

陈雪菲, 辛显康, 喻高明. IPSO-Stacking 双驱动集成学习自适应模型的致密砂岩储层渗透率预测[J]. 石油物探, 2025, 64(5): 946-956
CHEN Xuefei, XIN Xiankang, YU Gaoming. Permeability prediction for tight sandstone reservoirs based on an IPSO-Stacking dual-driven ensemble learning model[J]. Geophysical Prospecting for Petroleum, 2025, 64(5): 946-956

IPSO-Stacking 双驱动集成学习自适应模型的 致密砂岩储层渗透率预测

陈雪菲, 辛显康, 喻高明

(长江大学石油工程学院, 湖北武汉 430100)

摘要: 传统的致密砂岩储层渗透率预测通常采用物理模型与拟合模型, 物理模型难以获取精准物理参数, 纯数据驱动的拟合模型对非均质性较强的储层渗透率的预测准确性较差。为此, 从耦合物理模型和机器学习拟合模型入手, 首先引入 Stacking 集成学习模型预测储层流动单元指数 (FZI), 并结合 Kozeny-Carman 模型以及离散岩石类型 (DRT) 对储层进行划分, 然后使用改进的粒子群优化 (IPSO) 算法对物理模型和机器学习拟合模型的参数同步进行动态优化, 得到 IPSO-Stacking 双驱动集成学习自适应模型 (简称 IPSO-Stacking 模型), 利用江汉 WG 油田的测井数据测试 IPSO-Stacking 模型对致密砂岩储层的渗透率预测的能力。试验结果表明: 利用由耦合物理模型与机器学习拟合模型得到的 IPSO-Stacking 模型预测的 FZI 准确度达到 98%, 预测的渗透率准确度为 93%, 证明了 IPSO-Stacking 模型较强的预测能力; IPSO 算法较传统元启发式优化算法能更有效地调整物理模型和机器学习模型的参数; 利用 IPSO 算法进行迭代, 得到的 DRT 经验系数更具适应性。IPSO-Stacking 模型通过物理与数据驱动的协同优化, 实现了致密砂岩储层渗透率的高精度预测。

关键词: 渗透率; 耦合; 离散岩石类型; 流动单元指数; 改进的粒子群优化; 集成学习

中图分类号: TE; P631

文献标识码: A

文章编号: 1000-1441(2025)05-0946-11

DOI: 10.12431/issn.1000-1441.2023.0435

Permeability prediction for tight sandstone reservoirs based on an IPSO-Stacking dual-driven ensemble learning model

CHEN Xuefei, XIN Xiankang, YU Gaoming

(School of Petroleum Engineering, Yangtze University, Wuhan 430100, China)

Abstract: Permeability prediction for tight sandstone reservoirs usually uses physical and fitted models. However, physical models face challenges in obtaining accurate petrophysical parameters, while completely data-driven fitted models show poor performance in heterogeneous reservoirs. In response to these challenges, we propose a coupled approach integrating physical and fitted models. An ensemble learning model Stacking is employed to predict flow zone indicator (FZI) that characterizes reservoir flow units. The Kozeny-Carman model is combined with a discrete rock typing (DRT) method for reservoir classification. An improved particle swarm optimization (IPSO) algorithm is then utilized to synchronize the parameters of the physical and machine learning models dynamically. As per a case study in Jiangnan oilfield, the adaptive IPSO-Stacking model, established by coupling a physical model with a machine learning fitted model, achieves an accuracy of 98% in FZI prediction and 93% in permeability estimation, demonstrating robust predictive ability. The IPSO method is superior to conventional meta-heuristic optimization

收稿日期(Received): 2023-11-17; 接收日期(Accepted): 2025-02-18。

第一作者简介: 陈雪菲 (1999—), 女, 硕士在读, 研究方向为人工智能在油气田开发领域的应用。E-mail: cynthia14fei@163.com

通信作者: 辛显康 (1986—), 男, 副教授, 硕士生导师, 主要从事油藏物理模拟和数值模拟的研究工作。E-mail: xinxk@yangtzeu.edu.cn

基金项目: 国家自然科学基金青年科学项目 (52104020) 和湖北省自然科学基金青年科学项目 (2020CFB377) 共同资助。

This research is financially supported by the National Natural Science Foundation of China (Grant No. 52104020) and the Natural Science Foundation of Hubei Province (Grant No. 2020CFB377).

© The Author(s) 2025. This is an open access article under the CC-BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>)

algorithms in adjusting physical and fitted model parameters. Through IPSO iteration, the derived DRT empirical coefficients exhibit enhanced adaptability. The dual-driven IPSO-Stacking model achieves high-precision permeability prediction for tight sandstone reservoirs through collaborative optimization by integrating physics-based and data-driven approaches.

