从智能仪器的外部或内部获取信息,将其转换为数字或电子格式,可以移动并对智能仪器行动做出响应。光学传感器将光信息转换为以数字像素记录的数组或张量。声纳传感器将通过发送高频能量脉冲(声波)并监听之前的时间延迟听到回声,来测量时间延迟可以测量智能仪器到物体(例如井壁)距离,并保持智能仪器与物体保持距离。测井智能仪器的结构示意图及组件,如图 17

所示。

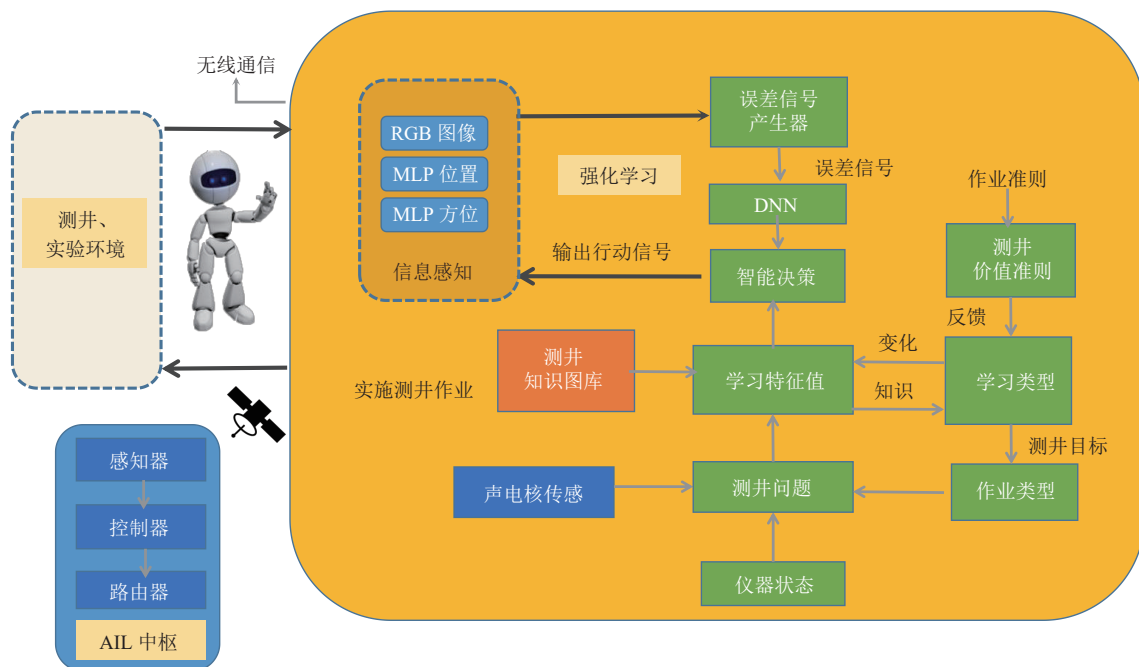


图 17 人工智能测井智能仪器原理流程

Fig.17 Flow chart showing the intelligent instrumentation of AIL

3.8 远程作业

由于测井作业现场大多位于偏远山区, 交通不便并且井场比较分散, 存在现场解释人员解释经验不足。测井服务公司通过 AIL 云的远程作业模块完成远程测井作业, 实现测井数据质量控制、数据采集以及资料快速处理解释, 这将解决测井数据多维度、多类型的信号采集与传输, 电缆传输, 井下存储式, 随钻, 光纤等采集一体化的测井作业问题。远程测井的实现由人工智能测井平台提供核心基础层、应用支持层、应用业务层以及现场作业层, 其各部分的组成, 如图 18 所示。远程采集能实现以井为中心, 通过云在中枢端和井场端建立技术桥梁。通过在井场端建立测井仪器设备的组装, 实现远程测井的标准化作业, 绞车仪器操作, 质量安全环保管理。通过远程通信, 在中枢端实现对现场作业的控制权, 测井过程质量的监控和资料的获取, 实现智能处理和决策。

4 应用

井场的需求通过卫星或物网上传到 AIL 系统中, 系统按照分类、回归、聚类、相关等不同的任务, 应用人工智能测井技术进行处理, 并返回结果进行解释, 组织, 决策, 执行, 反馈学习。具体在岩性识别、质量控制、油藏监测、地层真电阻率反演、储层流体识别等方面的应用效果, 如图 19 所示。

