



ELSEVIER

Contents lists available at ScienceDirect

Engineering

journal homepage: www.elsevier.com/locate/eng

Research
Unconventional and Intelligent Oil & Gas Engineering—Perspective

智能石油工程

Mohammad Ali Mirza , Mahtab Ghoroori * , Zhangxin Chen *

Department of Chemical and Petroleum Engineering, University of Calgary, Calgary, AB T2N 1N4, Canada

ARTICLE INFO

Article history:

Received 9 December 2021

Revised 1 May 2022

Accepted 17 June 2022

Available online 19 July 2022

关键词

人工智能
机器学习
智能油藏工程
文本挖掘
智能地球科学
智能钻探工程

摘要

数据驱动方法和人工智能(AI)算法比基于物理的方法更有前景,前者主要来源是数据,这是每个现象的基本要素。这些算法从数据中学习并揭示看不见的模式。这项新技术对每秒产生大量数据的石油行业具有重要意义。由于石油和天然气行业正处于向油田数字化的过渡阶段,在不同的石油工程挑战中,集成数据驱动建模和机器学习(ML)算法的动力越来越大。ML已广泛应用于工业的不同领域。人们已开展大量的研究,探索AI在该行业各个学科中的适用性。然而,这些研究缺乏两个主要特征,大多数研究要么不够实用,不适用于实际领域的挑战,要么仅限于特定问题,无法推广。必须注意数据本身及其分类和存储方式。尽管有大量来自不同学科的数据,但它们都被存储在部门的数据库中,消费者无法访问。为了从数据中获取尽可能多的信息,需要将数据存储在一个集中的数据库中,不同的应用程序可以从中方便地使用这些数据。

© 2022 THE AUTHORS. Published by Elsevier LTD on behalf of Chinese Academy of Engineering and Higher Education Press Limited Company. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. 引言

人工智能(AI)试图模仿人类的决策。被称为机器学习(ML)的AI技术子集使计算机能够通过使用外部数据,学习如何在其编程行为的限制之外采取行动。ML已彻底改变无数行业和研究领域,从股票市场分析到自动驾驶汽车行业,其应用范围极其广泛。随着物联网(IoT)设备和大数据(高速生成大量、不同种类的数据)的出现,ML是确保从大数据中获取可执行信息的最重要技术之一。

在石油和天然气行业,模型类型分为三大类:物理模型、数学模型和经验模型[1]。物理模型是对象的按比例缩小或放大版本,开发物理模型是为了简化对物理对象或场景的外观或操作方式的认识。这些模型具有开发成本

高、耗时长的缺点,并且在某些情况下可能不够准确。根据实验建立了经验模型,经验模型会出现各种误差,如人为误差和测量误差,并且无法归纳。数学模型对物理定律进行编码,以模拟基础物理学;然而,它们需要许多假设和简化[1]。为了应对这三种模型所面临的挑战、获取信息,并及时做出明智的决策,需要一种更有前景的技术。这就是ML可以应用之处,一是因为该技术能够从庞大数据集中获取信息并对该信息采取行动,而这些信息永远无法通过纯编程程序进行处理;二是因为数据与从数据中获取的信息之间的关系非常复杂。

石油和天然气行业正在迅速向油田数字化转型,人们越来越倾向于将数据驱动建模和ML算法应用于应对各种石油工程挑战。数据驱动建模使用从数据分析中导出的数

* Corresponding authors.

E-mail addresses: mahtab.ghoroori@ucalgary.ca (M. Ghoroori), zhachen@ucalgary.ca (Z. Chen).

学方程，而不是知识驱动建模。在知识驱动建模中，逻辑是用于表示理论的主要工具[2–3]。虽然可能有不从数据中学习的数据驱动算法（因此不能称为ML），但ML是数据驱动方法的一个子集，该方法展示了AI的一种形式。图1总结了不同类型的ML算法。

ML已广泛应用于石油工业的不同领域，包括地球科学、油藏工程、生产工程和钻井工程。接下来的4节将对ML在这些领域的应用进行批判性的回顾和展望。

1.1. 智能地球科学

早在20世纪60年代，地球科学已经开始利用决策树、马尔可夫链和K均值聚类等算法。马尔可夫链已用于沉积

学[4]、水文学[5]和测井分析[6]。Preston和Henderson [7]使用K均值聚类来解释泥沙沉积的周期性。决策树的早期应用可以在经济地质学和透视映射中查到[8–9]。由于多种因素，包括缺乏计算能力和该领域的不成熟，采用ML未能完全满足最初的期望；因此，AI在20世纪70年代几乎没有得到发展。Zhao和Mendel [10]在20世纪80年代采用递归神经网络（NN）进行地震反褶积，至此，人们对AI的兴趣又重新兴起。ML从知识驱动转变为数据驱动发生在20世纪90年代，当时McCormack [11]发表了地球物理中关于NN的首篇综述。McCormack的综述探索了模式识别，并总结了过去30年来NN的应用，以及地震道编辑

