



DOI:10.12404/j.issn.1671-1815.2405530

引用格式: 骆国辉, 彭小龙, 杨晨, 等. 基于自适应 PSO 参数优化的页岩气复合时间产量递减模型[J]. 科学技术与工程, 2025, 25(18): 7583-7589.

Luo Guohui, Peng Xiaolong, Yang Chen, et al. Composite time production decline model of shale gas based on adaptive PSO parameter optimization[J]. Science Technology and Engineering, 2025, 25(18): 7583-7589.

基于自适应 PSO 参数优化的页岩气复合时间产量递减模型

骆国辉, 彭小龙*, 杨晨, 朱苏阳

(西南石油大学油气藏地质及开发工程国家重点实验室, 成都 610500)

摘要 页岩气因其储层条件复杂、多尺度孔隙结构, 产量随时间变化呈现明显的非线性特征, 传统的产量预测方法依赖于地质和工程数据的统计分析, 很难适应地质条件的复杂性而无法达到高准确性。提出了将超双曲递减模型与具有时间属性的复合函数结合的方法, 并使用改进的自适应粒子群优化算法 (adaptive-particle swarm optimization, A-PSO) 来寻找最优模型参数, 建立了复合时间超双曲递减模型。研究表明: 采用 A-PSO 优化算法能够根据产量数据的复杂性和数据的变化自动调整参数和模型结构, 能更快更准地找到最优参数组合, 提高预测精度; 产量在时间上的波动大, 常规递减模型难以反映其特征, 复合时间递减模型灵活性强, 能够考虑油气藏的复杂性和多变性, 更准确地描述页岩气并在不同阶段的产量变化, 提供更高的拟合精度, 使得产量预测更接近实际值。

关键词 复合时间超双曲递减模型; 自适应粒子群优化算法; 参数优化; 页岩气; 产量预测

中图分类号 TE328;

文献标志码 A

Composite Time Production Decline Model of Shale Gas Based on Adaptive PSO Parameter Optimization

LUO Guo-hui, PENG Xiao-long*, YANG Chen, ZHU Su-yang

(State Key Laboratory of Oil and Gas Reservoir Geology and Exploitation, Chengdu 610500, China)

[Abstract] Due to the complex reservoir conditions and multi-scale pore structure of shale gas, the production shows significant non-linear characteristics over time. Traditional production prediction methods, which rely on statistical analysis of geological and engineering data, find it difficult to adapt to the complexity of geological conditions and thus cannot achieve high accuracy. A method that combines the hyperbolic decline model with a composite function having time attributes was proposed. The improved A-PSO (adaptive particle swarm optimization algorithm) was used to find the optimal model parameters, establishing a composite time hyperbolic decline model. The research results show as follows. The A-PSO optimization algorithm can automatically adjust parameters and model structure according to the complexity of production data and data changes, finding the optimal parameter combination more quickly and accurately, thereby improving prediction accuracy. The production fluctuates greatly over time, making it difficult for conventional decline models to reflect its characteristics. The composite time decline model, with its strong flexibility, can consider the complexity and variability of oil and gas reservoirs, more accurately describe the production changes of shale gas wells at different stages, and provide higher fitting accuracy, making the production prediction closer to the actual value.

[Keywords] composite time super-hyperbolic decline model; adaptive particle swarm optimization algorithm; parameter optimization; shale gas; production forecasting

页岩气是一种非常特殊的天然气资源, 与常规天然气相比, 其岩层密度大、孔隙度低, 气体难以自

然流动, 开采过程更加复杂^[1-3]。自 20 世纪 80 年代末以来, 页岩气逐渐成为天然气产量的重要组成部

收稿日期: 2024-07-23 修订日期: 2025-03-27

基金项目: 四川省中央引导地方科技发展项目(2022ZYD0003)

第一作者: 骆国辉(1999—), 男, 汉族, 四川泸州人, 硕士。研究方向: 页岩气可采量评估及产量预测方法和数值模拟算法。E-mail: 13541596820@163.com。

* 通信作者: 彭小龙(1973—), 男, 汉族, 四川达州人, 博士, 教授。研究方向: 油气及煤层气藏渗流理论和数值模拟、地质建模数模一体化和油气藏分子模拟。E-mail: peng_xl@126.com。