4.1 岩性识别

鄂尔多斯盆地致密砂岩具有分布面积广、含油质

好, 而具有勘探和开发的巨大潜力。但其储层组成复杂, 而造成勘探开发难度增大。地层的岩性还包括页岩、石膏岩、石灰岩和白云岩等。常规的岩性识别方法未取得良好的效果。以下为应用人工智能模型解决复杂岩性识别的具体步骤: (1) 定义岩性识别问题。确定需要分类的学习数据集中的岩性为 39 种。(2) 数据预处理。把数据缺失, 计算错误或特殊标记的地方设置为 NaN。剔除超界数据或缺失数据较多的行; 由于深度列只是标记, 与岩石命名无关。所以在特征工程中, 去掉深度列以提高学习精度。即在 37 个特征值中剔除深度, 实际特征值为 36。(3) 把数据调入学习工作区。查看每个特征值的范围, 设置交叉学习验证比例。(4) 数据转换。标准化或归一化。(5) 特征值提取和数据探索。根据专家知识经验, 删除无关的特征值。数据探索包括用统计分析、可视化等, 查看数据质量。(6) 数据分割。把数据集分为训练集、验证集和测试集, 本例中 80% 数据用于学习训练, 20% 用于验证。另外 16 组油田数据用于测试。(7) 学习模型选择。将选择不同的机器学习算法, 如支持向量机(Support vector machine, SVM)、决策树、朴素贝叶斯、集成装袋算法等, 并通过对训练数据的拟合和测试数据的验证, 来评估各个算法的性能。(8) 学习模型评估。比较不同算法在验证集上评估模型性能, 使用交叉验证来减少过拟合风险上的表现, 优选出最优模型为集成装袋法, 其精度为 93.8%(表 1)。(9) 模型部署。将最优 KNN 算法后导出该模型, 就可