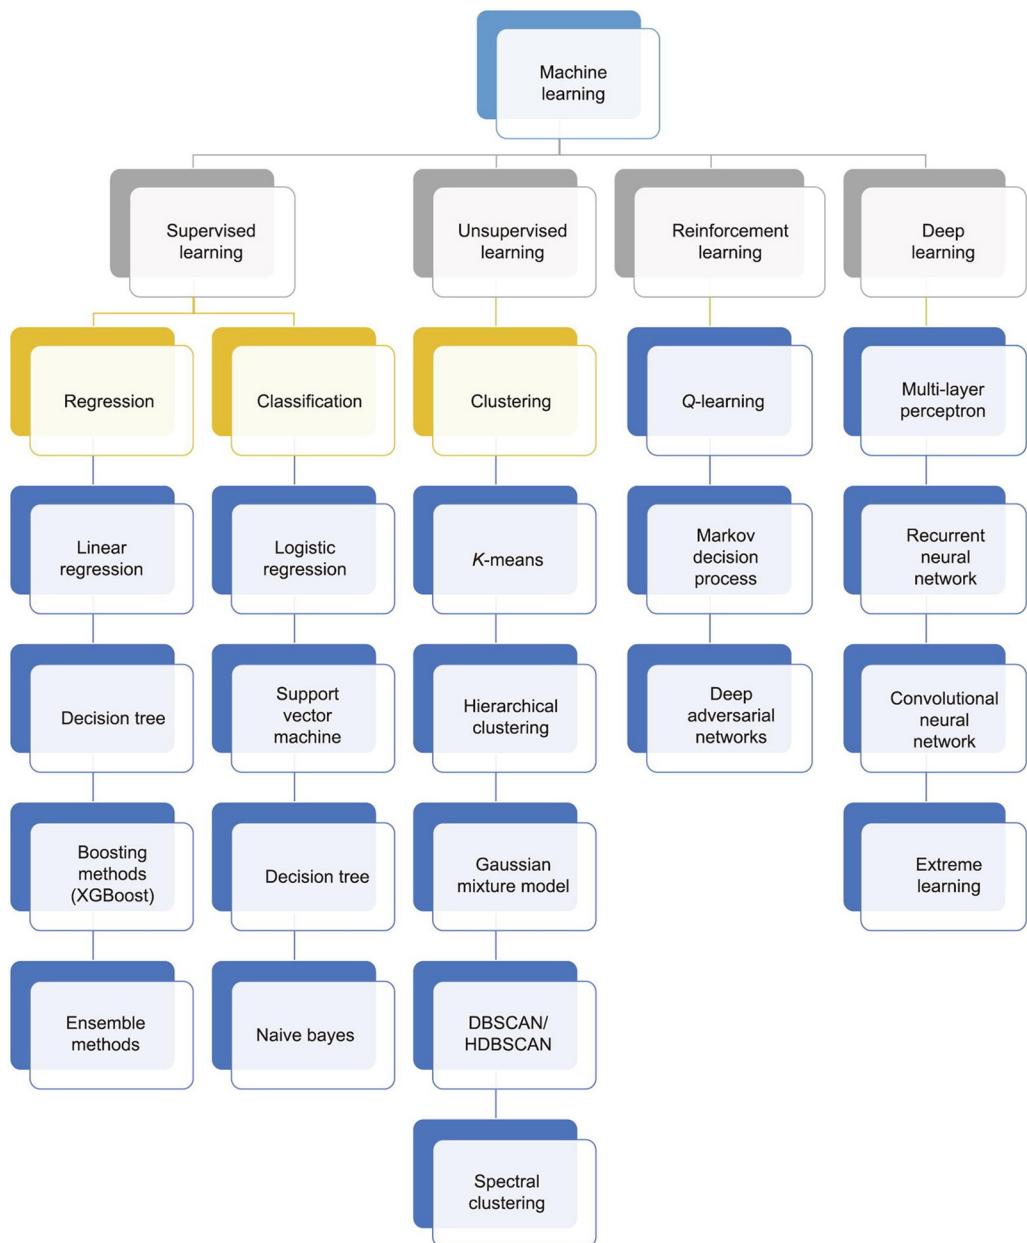


图1. 不同类型的ML算法。DBSCAN：基于密度的噪声应用空间聚类；HDBSCAN：基于层次密度的噪声应用空间聚类。

和自动测井分析的应用样本。深度学习 (DL) 和卷积神经网络 (CNN) 在 21 世纪 10 年代得到复兴, 当时 Walde-land 和 Solberg [12] 将小型 CNN 应用于地震数据以进行盐识别。断层解释[13–15]、层位选取[16]和岩相分类[17–18]是 CNN 在地球科学中的其他应用。Mosser 等[19]应用了生成式对抗网络 (GAN), 即 ML 模型, 其中两个 NN 竞争性地协同工作, 以在地球科学早期进行更准确的预测, 从而对三维 (3D) 多孔介质进行孔隙尺度建模。GAN 还用于地震记录生成和地质统计反演[20]。