分,其在天然气产量中的比例持续提升^[4]。然而,关于页岩气生产的长期可持续性的争论仍然存在,一些研究强调了页岩气井的高递减率,这表明生产水平最终可能低于目前的预测^[5],合理的产量预测是实现页岩气开发的高效、安全、经济开发的关键,对于推动页岩气产业的发展具有重要作用^[6-7]。由于页岩气储层的独特特征和挑战,页岩气产量预测模型的发展经历了相当大的演变。页岩气产量通常呈现早期峰值,随后急剧下降,因此需要精确的预测模型来优化开采并预测最终采收率。

页岩气产量预测依赖于各种模型和方法来解释非常规储层的独特特征,在这些方法中,递减曲线分析因其预测油气产量的简单和高效而脱颖而出^[8]。该模型对包括页岩气、致密气等非常规储层在内的多种储层类型的适应性突出了其在现代石油工程中的重要性^[9]。但其预测的准确性在很大程度上取决于用于模型拟合的历史生产数据的质量和规模,在确定模型参数方面也存在挑战,既困难又耗时,为了应对这些挑战,研究人员开发了各种适应和混合模型,扩展指数下降曲线分析(extended exponential decline curve analysis, EEDCA)、Duong 模型和幂律指数模型等^[10-13],以提高双曲线递减模型对非常规油藏的适用性,但传统递减方法主要通过理论分析及统计方法确定参数^[14-15]。近年来,人们探索了结合机器学习和统计方法的创新方法来提高预测精度。例如,已经提出将高斯过程回归(Gaussian process regression, GPR)与卷积神经网络(convolutional neural networks, CNN)相结合来补充传统的数值模拟。该混合模型旨在克服传统模拟的资源密集性,实现水平井参数的快速优化^[16-17]。另一种新颖的方法是使用粒子群优化算法(particle swarm optimization, PSO)优化的带有4个参数的新灰色模型,该模型解决了现有灰色模型特征表达不足、参数优化不足等缺点,粒子群算法与灰色建模相结合,预测精度更高,计算成本更低^[18-20]。

预测产量和估算最终采收率(estimated ultimate recovery, EUR)对于优化页岩气开发至关重要,产量递减通常会受到多种因素的影响,单纯使用超双曲线递减模型的观察时间无法充分反映这些变化,且需要稳健数据和仔细参数估计^[21]。现提出将具有时间属性的复合函数与超双曲线递减模型进行融合的方法,同时采用自适应粒子群优化算法寻找最优模型参数的产量递减模型。

1 产量递减模型建立

1.1 复合时间递减模型

超双曲线递减模型(hyper-hyperbolic decline

model, HDM)是在双曲线递减的基础上发展起来的^[22-24],当双曲线递减指数 $b > 1$ 时,就进入了超双曲线递减阶段,产量下降的速度会随着时间的推移而加快。超双曲线递减模型的方程表示为

$$q(t) = \frac{q_i}{(1 + bd_i t)^{1/b}} \quad (1)$$

式(1)中: q 为产气量, m^3/d ; q_i 为初始产量, m^3/d ; b 为递减指数,无因次; d_i 为初始递减率, $1/d$; t 为生产时间, d 。

在开发过程中,天然气的产量递减通常会受到多种随时间变化的因素的不确定性影响,超双曲线递减模型有时难以准确描述产量递减的复杂性^[25]。具有时间属性的复合函数能更好地反映气藏系统的发展变化,因为它可以将时间视为一个动态的变量,而不仅仅是一个静态的观察时间。

$$T(t) = mt^b \quad (2)$$

式(2)中: m 为调整时间的影响因子。

将 T 视为一个具有时间属性的复合函数,这个复合函数能够有效地描绘出气藏系统随时间的演进,因为它把时间当作一个动态变量来处理(图1),而不是单纯作为一个静态的观测点。这样的处理方式使得函数能够捕捉到气藏系统在不同时间点的状态变化,从而提供一个更为动态和全面的系统描述。

m 的值可以根据实际情况进行调整,以反映时间对产量递减的具体影响。如果 m 的值较大,那么时间的影响就会更加显著;反之,如果 m 的值较小,那么时间的影响就会相对较小。通过调整 m 的值,可以使模型更好地适应不同的气藏条件和开发策略,从而提高预测的精度和可靠性。将时间的影响因素与超双曲线递减模型进行结合,建立复合时间递减模型(T-hyper-hyperbolic decline model, T-HDM),从而更准确地描述产量递减的过程,即