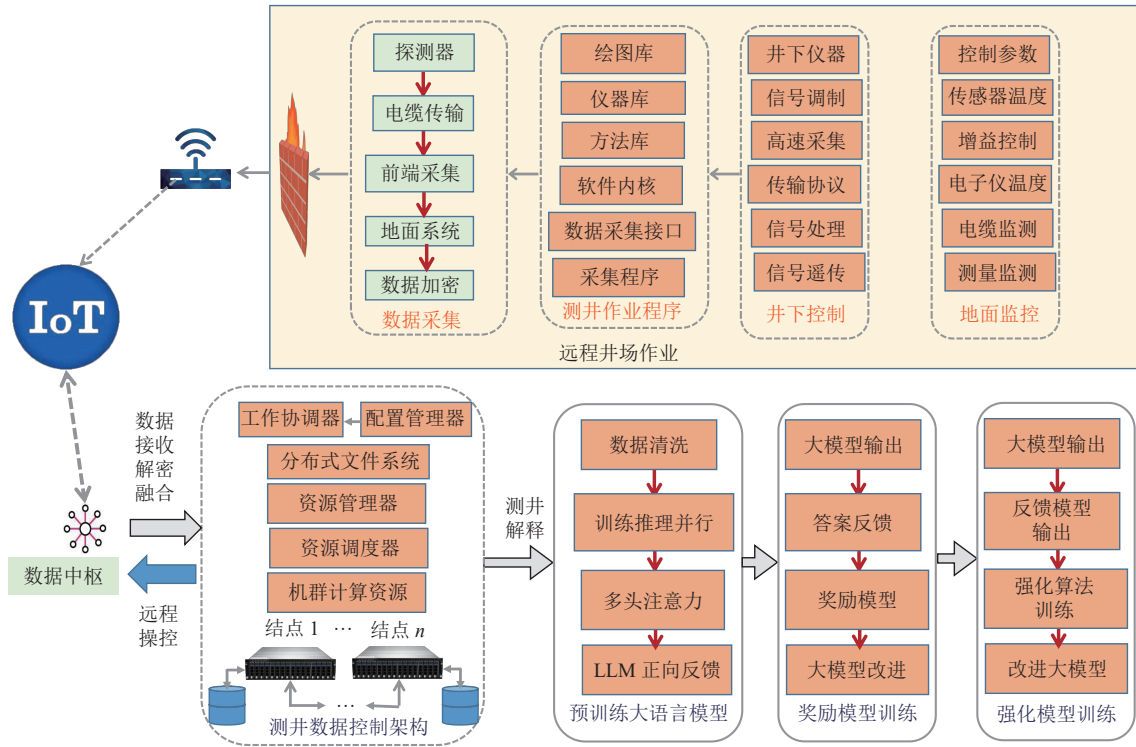
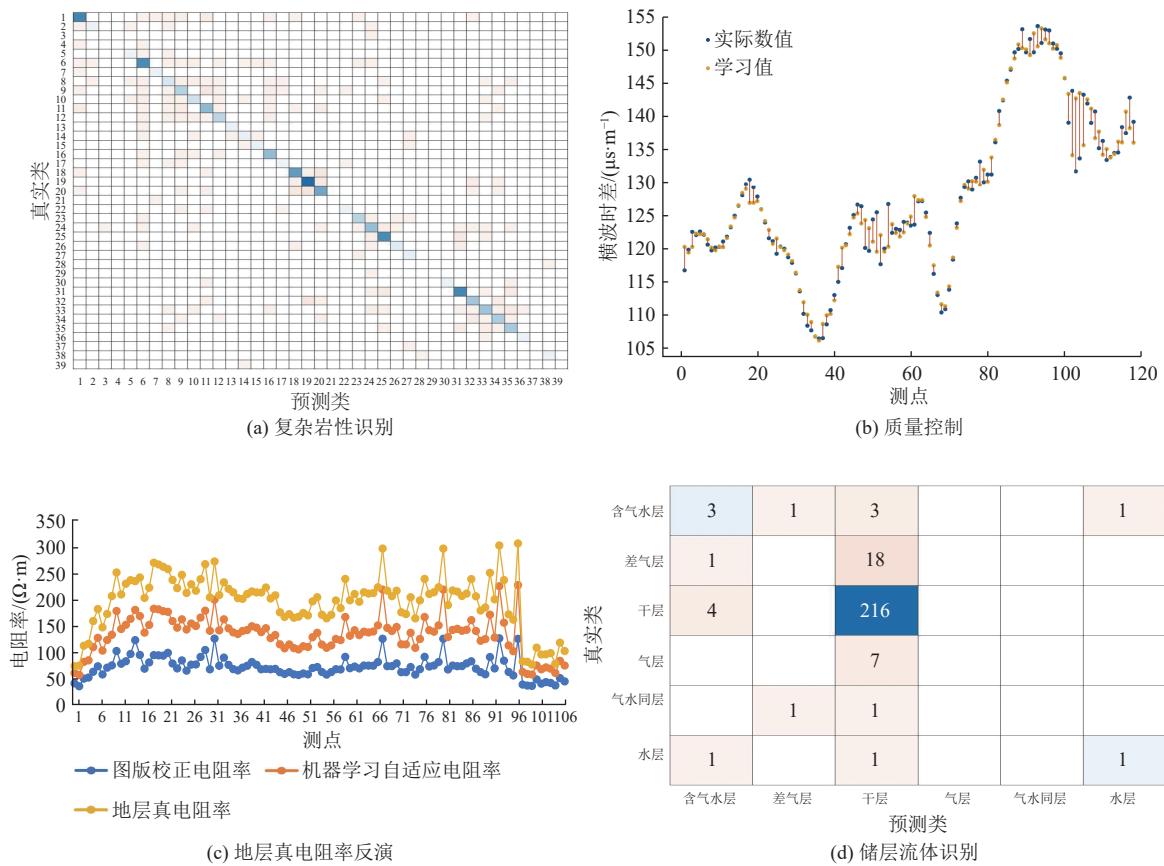


图 18 远程作业技术构成

Fig.18 Structure of remote operation technology



注：图 a 中 1—39 代表不同岩性。

图 19 AIL 在复杂岩性识别、测井质量控制、地层真电阻率反演以及储层流体识别中的应用

Fig.19 Application of AIL in the identification of complex lithologies, log quality control, inversion of true resistivity, and reservoir fluid identification

以使用独立的测试集对模型进行最终评估。通过对新数据进行预处理和特征提取, 便可以使用训练好的模型对这些岩石进行命名。这样就能够实现对未知岩石的自动识别和命名, 提高岩石命名的效率和准确性。

应用 AI 算法发现, 最佳分类器是集成装袋法, 其次是朴素贝叶斯、KNN、人工神经网络等(表 1)。所以, 选用集成装袋模型作为最终的优选模型用于实际数据的岩性分类, 实现了 39 种岩性的识别(图 19a), 而应用岩性曲线和交会图只能识别 6 种岩性。