地震活动是地球科学中的另一个重要领域, ML 在其中得到了广泛应用。Mousavi 等[21]使用 ML 算法, 根据地面接收器上记录的波形特征, 区分深部微地震事件和浅部微地震事件。He 等[22]使用 ML 算法来改进诱发地震事件的风险管理。他们提出的模型是一组简单的闭式表达式, 具有透明度高、执行速度快的优点, 为操作员提供了最大的成功可能性。采矿、油气田枯竭、废水注入和地热作业等工业活动会诱发地震[23–24]。在加拿大西部, 水力压裂 (HF) 引发的地震活动受到了公众和学术界的关注[25]。由于强烈耦合的地质力学、地球物理和地质行为带来的复杂性, 研究诱发地震活动与 HF 之间的相关性一直是一项极具挑战性的工作。因此, ML 在地震活动中的应用仍存在很大的探索空间。

1.2. 智能油藏工程

ML 算法常用于油藏工程的各个领域, 特别是在油藏表征和压力、体积和温度 (PVT) 计算方面。Gharbi 和 Elsharkawy [26] 开发了一个双层 NN, 用于估计油层的泡点压力和地层体积系数。在另一项研究中, 采用径向基函数和多层次感知器 NN 来估计地层体积系数、等温压缩性和盐水含盐量[27]。Wang 等[28]在组成油藏模拟中使用人工神经网络 (ANN) 进行相平衡计算, 包括相稳定性测试和相分裂计算。将两种方法, 即支持向量机 (SVM) 和模糊逻辑相结合, 使用实际测井作为输入, 预测渗透率和孔隙度[29]。Patel 和 Chatterjee [30] 利用分类算法进行快速准确的岩石分类 (即根据相似性将储油岩分为不同类别)。在随机噪声存在的情况下, An [31] 探索了具有单个隐藏层的 ANN 的性能, 以建立预测低速层厚度的模型。该方法还被用于加拿大阿尔伯塔省北部的一个油田, 以构建孔隙度净产层厚度分布图。据该分布图, 钻了四口井, 油田产量增加了近 20% [32]。Jamialahmadi 和 Javadpour [33] 利用径向基函数 NN, 使用深度测量和岩心数据的孔隙度作为输入, 估算伊拉克共和国南部整个油田的渗透率。Wang 等[34]开发了一个集成 ML 模型 (即随机森林算法),

以使用结构复杂且高度断裂的海上油田的实际生产和注入数据作为主要输入, 预测井位的延时饱和度剖面。通过引入极限学习机 (ELM), 开发了一个用于预测多个储层参数 (即孔隙度、饱和度、岩相和页岩含量) 的新框架, 这是最先进的 ML 技术之一[35]。与典型的单层前馈 NN 方法相比, 该方法在不牺牲精度的情况下, 需要的计算资源和训练时间更少。

1.3. 智能生产工程

生产预测/优化和 HF 是能源行业中 ML 日益流行的另外两个领域。生产预测和优化必须考虑许多参数, 包括采油工艺、支撑剂类型、井距、处理速度和压裂阶段数。尽管操作参数优化可以节省数百万美元, 并显著提高非常规油藏产量, 但传统的油藏模拟计算成本高昂, 在考虑油藏特征的不同变化的情况下, 计算成本会增加[36–37]。因此, 产量预测和优化是 AI 应用的良好候选领域, 如最近开发和分析的用于各种开采工艺 (如水和化学剂驱油以及蒸汽注入[38–40]) 的 ML 算法所示。Dang 等[41]利用 NN 对相对渗透率进行多维插值, 以克服混合开采过程中不同参数 (即聚合物、表面活性剂和盐度) 的影响。使用地质、岩心和测井数据对不同储层中的井进行产量预测, 是 ML 算法广泛用于该领域的应用[42–43]。Tadjer 等[44]利用 DeepAR 和 Prophet (时间序列 ML 算法) 作为短期油气井预测递减曲线分析的替代方案。使用 NN 预测垂直井的井底压力 (生产设施设计的关键参数) 是 ML 在该领域的另一个应用[45]。运用长短期记忆 (LSTM) 模型和特征选择方法预测加拿大 Duvernay 页岩气井的日产量[46]。Popa 和 Connell [47] 通过将模糊逻辑和 NN 相结合进行地层性能评估, 研究了水平井位优化。