Keywords: permeability, coupling, DRT, FZI, IPSO, ensemble learning

渗透率预测是致密砂岩储层常规测井评价中的关键内容之一。致密砂岩储层存在低孔低渗、复杂的多孔隙结构以及非均质等特性,常规地球物理测井解释存在多解性^[1-3]。常规测井解释渗透率预测主要采用物理模型^[4]和拟合模型^[5]。指数型模型、Kozeny-Carman 模型^[6-7]和幂律型^[8]模型等为常用的物理模型,其中, Kozeny-Carman 模型常作为基础模型被改进和推广;拟合模型包括多元线性回归模型、多项式回归模型、逻辑回归模型等。传统的物理模型和拟合模型存在诸如对噪声敏感、受限于特定条件以及需要大量的先验知识等不足^[9-12]。在具体的场景下,物理模型与拟合模型相互补充,因此需要深入探讨两者之间的关联性及其耦合程度。例如,探讨物理模型与拟合模型在何种程度上能够提高渗透率的预测精确,离散岩石类型 (discrete rock type, DRT) 的划分原理及相关概念。

为充分挖掘储层参数与常规测井数据之间的非线性关系,前人利用机器学习方法代替传统的非线性表达式建立方法,实现常规测井数据与储层参数之间的精确拟合。在机器学习领域中,集成学习以融合多个机器学习模型来获得更高的准确度;集成学习的三大类算法包括: Bagging、Boosting、Stacking^[13]。随机森林 (random forest, RF) 算法是 Bagging 的代表性算法,极端梯度提升 (extreme gradient boosting, XGBoost) 算法为 Boosting 算法中的代表性方法之一^[14]。孙予舒等^[15]将 XGBoost 算法用于确定复杂碳酸盐岩层的岩性;郭建宏等^[16]采用 RF 算法模型预测储层煤层气含量。Bagging 算法和 Boosting 算法都是通过对建立的各种模型进行均衡处理来实现整合,故难以解决特征变量之间相关性高的问题,Stacking 算法通过训练次级学习器并综合多个基础模型的预测结果来提升模型的性能和泛化能力,将基础模型的预测结果作为新的特征输入到元模型中进行训练和预测,以获得更准确的预测结果。

为解决机器学习模型参数调试的复杂问题,引入了元启发优化算法简化了人工调试过程,并提高了模型的预测精度。谷宇峰等^[17]使用粒子群优化 (particle swarm optimization, PSO) 算法改进了 XGBoost 模型,并得到了可靠的渗透率解释模型。但该算法对于具有

复杂非线性关系的致密砂岩储层渗透率预测效果并不理想,仅依靠机器学习模型直接预测孔隙结构更加复杂的储层岩样难以获得较好的结果。

为此,本文采用 Stacking 集成学习算法来挖掘岩石储层分布特征与测井数据之间的关系。同时,将流动单元指数 (flow zone index, FZI) 作为影响因子引入用于储层划分的 DRT 模型,并利用改进的粒子群优化 (improved particle swarm optimization, IPSO) 算法对 DRT 模型和基于 Stacking 的 FZI 模型参数进行优化,建立了一种基于物理与数据的双驱动模型,该模型耦合了物理经验模型和基于数据的机器学习模型,采用优化算法形成自适应渗透率预测模型。以物理经验模型和基于数据的机器学习模型相结合的方式,即物理和数据的双驱动模式,为致密砂岩储层渗透率的预测提供技术支撑。

1 方法原理

1.1 基于流动单元指数的储层划分

对于均匀孔隙介质, KOZENY^[6]和 CARMAN^[7]根据毛细管理论所描述的孔隙度与渗透率的复杂关系,建立了 Kozeny-Carman 方程^[7],其常用形式^[18]为:

$$K = \frac{\varphi^3}{(1-\varphi)^2} \left(\frac{1}{F_s \tau^2 S_{gv}^2} \right) \quad (1)$$

式中: K 为渗透率; φ 为孔隙度; F_s 为孔隙几何形状指数 (圆柱形管时 F_s 为 2); τ 为流动路径的弯曲度; S_{gv} 为矿物颗粒的比表面积。AMAEFULE 等^[19]对 (1) 式变形,定义了流动单元指数 FZI:

$$FZI = \frac{1}{\sqrt{F_s} \tau S_{gv}} = 0.0314 \sqrt{\frac{K}{\varphi} \frac{1-\varphi}{\varphi}} \quad (2)$$

KHARRAT 等^[20]提出离散岩石类型聚类算法,表达式为:

$$DRT = \text{ROUND}(2 \ln FZI + C) \quad (3)$$

式中: C 为经验系数,由 FZI 值的正态分布特性确定,初始值取 10.6; ROUND($\cdot$) 为取整运算。基于上述理论,以 FZI 为影响因子划分储层 DRT 类型即建立 DRT 模型。

利用 FZI 划分储层得到不同的 DRT 类型,不同 DRT 类型对应着不同的孔隙结构和岩性特征,这些特

征直接影响着渗透率的大小,准确划分 DRT 类型为后续精准预测储层渗透率提供了重要的基础。

DRT 模型是储层划分的经典方法,其依赖经验系数(如 C 值)且对非均质性储层的适应性不足。本文引入 Stacking 集成学习算法替代传统回归方法预测 FZI,减少人工经验参数误差,并将 DRT 聚类中的经验系数 C 纳入 IPSO 动态优化框架,实现物理模型参数与数据驱动模型参数的协同调整。