表 1 不同机器学习算法的准确率对比
Table 1 Comparison of accuracy of different machine learning algorithms

算法	验证准确率/%
朴素贝叶斯	89.2
KNN	86.1
提升树	58.9
集成装袋	93.8
二层神经网络	80.6
三层神经网络	80.5
宽神经网络	84.5
子空间判别法	50.1
支持向量机核函数	40.8
逻辑回归核函数	34.7

4.2 质量控制

通常认为测井信号由地层信号、井场随机噪声和仪器电路噪声等构成。其中的数据错误包括仪器故障, 车间和现场校准错误, 操作员误操作以及仪器内置的硬件限制引起的误差。AI 学习方法通过对多井测井归一化解决以上问题, 它也特别适用于数百个测井数据质量差异和不同年代的井。首先将机器学习应用于多井归一化问题。参考单元通常是横向扩展的同一沉积地层, 同一沉积环境, 具有一致的测井响应。应用参考井段的测井数据训练预测性机器学习模型, 并使用基于回归的优化算法确定固定偏移量, 然后用其作为对其他井的密度和中子测井数据进行归一化校正。该方法具有较强的泛化性, 因为它与信号类型无关。如果可以使用足够大数量的标记数据, 则可以将其扩展为其他测井类型, 尤其是在其相关性不明显时。

由于某些井段横波数据的缺乏, 但如果进行储层的工程评价时, 需要计算剪切模量, 泊松比等剪切参数。因此, 需要从常规测井曲线中预测横波数据。利用机器学习进行预测除使用纵波测井作为主要特征曲线外, 还加入了伽马, 张力, 体积密度, 中子, 深中浅电阻率, 自然电位等 9 条测井曲线作为特征。利用的机器学习算法有线性回归、决策树、支持向量机、集成机器学习以及高斯处理等, 利用邻井的横波时差测井曲线用于训练和

验证学习预测模型。特征曲线的选择过程要尽可能依次选用与横波速度(v_s) 具有相关性的曲线。评价各种训练回归模型, 并模型的均方根误差(E_{RMS}) 是将预测值与各种模型的实际值进行比较计算出来的, 然后选择具有最小 E_{RMS} 为 2.6129 的高斯回归模型, 其原理是根据相同年代的地层具有相同的沉积环境, 具有相同或相似的声学、电学和核物理性质的原理, 通过对同一井除垮塌或仪器测量失效段以外的井段测井数据或邻井测井数据的学习, 预测出缺少段测井数据。或者从有横波数据的井段(邻井)学习出横波数据。图 19b 机器学习高斯回归的横波时差预测结果。

4.3 油藏监测

油藏监测模型更新通常花费时间长, 这将导致开发风险增加, 并可能造成经济上的重大损失。使用人工智能算法能解决了油藏含油饱和度的变化问题。应用模式地质匹配, 找到对应的地质层, 便于油藏模型更新油藏监测, 参数预测的问题解决。基于机器学习的匹配方法根据相同地质背景下的沉积环境具有相同的岩石物理特性的原理, 利用时间推移测井反映油藏的静态和动态状态。

4.4 地层真电阻率反演

在获取地层真电阻率时, 为克服正演模拟计算速度慢和受校正图版精度的影响, 机器学习替代了正演迭代过程。结合实际测井数据, 针对 11 种地层模型开展正演模拟, 利用机器学习建立相应的函数。对未知测井数据进行反演, 应用基于物理模拟和数据模型经过侵入、层厚以及围岩校正后的深侧向电阻率结果, 分别精度提升了 0.08%、1.15%、3.68%、1.03%、3.12%、4.72%、1.9%、0.15%、0.26%、3.22%、0.82%, 如图 19c 所示。

4.5 储层流体识别

传统的测井评价方法是首先通过划分岩性, 接着确定储层, 再计算含油饱和度, 最后确定流体性质。机器学习可以将地层厚度、电阻率、声波时差、中子孔隙、密度、自然伽马、总孔隙度、渗透率、含油饱和度、泥质含量、岩性等多个地球物理测井信号合并为输入数据, 可以大规模部署, 可实现同时进行储层和流体的分类评价, 得到的结果包括含气水层、差气层、水层, 干层, 气层、气水同层。本次学习样本数为 261 组, 验证样本为 52 组, 可识别 6 种储层流体类型。特征值包括储层层位、起始深度, 终止深度, 累计厚度, 储层厚度, 有效厚度, 最大电阻率, 平均电阻率, 最小电阻率, 最大声波时差, 平均声波时差, 最小声波时差, 最大中子孔隙度, 平均中子孔隙, 最小中子孔隙, 最大密度, 平均密度, 最小密度, 最大自然伽马, 平均自然伽马, 最小自然伽马, 最大总孔隙度, 平均总孔隙度, 最小总孔隙度, 最大渗透率,