在过去 20 年中, HF 工作的数量不断增加, 产生了大量可用于构建 ML 预测模型的测量数据。Mohaghegh [48] 进行了一项使用模糊逻辑聚类分析绘制 Utica 页岩天然裂缝网络的研究。He 等[49]利用 AI 和模糊逻辑分析, 开发了一种优化页岩气储层 HF 设计的模型。使用 SVM 开发了一种用于确定粗糙岩石水力开度的新模型[50]。Yang 等[51]建立了一种数据分析方法, 该方法将由声波测井得出的设计参数与压裂后分析得出的设计参数相结合, 用于优化压裂处理设计。通过使用生产测井仪数据和沿 Marcellus 页岩储层水平井的深剪切波成像, 验证了所获得的压裂优化算法。Wang 和 Sun [52]提出了一种将 ML、储层模拟和 HF 相结合的综合方法, 用于优化二叠纪页岩中的井距, 并考虑了该大区域每个代表性区域的典型井。Bangi 和 Kwon [53]应用强化学习算法达到了沿裂隙的均匀支撑

剂浓度，从而提高HF生产率；研究人员将降维与迁移学习相结合，以加快学习过程。Duplyakov等[54]提出了一种基于升压算法和岭回归组合的模型，用于预测多级压裂完井的累积产油量。对加拿大阿尔伯塔省Montney地层的74口HF井进行了案例研究，以井间距、岩石力学特性和完井参数作为输入特征，预测5年内的累积产量剖面[55]。利用基于产量、完井和HF数据的深度NN作为输入特征，开发了一个用于预测页岩储层累积天然气产量的代理模型；使用Montney地层中1239口水平井的现场数据验证了该模型[56]。

1.4. 智能钻探工程

考虑钻井作业期间每天都会产生大量的实时数据，钻井工程也从ML的应用中受益匪浅。由于近年来油价不稳定，人们一直在寻求如何在各种价格方案中确保良好的经济性。为了实现这一目标，ML已经变得越来越普遍，以及时缓解钻井挑战。钻井作业优化和卡钻预测是钻井工程中最关键的两个领域，人们经常使用AI进行研究。Mohaghgh [57]利用ANN及时识别钻井异常及其相关非生产时间（NPT）。Unrau等[58]开发了ML模型，用来确定实时报警阈值，以便在钻井作业期间检测流速和泥浆体积数据的异常。该模型有助于早期检测井漏，并最大程度地减少错误报警。Pollock等[59]应用强化学习算法，基于二叠纪和阿巴拉契亚盆地的14口水平井，改进预训练NN。改进后的模型将曲折度和计划轨迹偏差降至最低，误差小于3%。Zhao等[60]应用ML算法得出不同钻井参数的趋势，用于识别异常事件并提出相应的补救措施。已尝试使用钻压、流速和每分钟转数等钻井特征，将ML算法应用于优化钻速（ROP）[61]。Goebel等[62]通过对钻速、管道旋转、倾斜角度和流速等各种参数进行监测和研究，开发了一种ML模型来预测未来的卡钻管柱。一年后，Dursun等[63]提出了钻井期间的实时风险预测。将ML算法与数据挖掘和自然语言处理（NLP）技术相结合，在极短的时间内调查中东地区两个陆上油田的每日钻井报告（DDR），以便对生产和NPT进行分类，并发现NPT的关键影响因素[64]。

2. 挑战和机遇

ML算法可以非常有效地用来解决三种主要类型的问题：为已了解的问题构建替代模型，以降低计算成本；为需要人为干预和知识分析的问题建立ML模型；为以前无法解决的复杂问题建立ML模型。在环境简单、数据容易

获取且决策成本不昂贵的领域，ML能够最快地取得成功。尽管石油工业中使用ML的大多数情况不符合这几类问题中的任何一个[因为环境通常是各种各样的，决策成本是昂贵的（如钻井），数据是分散的]，但通过有效运用ML投资长期收益可以提供大量价值，不过需要周密的设计，并与领域专家高度合作[65]。

将ML算法应用于石油工程问题需要克服各种挑战。一项挑战是，数据量往往很大（即大量数据），数据种类（即许多不同的数据格式）和真实性（即数据不一致、不准确）繁多，且速度快（即数据流入率高）。石油工业操作设备上安装的井下和地面传感器每天都会产生大量的数据。该行业利用结构化和非结构化数据来跟踪生产、安全和维护。获取石油行业的准确数据通常很困难或不可能，而且可能很昂贵。因此，获取足够数量的高质量数据用于培训和验证ML模型是石油行业面临的普遍挑战，这会导致训练数据出现不确定性和噪声。反过来，这些问题会损害ML模型的通用性和准确性。此外，原始数据通常不适合ML算法，需要进行预处理和清洗。地下不确定性和数据处理时间延误也是重要的考虑因素。此外，此类数据通常存在于各部门的小数据库中，由于保密问题和竞争优势，相应的模型要么没有，要么不向其他人开放。这一问题在学术环境中尤为普遍[65]。此外，模型的可解释性对地球科学很重要，因为知道导致结果的原因与知道结果本身同样重要。