1.2 优化算法

构建参数预测模型和拟合过程中,经验参数直接或间接地影响训练效果和预测精度,例如在机器学习模型中,支持向量机(support vector machine, SVM)的惩罚系数和径向基函数的选择范围、RF 决策树的数量和最大深度、XGBoost 中弱学习器贡献程度、物理模型中 DRT 聚类算法的经验系数 C 等。为克服传统参数调优的局限性,本文采用 IPSO 算法。IPSO 算法具有全局搜索能力,在多模态问题求解中表现出色;该算法引入了更加智能和自适应的粒子初始化以及参数自适应调整方法,采用自适应惯性权重策略,动态平衡全局搜索与局部收敛能力,显著提升了多模态优化问题的求解效率,为物理与数据双驱动模型的协同优化提供了技术保障^[21]。IPSO 算法自适应优化过程的数学表达式如下:

$$\mathbf{X} = (x_1, x_2, \dots, x_N)^T \in \mathbb{R}^{N \times D} \quad (4)$$

式中: $\mathbf{X}$ 代表群体; x_N 为第 N 个粒子; N 代表群体中粒子的数量; D 是优化参数的数量,包括(3)式中的 C 值以及文中所使用的机器学习模型的相关参数。在模型迭代寻优过程中,种群 $\mathbf{X}$ 中的每个粒子 x_N 通过个体极值以及种群极值调整自身的速度和位置,调整过程执行(5)式和(6)式:

$$v_{i,d}^{(k+1)} = \omega v_{i,d}^{(k)} + c_1 r_1 [p_{i,d}^{(k)} - x_{i,d}^{(k)}] + c_2 r_2 [g_d^{(k)} - x_{i,d}^{(k)}] \quad (5)$$

$$x_{i,d}^{(k+1)} = x_{i,d}^{(k)} + v_{i,d}^{(k)} \quad (6)$$

式中: i 表示粒子的索引,取值范围为 $1 \sim N$; d 表示优化参数的索引,取值范围为 $1 \sim D$; k 表示当前的迭代次数; ω 为惯性权重; c_1, c_2 是不同的加速系数; r_1, r_2 为弹性系数; $p_{i,d}^{(k)}, v_{i,d}^{(k)}, x_{i,d}^{(k)}$ 分别表示第 k 次迭代中第 i 个粒子的第 d 个优化参数的个体极值、速度和位置; $g_d^{(k)}$ 为第 k 次迭代中第 d 个优化参数的群体极值。

将初始惯性权重设为 0.9,迭代中线性降至 0.4,以避免早熟收敛;加速系数分别从 2.5 降至 1.5,1.5 升至 2.5,以增强算法初期探索与后期开发能力;种群规模 $N=50$,优化参数维度 $D=8$ (包含 DRT 的 C 值及 Stacking

超参数)。这一机制动态平衡了全局搜索能力与局部收敛能力,解决了传统 PSO 算法在多模态优化中易陷入局部最优的问题。通过同步优化物理模型 DRT 的 C 值与机器学习模型超参数,IPSO 显著增强了物理-数据双驱动的协同性,为复杂储层渗透率预测提供了高效优化框架。

2 双驱动集成学习自适应模型的建立

2.1 基于 Stacking 的 FZI 预测模型构建

由前文对于 Kozeny-Carman 方程以及 DRT 模型的介绍可知,准确预测 FZI 便能够准确把握储层特性。为提高储层渗透率预测模型精度,首先需要构建高精度 FZI 预测模型。鉴于传统的多元回归算法不能准确地计算 FZI,故引入机器学习算法建立 FZI 预测模型,以传统测井响应数据作为机器学习模型特征输入数据,以 FZI 为目标输出值,通过训练预测模型得出 FZI。该方法避免了直接计算 FZI,直接对流动单元类型进行划分,从而有效降低了误差传播的风险^[22]。针对样本数据问题,采用集成学习的策略,构建多个小样本集同时对数据集进行有放回抽样,并训练多个模型。上述方法能够更好地处理样本数量不足的问题,提高模型的预测性能。

Stacking 集成学习^[23]是一种采用分层结构的集成学习算法,其结构如图 1 所示。在 Stacking 集成学习结构中,首先将原始数据输入到第 1 层的基学习器进行训练,并生成预测结果,这些预测结果被整合成一个新的特征矩阵,每列对应一个基学习器的预测结果;然后将整合后的特征矩阵和原始数据的真实标签作为输入,利用元学习器进行训练;最后利用训练好的元学习器对测试集或新样本进行预测。Stacking 集成学习算法的核心思想是结合多个基学习器的预测结果,利用一个更强的元学习器进行整合和预测。由




图 1 Stacking 集成学习算法结构示意图

Fig. 1 Schematic architecture of the ensemble learning model Stacking

于选择相异算法作为基学习器,因此,Stacking 集成学习算法的泛化能力也更为突出^[24]。

在构建基于 Stacking 的 FZI 预测模型时,基学习器的选择要兼顾准确性与多样性,既要选择预测性能优异的算法,又要考虑算法之间的差异度,保证集成学习的多样性。3 种算法的准确性以及多样性分析如下。①在理论方面,XGBoost 和 RF 算法是基于重抽样技术和决策树算法的集成学习方法,决策树是一种适应性较强的分类方法,可以在建模过程中自动地去除噪声或错误样本,因此,具有更好的容错性,其分类过程属于线性计算,不需要矩阵变换或核函数转换的参与,理论上具有较高的预测准确率。SVM 算法基于统计学习理论和结构风险最小化原则,旨在寻找最优分类超平面以最大化分类间隔,具有处理高维空间和非线性问题的潜力。②在形式方面,XGBoost 算法支持多种损失函数和正则化方法,通过调整参数可以灵活地配置模型,故拥有较高的可解释性,RF 算法和 SVM 算法原理更为复杂,可解释性差,且算法效果受参数