平均渗透率,最小渗透率,最大含油饱和度,平均含油饱和度,最小含油饱和度,最大泥质含量,平均泥质含量,最小泥质含量,岩性。通过比较了各种机器学习算法,包括支持向量机,决策树,深度神经网络,集成提升法,贝叶斯分类和随机森林,最终选择使用支持向量机判断为最佳模型,正确率为 85.3%,具体结果见表 2。结果表明,对于存在不同类型的孔隙度和孔隙几何形状的储层,支持向量机具有出色的预测表现。图 19d 为储层流体类型识别混淆矩阵。

表 2 学习算法对储层流体识别的准确率对比
Table 2 Comparison of accuracy of learning algorithms in identifying reservoir fluids

算法	验证准确率/%
决策树	84.2
逻辑回归	84.6
提升树	84.9
支持向量机	85.3
SVM核函数	84.9
集成装袋	84.6

5 结语

(1) 基于对测井技术发展的深入分析,揭示了人工智能测井(AIL)作为第五代测井技术的发展趋势。AIL 技术,以测井大数据为依托,关键技术为核心,物理模型与智能算法为推动力,成功地从跨学科的角度解决了测井评价对象的复杂性和多属性问题。明确了 AIL 的定义,并根据 AI 技术的发展,阐明了其发展的三个阶段,为人工智能测井的未来发展奠定了坚实的基础和明确的方向。

(2) 构建了人工智能测井的体系生态。从声、电、核及核磁的统一场描述出发,结合测井大数据的特点和硬件算力的支撑,提出了“数据内存化、运算并行化、程序数据化和算法尺度化”的 AIL 系统设计思想,并设计了相应的系统架构。此外,还从大函数空间和知识挖掘的角度出发,提出了 7 种 AIL 学习算法,并分析了 8 种关键技术,实现了原理、系统、学习算法与测井知识发现模式的多学科交叉研究视角,构建了一个全面的人工智能测井技术生态体系。

(3) 通过测井大数据与人工智能测井的结合,利用 AIL 关键技术,实现了测井方法、仪器制造、数据采集、智能解释以及岩石物理等测井环节的数字化覆盖与处理。这些技术在复杂岩性识别、测井质量控制、油藏监测以及储层流体识别等勘探开发地质-工程问题中的应用,展现了 AIL 技术在解决实际问题中的巨大潜力。实证研究验证了 AIL 在致密砂岩岩性识别及测

井模拟中的优势,其精度明显高于传统方法,凸显了 AIL 技术的应用优势和发展潜力。

(4) 随着人工智能测井技术在理论方法、高精度智能化测井系统与技术、多源多学科数据融合的大数据挖掘等方面的提升,AIL 技术有望在油气田勘探开发的多场景中得到更广泛的应用推广。特别是,通过机器学习算法对测井数据进行特征提取与分类,深度学习以及测井大模型的开发及运用,将进一步推动 AIL 技术的创新与升级。此外,测井大数据的挖掘与老井挖潜也是 AIL 技术未来发展的重要方向。

(5) AIL 技术的测井作业将实现智能仪器在井场的自组装、数据采集与分析、以及包含解释结果与建议的报告自动生成,这将显著提升测井的精确度和效率。这些进步不仅为石油勘探与开发领域带来了革命性的变化,而且为油气工业的规模化推广提供了坚实的技术支撑,预示着人工智能测井技术将在未来发挥更加关键的作用。

符号注释:

$\Psi^{(i)}(r-r')$ 为井孔不同探测器位置的场量变化; $i=1, 2, 3, 4, 5$ 分别为电、磁、声、核磁弛豫以及粒子运输; $\frac{\partial}{\partial r} F$ 为随探测器位置的体或面或线变化; $G(\theta, E, E')$ 为反映地层属性、探测器效率、相态以及场能(态)变化; $\Phi(E')$ 为探测器最初位置或状态的初始场(能)态; E, E' 为时间 t 到 t' 场能(态)的变化; 对于电阻率测井, r, r' 为不同位置的电压; 对于中高频电磁测井, r, r' 为介质中传播的相位或幅度的变化; 对于声波测井, 为声波传播震动能量或波列传播时间的变化; 对于核磁测井, r, r' 为纵向、横向弛豫时间的变化; 对于核测井, r, r' 为射线强度或计数率或粒子衰变数的变化; k 为输出层节点数; h 为神经网络的假设输出函数; a_k 为第 k 项输出实际值; y_k 为第 k 项输出值, 其和为第 k 项输出的损失梯度; v_p 为纵波速度。

致谢: 作者在此感谢油气藏地质与开发国家重点实验室(西南石油大学)开放基金和国家自然科学基金项目对本研究的支持,也诚挚地感谢评审专家和编辑部给出详细中肯的意见和建议。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

参考文献(References)

- [1] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.