或许由于上述挑战，ML在地球科学领域的应用并没有像在许多其他领域那样得到迅速发展。尽管ML是一种很有前途的技术，可以利用大数据发现输入-输出关系并得出信息，但ML的性能可能会因数据的高维性而受到影响。这可能导致误导性的相关性以及不切实际和不可靠的聚类。值得注意的是，数据在其初始状态下通常是模棱两可的，因此，需要不同的预处理技术来识别显著特征并使ML模型能够学习系统的行为。存在一个风险，即缺少数据和缺乏系统稳定性可能会将偏差引入ML模型中，使模型难以从数据中提取有益知识[66]。此外，应考虑利用不同来源数据的问题和挑战。与数据相关的隐私、安全和道德也是需要考虑的非常重要的方面。混合建模集成了ML算法与基于物理的方法，可以被认为是缓解上述问题的一种方法。此外，迁移学习是一种相对较新的ML技术，在地球科学领域具有良好前景。其中使用预训练模型作为起点，然后通过考虑自己的训练数据在预训练模型上进行模型训练。

3. 展望

ML的潜力在石油工业油藏模拟和文本挖掘这两个领

域尚未得到充分利用。油藏模拟涉及可充分说明物理性质随时间和空间而变化的微分方程 (DE)，因此有助于描述自然界中的物理现象。科学和工程中有许多问题，需要解决复杂的 DE。然而，DE 非常难解决，其相关模拟极其复杂且计算量大。这种复杂程度要求使用巨型计算机进行模拟，并也说明这一领域研究人员对 AI 的兴趣是合理的。DL 包含具有多个隐藏层的 NN，利用 DL 是一种很有前途的技术，可以加快 DE 的求解速度，节省科学家和工程师大量的时间和精力。加利福尼亚理工学院 (Caltech) 的研究人员引入了一种新的 DL 技术来求解 DE，该技术比传统 DL 算法更准确、更通用，并且速度快 1000 倍[67]。这种新方法基于在傅里叶空间而不是传统 DL 中的欧几里得空间中定义输入和输出。这一进步不仅减少了对超级计算机的依赖，还将提高计算能力，以有效地模拟更复杂的问题。

石油行业刚刚开始利用 ML 的技术进行智能报告并从文本中提取信息。每日钻井和完井报告是行业中两种主要的文本文件，这些文件包含重要文本以及各种其他类型的数据，如深度、套管尺寸、井眼尺寸和射孔深度。NLP 和 DL 算法可用来开发用于作业自动化质量控制和性能改进的模型，可提供更有效率的方法，远超依赖专家专业知识的传统方法[68]。一些研究调查了石油行业中的文本处理，重点关注了风险管理和服务预测用运算数据的文本挖掘[69]、基于报告的上下文分析的生产指标和模式识别[70–71]，以及报告分类[71]等主题。尽管文献中包含了使用文本挖掘技术缓解行业中基于文本的挑战等研究，但 ML 在这一领域仍有巨大潜力，必须对 ML 进行进一步探索。

4. 结论

数据驱动的方法和 AI 算法有足够的前景，有朝一日它们可能比基于物理的方法更可靠。它们的主要来源是数据，这是每个场景的基本要素。这些算法可学习数据并揭示看不见的模式。在石油行业内，人们对利用这项技术从每秒生成的大量数据中获取信息非常感兴趣。许多研究探索了 AI 在该行业各个分支学科的适用性；然而，明显缺乏两个主要特征。也就是说，关于这一主题的大多数研究要么不够实用，不适用于实际领域的挑战，要么仅限于特定问题，不可推广。必须注意数据本身以及数据的分类和存储方式。尽管有大量的由不同学科产生的数据，但它们仍然存在于部门的小数据库中，其他人员无法访问。为了从数据中获取尽可能多的信息，数据必须存储在一个集中

的数据库中，不同的应用程序可以从中方便地使用数据。在数据采集后以及在运用 AI 和 ML 技术之前，必须对数据进行处理，以便有效地提取特征并确保数据能够有效地支持算法。尽管 AI 和 ML 技术在石油和油藏工程领域越来越重要，但它们只是整体系统的一部分。为了确保该系统能够提供价值，将算法应用于这一具有挑战性的领域还需要仔细考虑，并且必须提供正确类型、质量和数量的数据，然后对数据进行有效处理，以取得预期结果。因此，尽管 AI 是有效管理世界地下资源的关键工具，但数据是充分利用这些可能性的关键。

Compliance with ethics guidelines

Mohammad Ali Mirza, Mahtab Ghoroori, and Zhangxin Chen declare that they have no conflict of interest or financial conflicts to disclose.