选取影响较大。③在适用场景方面,渗透率数据样本通常较少,XGBoost 算法除了对于高维稀疏数据的处理能力较强外,其基于梯度提升的框架能有效挖掘数据中的非线性关系,在小样本情况下同样能较好地发挥作用。RF 对于缺失值和异常值的鲁棒性较高,能够有效地处理数据中的噪声。SVM 算法能够通过选择不同的核函数来适应不同类型的数据,具有较强的灵活性,尤其适用于处理小样本高维特征数据。综合来看,这 3 种算法相互结合能够在不同方面发挥优势,满足 FZI 预测模型对准确性和多样性的要求^[25-31]。

考虑到基学习器预测误差会影响最终结果的精确度,故元学习器应选择泛化能力较强的算法。本文选择 XGBoost、RF 及 SVM 算法作为 Stacking 的基学习器,第 2 层元学习器选择泛化能力更强的 XGBoost 算法,最终构建了适用于预测 FZI 的 Stacking 模型。

2.2 渗透率预测模型构建

本文构建的自适应模型通过双驱动机制实现渗透率预测,技术路线如图 2 所示。在整个渗透率预测




图 2 基于 IPSO-Stacking 的双驱动集成学习自适应模型的渗透率预测技术路线

Fig. 2 Technology roadmap of the dual-driven adaptive IPSO-Stacking model for permeability prediction

过程中,一方面,基于 FZI 的 DRT 划分与 Kozeny-Carman 方程提供渗透率计算的物理约束,从岩石物理理论层面确保了模型的理论合理性;另一方面,Stacking 集成学习通过挖掘测井数据与 FZI 之间的非线性关系,建立数据驱动的预测框架,减少传统经验参数引入的误差。使用 IPSO 算法对物理模型中的经验系数和机器学习模型的超参数进行同步动态优化,融合两类驱动的优势,输出高精度渗透率预测值。物理模型与数据驱动模型通过 IPSO 算法实现参数同步优化,形成闭环反馈,以提升模型的自适应性。

使用 Python 语言实现预测、拟合以及优化,整体技术路线如图 2 所示。在迭代优化过程中,均方误差(mean squared error, MSE)用于评估模型的拟合误差。决定系数(R -squared, R^2)用于评估拟合模型的优度指标。对比预测渗透率与实际测量渗透率之间的差异可以得到决定系数,对 DRT 算法优化后的预测模型计算得到预测渗透率,最终构建 IPSO-Stacking 双驱动集成学习自适应(简称 IPSO-Stacking)模型,用于预测致密砂岩储层的渗透率。

3 实例应用

3.1 数据来源及试验设计

WG 油田中区潜 4³ 油藏构造形态为不对称长轴逆倾角背斜,轴向为西北 305°和东南 108°,构造自北向南被断层切割,构造最高点位于潜深 5 井区域,两

侧倾角自上而下递增,地层内无断层发育。目标区成岩前期构造倾角小,构造平缓,水动力不是很强,可形成大面积砂体沉积。微相类型主要有水下分流河道、河口坝、席状砂、远砂坝;岩性组合以杂砂质长石砂岩为主,平均石英含量为 60.4%,长石含量为 26.2%,含少量鲕粒;砂岩粒度一般较细,以粗粉砂质细砂岩为主,平均细砂含量为 51.3%,含少量中砂;孔隙度为 7.1%~18.2%,平均有效孔隙度为 14.0%,平均有效渗透率为 $49 \times 10^{-3} \mu\text{m}^2$,目标地层为低孔、低渗型致密砂岩储层。

本文对目标地层的取心孔隙度和渗透率数据进行了指数拟合,拟合结果中 R^2 仅为 0.332 3(图 3a)。这表明单一回归方程很难描述低孔隙度和低渗透率储层的复杂性,且无法满足精度要求。因此,需要对目标储层进行储层划分以进一步提高储层参数的拟合精度(图 3b)。观察图 3b 发现,同一类型的 DRT, K - ϕ 之间呈现水平直线关系,究其原因在于在同一 DRT 类型中,目标储层的岩性、孔隙结构等关键地质因素相似,使得渗透率在一定范围内保持稳定。如图 4a 和图 4b 所示,分别采用 DRT 聚类方法与常规 K-Means 聚类方法,可以看出在相同迭代次数下,采用 DRT 聚类方法并通过拟合曲线的方式得出的 MSE 和 R^2 均优于 K-Means 聚类方法得到的结果。图 4c 显示两种方法得到的 MSE 相差一个数量级,对比常规 K-Means 聚类方法,采用 FZI 作为影响因子的 DRT 聚类方法更具有物理意义,结果具有较高的准确度。此外,使用 DRT 进行储层划分训练过程中,损失函数呈现周期变





图 3 目的层段取心孔隙度与渗透率关系

a 指数拟合; b DRT 聚类拟合

Fig. 3 Relationship between core porosity and permeability in the target layer section



注: R^2 , MSE的下标代表迭代次数。

图4 基于岩心数据的储层划分方法对渗透率预测效果的对比试验

a 采用 DRT 聚类; b 采用 K-Means 聚类; c DRT、K-Means 迭代过程中 MSE 变化情况; d DRT、K-Means 迭代过程中 R^2 变化情况

Fig. 4 Comparison of permeability prediction performance of different reservoir classification methods based on core data