- [2] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven Earth system science[J]. *Nature*, 2019, 566(7743): 195–204.
- [3] BERGEN K J, JOHNSON P A, DE HOOP M V, et al. Machine learning for data-driven discovery in solid Earth geoscience[J]. *Science*, 2019, 363(6433): eaau0323.
- [4] 陈文超, 刘达伟, 魏新建, 等. 基于地震资料有效信息约束的深度网络无监督噪声压制方法[J]. *煤田地质与勘探*, 2021, 49(1): 249–256.
CHEN Wenchao, LIU Dawei, WEI Xinjian, et al. Unsupervised noise suppression method for depth network seismic data based on prior information constraint[J]. *Coal Geology & Exploration*, 2021, 49(1): 249–256.
- [5] 陈文超, 陈昕, 王伟, 等. 基于波形特征稀疏化建模的地震信号表示理论与方法[J]. *石油物探*, 2018, 57(1): 39–44.
CHEN Wenchao, CHEN Xin, WANG Wei, et al. Seismic signal analysis based on waveform diversity enabled sparse representation[J]. *Geophysical Prospecting for Petroleum*, 2018, 57(1): 39–44.
- [6] 马坚伟. 压缩感知走进地球物理勘探[J]. *石油物探*, 2018, 57(1): 24–27.
MA Jianwei. Compressive sensing in geophysical exploration[J]. *Geophysical Prospecting for Petroleum*, 2018, 57(1): 24–27.
- [7] YU Siwei, MA Jianwei. Deep learning for geophysics: Current and future trends[J]. *Reviews of Geophysics*, 2021, 59(3): <https://doi.org/10.1029/2021RG00074>.
- [8] ORELLANO Y, VARGAS M, BENITEZ J J. Solution for anomaly detection in oil & gas well drilling sensors based on recurrent Neural Networks: A big data approach[C]//Proceedings of the 2023 Latin America Unconventional Resources Technology Conference. Buenos Aires, Argentina. Tulsa, OK, USA: American Association of Petroleum Geologists, December 4–6, 2023.
- [9] 程希, 程宇雪, 程佳豪, 等. 基于机器学习与大数据技术的地球物理测井系统[J]. *西安石油大学学报(自然科学版)*, 2019, 34(6): 108–116.
CHENG Xi, CHENG Yuxue, CHENG Jiahao, et al. Geophysical logging system based on machine learning and big data technology[J]. *Journal of Xi'an Shiyou University (Natural Science Edition)*, 2019, 34(6): 108–116.
- [10] 赵丽莎, 史永彬, 金玮, 等. 基于梦想云的测井智能化解释应用研究[J]. *中国石油勘探*, 2020, 25(5): 97–103.
ZHAO Lisha, SHI Yongbin, JIN Wei, et al. Application research on intelligent logging interpretation based on E & P Dream Cloud[J]. *China Petroleum Exploration*, 2020, 25(5): 97–103.
- [11] 匡立春, 刘合, 任义丽, 等. 人工智能在石油勘探开发领域的应用现状与发展趋势[J]. *石油勘探与开发*, 2021, 48(1): 1–11.
KUANG Lichun, LIU He, REN Yili, et al. Application and development trend of artificial intelligence in petroleum exploration and development[J]. *Petroleum Exploration and Development*, 2021, 48(1): 1–11.
- [12] 杜金虎, 时付更, 杨剑锋, 等. 中国石油上游业务信息化建设总体蓝图[J]. *中国石油勘探*, 2020, 25(5): 1–8.
DU Jinhui, SHI Fugeng, YANG Jianfeng, et al. Overall blueprint of information construction of PetroChina upstream business[J]. *China Petroleum Exploration*, 2020, 25(5): 1–8.
- [13] 石玉江, 王娟, 魏红芳, 等. 基于梦想云的油气藏协同研究环境构建与应用[J]. *中国石油勘探*, 2020, 25(5): 15–22.
SHI Yujiang, WANG Juan, WEI Hongfang, et al. Construction and application of oil and gas reservoir collaborative research environment based on E & P Dream Cloud[J]. *China Petroleum Exploration*, 2020, 25(5): 15–22.
- [14] 程希, 宋新爱, 李国军. 人工智能测井的发展现状及趋势[C]//中国石油学会测井专业委员会年会论文集, 2020.11.
- [15] 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 Xi, ZHOU Jun, FU Haicheng, et al. Applicability and application of machine learning algorithm in logging interpretation[J]. *Northwestern Geology*, 2023, 56(4): 336–348.
- [16] MOHAMED I M, MOHAMED S, MAZHER I, et al. Formation lithology classification: Insights into machine learning methods[C]//P Society of Petroleum Engineers. the SPE Annual Technical Conference and Exhibition. 30 September–2 October, 2019, Calgary, Alberta, Canada, doi: <https://doi.org/10.2118/196096-MS>.
- [17] LIANG Yu, ZHAO Peidong. A machine learning analysis based on big data for eagle ford shale formation[C]//Society of Petroleum Engineers. The SPE Annual Technical Conference and Exhibition. 30 Sep–2 October 2019, Calgary, Alberta, Canada, doi: [10.2118/196158-MS](https://doi.org/10.2118/196158-MS).
- [18] ASALA H I, CHEBEIR J A, MANEE V, et al. An integrated machine-learning approach to shale-gas supply-chain optimization and refrac candidate identification[C]//Society of Petroleum Engineers. The SPE Annual Technical Conference and Exhibition. 9–11 October 2017, San Antonio, Texas, USA, 2017: 1201–1224. doi: [10.2118/187361-PA](https://doi.org/10.2118/187361-PA).
- [19] BENNIS M, TORRES-VERDÍN C. Estimation of dynamic petrophysical properties from multiple well logs using machine learning and unsupervised rock classification[C]//Society of Petroleum Engineers. SPWLA 60th Annual Logging Symposium. June 15–19, 2019, The Woodlands, TX, USA, doi: [10.30632/T60ALS-2019_KKKKK](https://doi.org/10.30632/T60ALS-2019_KKKKK).
- [20] GUEVARA J, ZADROZNY B, BUORO A, et al. A machine-learning methodology using domain-knowledge constraints for well-data integration and well-production prediction[C]//Society of Petroleum Engineers. SPE Reservoir Evaluation & Engineering. 2019: 1185–1200. doi: [10.2118/195690-PA](https://doi.org/10.2118/195690-PA).
- [21] GUPTA I, DEVEGOWDA D, JAYARAM V, et al. Machine learning regressors and their metrics to predict synthetic sonic and brittle zones[C]//American Association of Petroleum Geologists. The Unconventional Resources Technology Conference. 22–24 July 2019, Denver, Colorado, USA. Tulsa, OK, USA, doi: [10.15530/urtec-2019-0148](https://doi.org/10.15530/urtec-2019-0148).
- [22] KUVICHKO A, SPESIVTSEV P, ZYUZIN V, et al. Field-scale automatic facies classification using machine learning algorithms[C]//Society of Petroleum Engineers. The SPE Russian Petroleum Technology Conference. 22 – 24 October 2019, Moscow, Russia, doi: [10.2118/196860-MS](https://doi.org/10.2118/196860-MS).
- [23] Enhanced reservoir geosteering and geomapping from refined models of ultra-deep lwd resistivity inversions using machine-