References

- [1] Noshi CI, Schubert JJ. The role of machine learning in drilling operations: a review. In: Proceedings of the SPE/AAPG Eastern Regional Meeting; 2018 Oct 7–11; Pittsburgh, PA, USA. Richardson: OnePetro; 2018.
- [2] Solomatine DP, Ostfeld A. Data-driven modelling: some past experiences and new approaches. *J Hydroinform* 2008;10(1):3–22.
- [3] Dubois D, Hájek P, Prade H. Knowledge-driven versus data-driven logics. *J Logic Lang Inform* 2000;9(1):65–89.
- [4] Schwarzacher W. The semi-Markov process as a general sedimentation model. In: Merriam DF, editor. *Mathematical models of sedimentary processes: an international symposium*. Boston: Springer; 1972. p. 247–68.
- [5] Matalas NC. Mathematical assessment of synthetic hydrology. *Water Resour Res* 1967;3(4):937–45.
- [6] Agterberg FP. Markov schemes for multivariate well data. In: *Proceedings of the International Symposium on the Application of Computers and Operations Research in the Mineral Industry*. Pennsylvania: Pennsylvania State University; 1966.
- [7] Preston FW, Henderson J. Fourier series characterization of cyclic sediments for stratigraphic correlation. In: Merriam DF, editor. *Proceedings of the Symposium on Cyclic Sedimentation*. Kansas: Geological Survey; 1964. p. 415–25.
- [8] Newendorp PD. Decision analysis for petroleum exploration. Tulsa: PennWell Books; 1976.
- [9] Reddy RKT, Bonham-Carter GF. A decision-tree approach to mineral potential mapping in Snow Lake Area. *Manitoba Can J Rem Sens* 1991;17(2):191–200.
- [10] Zhao X, Mendel JM. Minimum-variance deconvolution using artificial neural networks. In: *SEG technical program expanded abstracts 1988*. Houston: SEG Library; 1988.
- [11] McCormack MD. Neural computing in geophysics. *Lead Edge* 1991; 10(1): 11–5.
- [12] Waldegaard AU, Solberg AHSS. Salt classification using deep learning. In: *Proceedings of the 79th EAGE conference and exhibition 2017*; 2017 Jun 12–15; Paris, France; 2017.
- [13] Araya-Polo M, Dahlke T, Frogner C, Zhang C, Poggio T, Hohl D. Automated fault detection without seismic processing. *Lead Edge* 2017;36(3):208–14.
- [14] Guitton A. 3D convolutional neural networks for fault interpretation. In: *Proceedings of the 80th EAGE conference and exhibition 2018*; 2018 Jun 11–14; Copenhagen, Denmark; 2018.
- [15] Purves S, Alaei B, Larsen E. Bootstrapping machine-learning based seismic fault interpretation. In: *Proceedings of the AAPG Annual Convention and*