化(图 4c 和 图 4d)。由 (3) 式可以看出, 除 FZI 之外, C 同样影响 DRT 值。

根据 (1) 式至 (3) 式, 并利用细分孔隙度和渗透率的复杂关系得到了 13 个 DRT 类型, 根据不同的 DRT 类型建立相应的回归方程。通过动态优化, 确定 (3) 式中的最佳 C 值为 10.96, 该数值直接影响 DRT 聚类的数量和回归方程的拟合优度 R^2 , 也间接影响最终的计算结果。

对岩心进行物性分析后获得孔隙度和渗透率, 然后根据 (2) 式计算出 FZI, 从而对储层进行划分。上述过程以取心段的岩心样本为基础, 但对没有取心的储层, 则需要依靠常规测井数据来建立 FZI 与测井响应之间的关系模型以实现储层划分。由于缺乏基础信息, Kozeny-Carman 模型无法直接应用。为此, 本文利用 Stacking 集成学习算法挖掘常规测井参数与 FZI 之

间的非线性关系, 构建 FZI 预测模型, 并在此基础上构建渗透率拟合模型, 同时设计优化对比实验对模型进行迭代优化, 自适应地确定 C 值的最优解和机器学习模型参数^[32]。

3.2 FZI 敏感性分析

在建立 FZI 预测模型之前, 可以根据 (2) 式对参与建模的输入测井参数进行预选。利用声波时差 (AC)、自然伽马 (GR)、校正补偿中子 (CNL) 以及密度 (DEN) 曲线计算出测井解释参数孔隙度 ϕ ; τ 与地层因素、测井参数深侧向电阻率 (RD)、浅侧向电阻率 (RS) 等有关^[33]。通常情况下地层泥质含量 (VSH) 和孔隙度 (POR)(即通过校正补偿中子-密度交会得到的孔隙度) 可以满足解释精度要求, 直接参与建模^[34]; 因此, 初步选择 GR、AC、CNL、DEN、RD、RS、POR 和 VSH 8 种参数参与建模。由于测井参数与 FZI 之间的

关系通常表现为非线性,因此在初步筛选之后,需要分析上述 8 种参数对 FZI 的敏感性,本文采用适合刻画非线性相关性的 Spearman 秩相关系数进一步筛选敏感参数。图 5 为使用测井参数计算得到的 FZI 秩相关系数矩阵。总体上,FZI 与 AC、POR、GR、VSH 和 CNL 参数具有较高的相关性,因此,最终选择这 5 个参数作为输入参数来训练以及验证 Stacking 模型。




图 5 FZI 敏感参数秩相关系数矩阵

Fig. 5 Rank correlation coefficient matrix of FZI-sensitive parameters

3.3 渗透率预测试验与结果分析

将 465 个样本试验数据按照 7 : 3 的比例随机划分为两个不重叠的集合,得到 326 个样本的训练集和 139 个样本的测试集,用训练集样本训练模型并使用 MSE 评估模型拟合能力,用测试集样本对模型进行测试并根据 MSE 和 R^2 评估模型泛化能力。利用 AdaBoost、SVM、XGBoost、RF、Linear 模型以及本文方法建立的 Stacking 模型分别对 FZI 进行预测,不同方法预测的结果与 FZI 真实值如图 6 和表 1 所示。可以看出,本文方法建立的 Stacking 模型能较好地反映 FZI 的变化趋势,预测结果更加准确。为了优化 Stacking 模型的参数,分别采用 PSO 算法和 IPSO 算法进行动态优化,图 7 展示了分别基于 PSO 与 IPSO 算法优化的 Stacking 模型预测的 FZI 结果,可以看出 IPSO 算法相较于传统的 PSO 算法具有更好的全局搜索能力、自适应性和收敛性能,对于复杂的问题具有更好的适应性。

利用机器学习模型进行参数预测,并采用 IPSO 算法进行迭代优化,可以自适应地获取 FZI 值和 C 值的最优解。基于 DRT 聚类分别对孔隙度和渗透率数




图 6 6 种不同方法预测的 FZI 与真实值的分布

Fig. 6 Comparison of actual and predicted FZIs using 6 methods

表 1 6 种不同算法预测 FZI 结果评估

Table 1 Evaluation of FZI results predicted using 6 different methods

算法名称	MSE	R^2
SVM	0.005 60	0.86
RF	0.004 30	0.94
Linear	0.020 00	0.65
AdaBoost	0.005 90	0.88
XGBoost	0.004 90	0.91
Stacking	0.000 25	0.98




图 7 基于 PSO 与 IPSO 算法优化的 Stacking 模型的 FZI 预测结果

Fig. 7 Comparison of FZI results predicted using the PSO-Stacking and IPSO-Stacking models

据建立拟合模型,并对渗透率进行预测。从图 8a 可以明显看出,随着 C 值的增加,其对应的 MSE 呈现规律性变化,在 C 值长度为 1 的周期内,MSE 有着不同幅度的变化趋势,这也是使用 DRT 进行储层划分训练过程的损失函数呈现周期变化的原因;当 C 接近 10.96 时,MSE 为极值 0.34(图 8b)。将预测渗透率与实际渗透率计算得到的 MSE 作为适应度值,并使用迭代寻优的方法对渗透率进行优化。




图 8 自适应优化过程中 C 与 MSE 的关系
a C 与 MSE(全局); b C 与 MSE(局部放大显示)