- learning algorithms[C]//the Society of Petrophysicists and Well Log Analysts. SPWLA 60th Annual Logging Symposium. June 15-19, 2019, The Woodland, TX, USA, doi: [10.30632/T60ALS-2019_EE](https://doi.org/10.30632/T60ALS-2019_EE).
- [24] MUKHERJEE T, BURGETT T, GHANCHI T, et al. Predicting gas production using machine learning methods: A case study[C]//SEG International Exposition and 89th Annual Meeting. 2019, San Antonio, Texas. Society of Exploration Geophysicists, 2019: 2248-2251. doi:[10.1190/segam2019-3215692.1](https://doi.org/10.1190/segam2019-3215692.1).
- [25] BRAZELL S, BAYEH A, ASHBY M, et al. A machine-learning-based approach to assistive well-log correlation[J]. *Petrophysics*, 2019, 60(4): 469-479.
- [26] HUSSAIN S A, CHATTERJEE C, SARKAR S K, et al. Predicting horizontal shear slowness- A machine learning approach[C]//Society of Petroleum Engineers. The Abu Dhabi International Petroleum Exhibition & Conference. Day 2 Tue, November 12, 2019. Abu Dhabi, UAE. SPE, 2019: SPE-197128-MS.
- [27] VALLABHANENI S, SARAF R, PRIYADARSHY S. Machine-learning-based petrophysical property modeling[C]//Society of Petroleum Engineers. The SPE Europec featured at 81st EAGE Conference and Exhibition. Day 3 Wed, June 05, 2019. London, England, UK. SPE, 2019: SPE-195436-MS.
- [28] LI Xuechen, MA Xinfang, XIAO Fengchao, et al. Intelligence-driven prediction of shear wave velocity based on gated recurrent unit network[C]//American Rock Mechanics Association. The 56th US Rock Mechanics/Geomechanics Symposium. June 2022, Santa Fe, New Mexico, 2022: 0358.
- [29] ORIYOMI R, WEN P, CARLOS T-V, et al. Best practices in automatic permeability estimation: machine-learning methods vs. conventional petrophysical models[C]// the Society of Petrophysicists and Well Log Analysts. SPWLA 64th Annual Logging Symposium, June 10-14, 2023, Lake Conroe, TX, USA, doi: [10.30632/SPWLA-2023-0084](https://doi.org/10.30632/SPWLA-2023-0084).
- [30] GABRIELA F, GUSTAVO G. Geotechnical parameters prediction from geophysical logging data using supervised learning methods[C]//15th ISRM Congress 2023 & 72nd Geomechanics Colloquium. October 9, 2023 - Saturday, October 14, 2023 Venue: Salzburg Congress, Salzburg, Austria, 2023: 959-963.
- [31] LEI Fu, YU Yanxiang, XU Chicheng, et al. Well-log-based reservoir property estimation with machine learning: a contest summary[J]. *Petrophysics*, 2024, 65(1): 108-127.
- [32] BATAEE M, AL-JARMOUZI A H, SHAHBAZI A, et al. A new approach in reservoir characterization using artificial intelligence[C]//the Offshore Technology Conference. 1 - 4 May, 2023, Houston, TX, USA, 2023: OTC-32602-MS. doi: [10.4043/32602-MS](https://doi.org/10.4043/32602-MS).
- [33] S MOHD SHAH J, MOHAMAD ZULKIFLI N F, FADHIL M I M, et al. Delving into Artificial Intelligence World: Pioneering machine learning platforms to predict reservoir properties[C]//the Offshore Technology Conference. February 2024, Asia, Kuala Lumpur, Malaysia, doi:[10.4043/34782-MS](https://doi.org/10.4043/34782-MS).
- [34] 李宁, 刘英明, 王才志, 等. 大庆油田 CIFLog 测井数智云平台建设应用实践[J]. *大庆石油地质与开发*, 2024, 43(3): 17-25.
LI Ning, LIU Yingming, WANG Caizhi, et al. Construction and application of CIFLog logging digital-intelligent cloud platform in Daqing Oilfield[J]. *Petroleum Geology & Oilfield Development in Daqing*, 2024, 43(3): 17-25.
- [35] 熊文君, 肖立志, 袁江如, 等. 基于深度强化学习的测井曲线自动深度校正方法[J]. *石油勘探与开发*, 2024, 51(3): 553-564.
XIONG Wenjun, XIAO Lizhi, YUAN Jiangru, et al. Automatic depth correction method of logging curve based on depth reinforcement learning[J]. *Petroleum Exploration and Development*, 2024, 51(3): 553-564.
- [36] LEVINE H, TU Yuhai. Machine learning meets physics: A two-way street[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2024, 121(27): doi/[10.1073/pnas.2403580121](https://doi.org/10.1073/pnas.2403580121).

(责任编辑 聂爱兰)