- Exhibition; 2018 May 20–23; Salt Lake City, UT, USA; 2018.
- [16] Wu H, Zhang B. Semi-automated seismic horizon interpretation using encoder-decoder convolutional neural network. In: SEG technical program expanded abstracts 2019. Houston: SEG Library; 2019.
- [17] Chevitarese DS, Szwarcman D, Gama e Silva RM, Vital Brazil E. Deep learning applied to seismic facies classification: a methodology for training. In: Proceedings of the European Association of Geoscientists & Engineers, Saint Petersburg 2018; 2018 Apr 9–12; Saint Petersburg; 2018. p. 1–5.
- [18] Dransch JS, Lüthje M. Deep-learning seismic facies on state-of-the-art CNN architectures. In: SEG technical program expanded abstracts 2018. Houston: SEG Library; 2018.
- [19] Mosser L, Dubrule O, Blunt MJ. Reconstruction of three-dimensional porous media using generative adversarial neural networks. *Phys Rev E* 2017; 96(4): 043309.
- [20] Laloy E, Héroult R, Jacques D, Linde N. Training-image based geostatistical inversion using a spatial generative adversarial neural network. *Water Resour Res* 2018; 54(1): 381–406.
- [21] Mousavi SM, Horton SP, Langston CA, Samei B. Seismic features and automatic discrimination of deep and shallow induced-microearthquakes using neural network and logistic regression. *Geophys J Int* 2016; 207(1): 29–46.
- [22] He M, Li Q, Li X. Injection-induced seismic risk management using machine learning methodology—a perspective study. *Front Earth Sci* 2020; 8: 227.
- [23] Mahani AB, Schultz R, Kao H, Walker D, Johnson J, Salas C. Fluid injection and seismic activity in the northern Montney play, British Columbia, Canada, with special reference to the 17 August 2015 M w 4.6 induced earthquake. *Bull Seismol Soc Am* 2017; 107(2): 542–52.
- [24] Ellsworth WL. Injection-induced earthquakes. *Science* 2013; 341(6142): 1225942.
- [25] Atkinson GM, Eaton DW, Ghofrani H, Walker D, Cheadle B, Schultz R, et al. Hydraulic fracturing and seismicity in the western Canada sedimentary basin. *Seismol Res Lett* 2016; 87(3): 631–47.
- [26] Gharbi RB, Elsharkawy AM. Universal neural network based model for estimating the PVT properties of crude oil systems. In: Proceedings of the SPE Asia Pacific Oil and Gas Conference and Exhibition; 1997 Apr 14–16; Kuala Lumpur, Malaysia. Richardson: OnePetro; 1997.
- [27] Osman EA, Abdel-Wahhab OA, Al-Marhoun MA. Prediction of oil PVT properties using neural networks. In: Proceedings of the SPE Middle East Oil Show; 2001 Mar 17–20; Manama, Bahrain. Richardson: OnePetro; 2001.
- [28] Wang K, Luo J, Wei Y, Wu K, Li J, Chen Z. Practical application of machine learning on fast phase equilibrium calculations in compositional reservoir simulations. *J Comput Phys* 2020; 401: 109013.
- [29] Helmy T, Fatai A. Hybrid computational intelligence models for porosity and permeability prediction of petroleum reservoirs. *Int J Comput Intell Appl* 2010; 9(4): 313–37.
- [30] Patel AK, Chatterjee S. Computer vision-based limestone rock-type classification using probabilistic neural network. *Geosci Front* 2016; 7(1): 53–60.
- [31] An P. The effect of random noise in lateral reservoir characterization using feed-forward neural networks. In: SEG technical program expanded abstracts 1994. Houston: SEG Library; 1994.
- [32] An P, Moon WM, Kalantzis F. Reservoir characterization using seismic waveform and feedforward neural networks. *Geophysics* 2001; 66(5): 1450–6.
- [33] Jamialahmadi M, Javadpour FG. Relationship of permeability, porosity and depth using an artificial neural network. *J Petrol Sci Eng* 2000; 26(1–4): 235–9.
- [34] Wang B, Sharma J, Chen J, Persaud P. Ensemble machine learning assisted reservoir characterization using field production data—an offshore field case study. *Energies* 2021; 14(4): 1052.
- [35] Liu X, Ge Q, Chen X, Li J, Chen Y. Extreme learning machine for multivariate reservoir characterization. *J Petrol Sci Eng* 2021; 205: 108869.
- [36] Chen Z. Reservoir simulation: mathematical techniques in oil recovery. In: CBMS-NSF regional conference series in applied mathematics. Philadelphia: Siam; 2007.
- [37] Chen Z, Huan G, Ma Y. Computational methods for multiphase flows in porous media. Philadelphia: Siam; 2006.
- [38] Amirian E, Chen Z. Cognitive data-driven proxy modeling for performance forecasting of waterflooding process. *Glob J Technol Optim* 2017; 08(01): 1–9.
- [39] Amirian E, Dejam M, Chen Z. Performance forecasting for polymer flooding in heavy oil reservoirs. *Fuel* 2018; 216: 83–100.
- [40] Huang Z, Chen Z. Comparison of different machine learning algorithms for predicting the SAGD production performance. *J Petrol Sci Eng* 2021; 202: 108559.
- [41] Dang C, Nghiem L, Fedutenko E, Gorucu SE, Yang C, Mirzabozorg A, et al. AI based mechanistic modeling and probabilistic forecasting of hybrid low salinity chemical flooding. *Fuel* 2020; 261: 116445.
- [42] Ng CSW, Ghahfarokhi AJ, Amar MN. Well production forecast in Volvo field: application of rigorous machine learning techniques and metaheuristic algorithm. *J Petrol Sci Eng* 2022; 208(Pt B): 109468.
- [43] Hui G, Chen S, He Y, Wang H, Gu F. Machine learning-based production forecast for shale gas in unconventional reservoirs via integration of geological and operational factors. *J Nat Gas Sci Eng* 2021; 94: 104045.
- [44] Tadjer A, Hong A, Bratvold RB. Machine learning based decline curve analysis for short-term oil production forecast. *Energy Explor Exploit* 2021; 39(5): 1747–69.
- [45] Ahmad MA, Chen Z. Machine learning models to predict bottom hole pressure in multi-phase flow in vertical oil production wells. *Can J Chem Eng* 2019; 97(11): 2928–40.
- [46] Lee K, Lim J, Yoon D, Jung H. Prediction of shale-gas production at Duvernay Formation using deep-learning algorithm. *SPE J* 2019; 24(06): 2423–37.
- [47] Popa A, Connel S. Optimizing horizontal well placement through stratigraphic performance prediction using artificial intelligence. In: Proceedings of the SPE Annual Technical Conference and Exhibition; 2019 Sep 30–Oct 2; Calgary, AB, Canada. Richardson: OnePetro; 2019.
- [48] Mohaghegh SD. Mapping the natural fracture network in Utica shale using artificial intelligence (AI). In: Proceedings of the SPE/AAPG/SEG Unconventional Resources Technology Conference; 2017 Jul 24–26; Austin, TX, USA. Houston: SEG Library; 2017.
- [49] He Q, Zhong Z, Alaboodi M, Wang G. Artificial intelligence assisted hydraulic fracturing design in shale gas reservoir. In: Proceedings of the SPE Eastern Regional Meeting; 2019 Oct 15–17; Charleston, WV, USA. Richardson: OnePetro; 2019.
- [50] Sun Z, Wang L, Zhou J, Wang C. A new method for determining the hydraulic aperture of rough rock fractures using the support vector regression. *Eng Geol* 2020; 271: 105618.
- [51] Yang S, McBride P, Kherroubi J, He A, Le Nir I, Quesada D, et al. An efficient workflow for geological characterization in unconventional reservoirs from a new through-the-bit logging electrical micro-imaging tool. In: Proceedings of the 2018 AAPG International Conference and Exhibition; 2018 Nov 4–11; Cape Town, South Africa; 2018.
- [52] Wang LK, Sun AY. Well spacing optimization for Permian basin based on integrated hydraulic fracturing, reservoir simulation and machine learning study. In: Proceedings of the SPE/AAPG/SEG Unconventional Resources Technology Conference; 2020 Jul 20–22; online. Richardson: OnePetro; 2020.
- [53] Bangi MSF, Kwon JSI. Deep reinforcement learning control of hydraulic fracturing. *Comput Chem Eng* 2021; 154: 107489.
- [54] Duplyakov VM, Morozov AD, Popkov DO, Shel EV, Vainshtein AL, Burnaev EV, et al. Data-driven model for hydraulic fracturing design optimization. Part II: inverse problem. *J Petrol Sci Eng* 2021; 208(Pt A): 109303.
- [55] Chaikine IA, Gates ID. A machine learning model for predicting multi-stage horizontal well production. *J Petrol Sci Eng* 2021; 198: 108133.
- [56] Han D, Kwon S. Application of machine learning method of data-driven deep learning model to predict well production rate in the shale gas reservoirs. *Energies* 2021; 14(12): 3629.
- [57] Mohaghegh SD, inventor; Mohaghegh SD, assignee. System and method providing real-time assistance to drilling operation. United States patent US20150300151. 2015 Oct 22.
- [58] Unrua S, Torrione P, Hibbard M, Smith R, Olesen L, Watson J. Machine learning algorithms applied to detection of well control events. In: Proceedings of the SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition; 2017 Apr 24–27; Dammam, Saudi Arabia. Richardson: OnePetro; 2018.
- [59] Pollock J, Stoecker-Sylvia Z, Veedu V, Panchal N, Elshahawi H. Machine learning for improved directional drilling. In: Proceedings of the Offshore Technology Conference; 2018 Apr 30–May 3; Houston, TX, USA. Richardson: OnePetro; 2018.
- [60] Zhao J, Shen Y, Chen W, Zhang Z, Johnston S. Machine learning-based trigger detection of drilling events based on drilling data. In: Proceedings of the SPE Eastern Regional Meeting; 2017 Oct 4–6; Lexington, KY, USA. Richardson: OnePetro; 2017.
- [61] Hegde C, Gray KE. Use of machine learning and data analytics to increase drilling efficiency for nearby wells. *J Nat Gas Sci Eng* 2017; 40: 327–35.
- [62] Goebel T, Molina RV, Vilalta R, Gupta KD, inventors; Landmark Graphics Corp., assignee. Method and system for predicting a drill string stuck pipe event. United States patent US8752648. 2014 Sep 10.
- [63] Dursun S, Tuna T, Duman K, Kellogg RW, inventors; Landmark Graphics Corp., assignee. Real-time risk prediction during drilling operations. United