Fig. 8 C -MSE relationship in adaptive optimization process

图 9 和表 2 分别展示了 3 种优化算法在基于双驱动集成学习模型下对渗透率预测的优化效果,并对优化结果进行了评估:分别基于 3 种优化算法的 Stacking 模型预测结果均良好,与 DRT 模型耦合效果甚好,其中,IPSO-Stacking 模型展现出最佳性能,其 MSE 约为 0.28, R^2 达到了 0.93。这表明 IPSO-Stacking 模型在 3

种机器学习模型中具有最强的耦合能力,能够更敏感地响应 DRT 模型。从图 9b 可以看出,当迭代次数达到 40 次时,PSO-Stacking 和 IPSO-Stacking 的 C 值仍未收敛,这说明不同的 DRT 模型和基于 Stacking 的 FZI 预测模型在一定范围内表现出不同的耦合程度,但在迭代次数大于 80 次后,3 种模型的 C 值均趋于稳定。




图 9 3 种算法对渗透率预测的优化效果对比
a MSE 与迭代次数; b C 与迭代次数

Fig. 9 Optimization process comparison for 3 permeability prediction algorithms

表 2 3 种算法对渗透率预测的优化结果评估

Table 2 Performance evaluation of 3 algorithms for optimized permeability prediction

优化方法	MSE	R^2
GA	0.52	0.83
PSO	0.33	0.89
IPSO	0.28	0.93

本次渗透率模型评价参数表现出较高的准确性, X 井目的层段综合测井评价结果以及基于不同模型预测 FZI 值、真实 FZI 值、渗透率预测值与真实值如图 10 所示。由本文提出的基于 IPSO-Stacking 的渗透率预测模型能准确预测渗透率的变化趋势,但对于少数极端变化趋势下的渗透率数值,其预测精度仍有一定偏差,模型预测精度有待提高,还需进一步研究预测模型。




图 10 X 井目的层段取心样本测井评价及渗透率解释成果

Fig. 10 Results of log-based evaluation and permeability interpretation for core samples from the target section in Well X

4 结论

本文将 FZI 作为影响因子, 通过 DRT 模型对储层进行划分, 耦合物理模型和基于机器学习的拟合模型, 并利用 IPSO 算法优化两种模型参数, 建立了一种 IPSO-Stacking 双驱动集成学习自适应模型来预测致密砂岩储层的渗透率。

1) 引入机器学习模型来解决构建物理模型时基础信息不充足的问题, 将拟合模型与物理模型进行耦合并充分利用测井及解释数据来构建更精确的模型, 可以显著提高并增强模型的可靠性和适用性。

2) 相较于使用单个机器学习模型进行预测的方法, 集成学习是通过融合多个机器学习模型在不同方面的优势, 显著提升预测精度, 基于 Stacking 的 FZI 预测模型 R^2 达到了 0.98, MSE 仅为 0.00025。

3) 相较于传统的 PSO 算法, IPSO 算法具有更好

的全局搜索能力、自适应性和收敛性能, 因而在求解多模态问题时表现良好。IPSO 在全局优化渗透率预测过程中 R^2 达到了 0.93, 相较 PSO 算法, MSE 降低了 6%, 相较 GA 算法, MSE 降低了 25%。在渗透率预测涉及的多参数优化过程中, IPSO 算法能在复杂多参数空间高效搜索, 通过改变孔隙度相关参数, IPSO 算法可快速定位较优解区域, 并持续探索不同空间, 避免了局部最优, 最终找到提升预测精度的参数值。

参考文献 (References)

[1] 刘冬冬, 杨东旭, 张子亚, 等. 基于常规测井和成像测井的致密储层裂缝识别方法——以准噶尔盆地吉木萨尔凹陷芦草沟组为例 [J]. 岩性油气藏, 2019, 31(3): 76-85.
LIU D D, YANG D X, ZHANG Z Y, et al. Fracture identification for tight reservoirs by conventional and imaging logging: A case study of Permian Lucaogou Formation in Jimsar Sag, Junggar Basin [J]. Lithologic Reservoirs, 2019, 31(3): 76-85.
[2] 任杰. 碳酸盐岩裂缝性储层常规测井评价方法 [J]. 岩性油气藏, 2020,

- 32(6): 129-137.
- REN J. Conventional logging evaluation method for carbonate fractured reservoir[J]. *Lithologic Reservoirs*, 2020, 32(6): 129-137.
- [3] 张宸嘉, 樊太亮, 孟苗苗, 等. 塔河油田奥陶系碳酸盐岩储集层成像测井地质解释[J]. *新疆石油地质*, 2018, 39(3): 352-360.
- ZHANG C J, FAN T L, MENG M M, et al. Geological interpretation of Ordovician carbonate reservoir in Tahe oilfield: Application of imaging logging technology[J]. *Xinjiang Petroleum Geology*, 2018, 39(3): 352-360.
- [4] 张冲, 张占松, 张超谟. 基于等效岩石组分理论的渗透率解释模型[J]. *测井技术*, 2014, 38(6): 690-694.
- ZHANG C, ZHANG Z S, ZHANG C M A permeability interpretation model based on equivalent rock elements theory[J]. *Well Logging Technology*, 2014, 38(6): 690-694.
- [5] 陈俊, 谢润成, 刘成川, 等. 中江气田侏罗系致密砂岩气藏测井流体识别及定量评价[J]. *天然气工业*, 2019, 39(增刊1): 136-141.
- CHEN J, XIE R C, LIU C C, et al. Identification and quantitative evaluation of logging fluids in Jurassic dense sandstone gas reservoirs in Zhongjiang gas field[J]. *Natural Gas Industry*, 2019, 39(S1): 136-141.
- [6] KOZENY J. Über kapillare Leitung des Wassers im Boden[J]. *Sitzungsber Akademie der Wissenschaften in Wien*, 1927, 136(2a): 271-306.
- [7] CARMAN P C. Permeability of saturated sands, soils and clays[J]. *The Journal of Agricultural Science*, 1939, 29(2): 262-273.
- [8] 李凯, 张浩, 冉超, 等. 考虑应力敏感的页岩气产能预测模型研究——以川东南龙马溪组页岩气储层为例[J]. *西安石油大学学报(自然科学版)*, 2016, 31(3): 57-61.
- LI K, ZHANG H, RAN C, et al. Productivity model of shale gas well with consideration of stress sensitivity: Taking Longmaxi formation shale gas reservoir in southeastern Sichuan Basin as an example[J]. *Journal of Xi'an Shiyou University (Natural Science Edition)*, 2016, 31(3): 57-61.
- [9] 张恒荣, 何胜林, 吴进波, 等. 一种基于 Kozeny-Carmen 方程改进的渗透率预测新方法[J]. *吉林大学学报(地球科学版)*, 2017, 47(3): 899-906.
- ZHANG H R, HE S L, WU J B, et al. A new method for predicting permeability based on modified Kozeny-Carmen equation[J]. *Journal of Jilin University (Earth Science Edition)*, 2017, 47(3): 899-906.
- [10] 谷宇峰, 张道勇, 阮金凤, 等. 用于储量渗透率预测的高效梯度提升决策模型[J]. *科学技术与工程*, 2021, 21(26): 11064-11074.
- GU Y F, ZHANG D Y, RUAN J F, et al. Permeability prediction using improved light gradient boosting machine in appraisal of oil-gas reserves[J]. *Science Technology and Engineering*, 2021, 21(26): 11064-11074.
- [11] 侯贤沐, 王付勇, 宰芸, 等. 基于机器学习和测井数据的碳酸盐岩孔隙度与渗透率预测[J]. *吉林大学学报(地球科学版)*, 2022, 52(2): 644-653.
- HOU X M, WANG F Y, ZAI Y, et al. Prediction of carbonate porosity and permeability based on machine learning and logging data[J]. *Journal of Jilin University (Earth Science Edition)*, 2022, 52(2): 644-653.
- [12] 鲁健康, 郝彬, 李程善, 等. 基于流动单元分类的致密砂岩储层渗透率预测[J]. *石油科学通报*, 2021, 6(3): 369-379.
- LU J K, HAO B, LI C S, et al. Permeability prediction of tight sandstone reservoirs based on flow unit classification[J]. *Petroleum Science Bulletin*, 2021, 6(3): 369-379.
- [13] 罗常伟, 王双双, 尹峻松, 等. 集成学习研究现状及展望[J]. *指挥与控制学报*, 2023, 9(1): 1-8.
- LUO C W, WANG S S, YIN J S, et al. Research status and prospect of ensemble learning[J]. *Journal of Command and Control*, 2023, 9(1): 1-8.
- [14] 陈吟凯. 基于概率有限自动机的梯度提升决策树全局解释方法[D]. 上海: 华东师范大学, 2023.
- CHEN Y K. Global interpretation of GBDT model based on probabilistic finite-state automata[D]. Shanghai: East China Normal University, 2023.
- [15] 孙予舒, 黄芸, 梁婷, 等. 基于 XGBoost 算法的复杂碳酸盐岩岩性测井识别[J]. *岩性油气藏*, 2020, 32(4): 98-106.
- SUN Y S, HUANG Y, LIANG T, et al. Identification of complex carbonate lithology by logging based on XGBoost algorithm[J]. *Lithologic Reservoirs*, 2020, 32(4): 98-106.
- [16] 郭建宏, 张占松, 张超谟, 等. 用地球物理测井资料预测煤层气含量——基于斜率关联度—随机森林方法的工作案例[J]. *物探与化探*, 2021, 45(1): 18-28.
- GUO J H, ZHANG Z S, ZHANG C M, et al. The exploration of predicting CBM content by geophysical logging data: A case study based on slope correlation random forest method[J]. *Geophysical and Geochemical Exploration*, 2021, 45(1): 18-28.
- [17] 谷宇峰, 张道勇, 鲍志东. 测井资料 PSO-XGBoost 渗透率预测[J]. *石油地球物理勘探*, 2021, 56(1): 26-37.
- GU Y F, ZHANG D Y, BAO Z D. Permeability prediction using PSO-XGBoost based on logging data[J]. *Oil Geophysical Prospecting*, 2021, 56(1): 26-37.
- [18] 孙建孟, 闫国亮. 渗透率模型研究进展[J]. *测井技术*, 2012, 36(4): 329-335.
- SUN J M, YAN G L. Review on absolute permeability model[J]. *Well Logging Technology*, 2012, 36(4): 329-335.
- [19] AMAEFULE J O, ALTUNBAY M, TIAB D, et al. Enhanced reservoir description: Using core and log data to identify hydraulic (flow) units and predict permeability in uncored intervals/wells[C]//Proceedings of SPE Annual Technical Conference and Exhibition. Houston: SPE, 1993: SPE-26436-MS.
- [20] KHARRAT R, MAHDAVI R, BAGHERPOUR M H, et al. Rock type and permeability prediction of a heterogeneous carbonate reservoir using artificial neural networks based on flow zone index approach[C]//Proceedings of SPE Middle East Oil and Gas Show and Conference. Manama: SPE, 2009: DOI: 10.2118/120166-MS.
- [21] 胡佳. 融合多种策略的改进粒子群算法[J]. *计算机系统应用*, 2021, 30(7): 172-177.
- HU J. Improved particle swarm optimization integrating multiple strategies[J]. *Computer Systems & Applications*, 2021, 30(7): 172-177.
- [22] 李雄炎, 秦瑞宝, 平海涛, 等. 高精度渗透率模型的建立与应用[J]. *中国石油大学学报(自然科学版)*, 2020, 44(6): 14-20.
- LI X Y, QIN R B, PING H T et al. Establishment and application of a high-precision permeability model[J]. *Journal of China University of Petroleum (Edition of Natural Science)*, 2020, 44(6): 14-20.
- [23] WOLPERT D H. Stacked generalization[J]. *Neural Networks*, 1992, 5(2): 241-259.
- [24] 韩腾飞, 李亚平. 基于 Stacking 集成学习的剩余使用寿命预测[J]. 计