- States patent US15/024, 575. 2015 Apr 30.
- [64] Castañeira D, Toronyi R, Saleri N. Machine learning and natural language processing for automated analysis of drilling and completion data. In: Proceedings of the SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition; 2018 Apr 23–26; Dammam, Saudi Arabia. Richardson: OnePetro; 2018.
- [65] Bhattacharya S. A brief review of popular machine learning algorithms in geosciences. In: Briefs in Petroleum Geoscience & Engineering. Cham: Springer; 2021.
- [66] Abrahart RJ, See LM, Solomatine DP. Practical hydroinformatics: computational intelligence and technological developments in water applications. New York: Springer Science & Business Media; 2008.
- [67] Li Z, Kovachki N, Azizzadenesheli K, Liu B, Bhattacharya K, Stuart A, Anandkumar A. Fourier neural operator for parametric partial differential equations. 2020. arXiv:2010.08895.
- [68] Noshi C. A brief survey of text mining applications for the oil and gas industry. International Petroleum Technology Conference; 2019 Mar 26–28; Beijing, China. Richardson: OnePetro; 2019.
- [69] Brestoff NE, inventor; assigneeIntraspexion LLC. Using classified text and deep learning algorithms to identify risk and provide early warning. United States patent US9552548B1. 2017 Jan 24.
- [70] Lv G, Zheng C, Zhang L. Text information retrieval based on concept semantic similarity. In: Proceedings of the 2009 Fifth International Conference on Semantics; 2009 Oct 12–14; Zhuhai, China. Piscataway: IEEE Publisher; 2009.
- [71] Arumugam S, Rajan S, Gupta S. Augmented text mining for daily drilling reports using topic modeling and ontology. In: Proceedings of the SPE Western Regional Meeting; 2017 Apr 23–27; Bakersfield, CA, USA. Richardson: OnePetro; 2017.