- 计算机集成制造系统, 2024, 30(7): 2464-2473.
- HAN T F, LI Y P. Remaining useful life prediction based on stacking ensemble learning[J]. Computer Integrated Manufacturing Systems, 2024, 30(7): 2464-2473.
- [25] 闫星宇, 顾汉明, 肖逸飞, 等. XGBoost 算法在致密砂岩气储层测井解释中的应用[J]. 石油地球物理勘探, 2019, 54(2): 447-455.
- YAN X Y, GU H M, XIAO Y F, et al. XGBoost algorithm applied in the interpretation of tight-sand gas reservoir on well logging data[J]. Oil Geophysical Prospecting, 2019, 54(2): 447-455.
- [26] CHEN T Q, GUESTRIN C. XGBoost: A scalable tree boosting system [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016: 785-794.
- [27] 邓浩阳. 高孔低渗碳酸盐岩储层孔隙结构及物性表征方法研究[D]. 成都: 西南石油大学, 2018.
- DENG H Y. The evaluation method of pore structure and physical property in carbonate rock reservoir with high porosity and low permeability[D]. Chengdu: Southwest Petroleum University, 2018.
- [28] ZHANG Z, ZHANG H, LI J, et al. Permeability and porosity prediction using logging data in a heterogeneous dolomite reservoir: An integrated approach[J]. Journal of Natural Gas Science and Engineering, 2021, 86: 103743.
- [29] 周雪晴, 张占松, 张超漠, 等. 基于粗糙集——随机森林算法的复杂岩性识别[J]. 大庆石油地质与开发, 2017, 36(6): 127-133.
- ZHOU X Q, ZHANG Z S, ZHANG C M, et al. Complex lithologic identification based on rough set-random forest algorithm[J]. Petroleum Geology & Oilfield Development in Daqing, 2017, 36(6): 127-133.
- [30] 盛晓晨, 史旭东, 熊伟丽. 改进粒子群优化的极限学习机软测量建模方法[J]. 计算机应用研究, 2020, 37(6): 1683-1687.
- SHENG X C, SHI X D, XIONG W L. Soft sensor modeling of extreme learning machine based on improved particle swarm optimization [J]. Application Research of Computers, 2020, 37(6): 1683-1687.
- [31] 王瑞婕, 包腾飞, 李扬涛, 等. 基于多因子融合和 Stacking 集成学习的大坝变形组合预测模型[J]. 水利学报, 2023, 54(4): 497-506.
- WANG R J, BAO T F, LI Y T, et al. Combined prediction model of dam deformation based on multi-factor fusion and Stacking ensemble learning[J]. Journal of Hydraulic Engineering, 2023, 54(4): 497-506.
- [32] 徐鹏宇, 周怀来, 官俊洁, 等. 碳酸盐岩储层自适应模型常规测井渗透率预测[J]. 石油地球物理勘探, 2022, 57(5): 1192-1203.
- XU P Y, ZHOU H L, GUAN J J, et al. Permeability prediction of carbonate reservoirs by conventional logging with adaptive model[J]. Oil Geophysical Prospecting, 2022, 57(5): 1192-1203.
- [33] 梁玉楠, 钟华明, 骆玉虎, 等. 珠江口盆地低阻低渗储层测井渗透率预测方法及应用[J]. 海洋地质前沿, 2019, 35(11): 28-34.
- LIANG Y N, ZHONG H M, LUO Y H, et al. Application of permeability prediction method to low-resistivity and low-permeability reservoirs in Pearl River Estuary Basin[J]. Marine Geology Frontiers, 2019, 35(11): 28-34.
- [34] 王猛, 董宇, 张志强, 等. 高精度流动单元分类方法及应用[J]. 断块油气田, 2022, 29(1): 89-94.
- WANG M, DONG Y, ZHANG Z Q, et al. High-precision classification method and application of flow unit[J]. Fault-Block Oil and Gas Field, 2022, 29(1): 89-94.

(编辑: 朱 珠)