$$q(t) = \frac{q_i}{[1 + bd_i T(t)]^{1/b}} \quad (3)$$




图1 影响因子 m 随时间变化曲线

Fig. 1 The variation curve of impact factor m over time

油气藏的开发过程是一个复杂的动态过程,受到地质条件、流体性质、开发方式等多种因素的影响。将传统递减模型中的人们观察时间 t 转换为反应油气系统内变化的复合函数 $T(t)$,将时间与油气系统内变化的复合函数联系起来,可以更全面地考虑油气藏的时空演化规律,进而使递减模型更加符合实际情况,可以得到拟合精度较高的、新的产量递减方程。从油气藏系统内部时空角度考虑,重新完善递减模型。再通过实际气藏开发,调整复合函数 $T(t)$,将有助于进一步辨识油气藏内各种影响因素与时间 t 的变化规律。

1.2 粒子群算法及自适应优化

粒子群算法是一种基于群体智能的优化算法,具有收敛速度快、参数少,对高维度优化问题能快速收敛于最优解。在 PSO 中,每个粒子代表解空间中的一个潜在解,粒子通过跟踪个体历史最佳位置 p_{best} 和群体历史最佳位置 g_{best} 来更新自己的速度和位置^[26-28]。粒子的移动受到自身经验和群体经验的共同影响,通过这种方式,粒子群作为一个整体在解空间中搜索全局最优解。

PSO 算法包含速度更新和位置更新两个主要方程,其中速度更新公式,即粒子下一步迭代移动的距离和方向,也就是一个位置向量,即

$$v_i^{n+1} = \omega v_i^n + c_1 r_1 (p_{best_i}^n - x_i^n) + c_2 r_2 (g_{best}^n - x_i^n) \quad (4)$$

式(4)中: v_i 为粒子 i 的移动速度; ω 为粒子惯性权重; c_1 为个体加速常量; c_2 为群体加速常量; r_1 、 r_2 为位置权重; p_{best_i} 为粒子最优位置; g_{best} 为群体最优位置; x_i 为粒子位置; n 为迭代次数。

每个粒子的更新位置由当前位置和新计算的速度决定,即位置更新方程为

$$x_i^{t+1} = \omega v_i^t + c_1 r_1 (p_{best_i}^t - x_i^t) + c_2 r_2 (g_{best}^t - x_i^t) \quad (5)$$

每个粒子的速度和位置的参数相互依赖,即位置取决于速度,同时,速度依赖于位置。速度更新公式根据粒子自身的历史经验以及群体中其他粒子的信息来更新粒子的速度,其包括 3 个部分:考虑了粒子个体搜索能力,使粒子根据自身历史最佳位置进行调整,以便向历史最佳位置移动的个体经验项;考虑了粒子群体的合作搜索能力,使粒子根据群体中其他粒子的历史最佳位置进行调整,以便向全局最佳位置移动的社会经验项,以及用于平衡个体经验项和社会经验项的影响惯性权重,其随着迭代的进行逐渐减小,以增加算法的收敛性,3 个部分对于数据方向的调整如图 2 所示。

本文研究通过聚类算法将例子动态划分区域,通

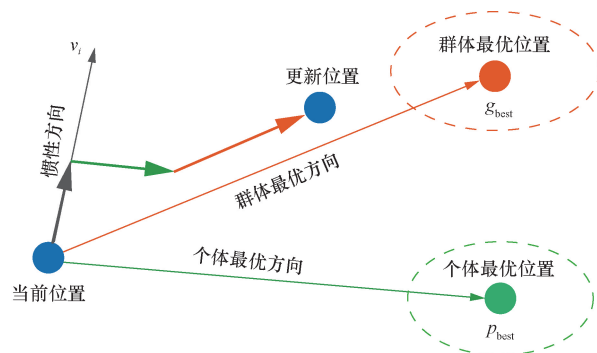


图2 粒子位置更新示意图

Fig. 2 Particle position update diagram

过区域划分平衡局部搜索与全局搜索的能力,提高算法的收敛速度和精度;同时根据粒子间的距离动态调整惯性权重[自适应惯性权重,式(6)]和加速度因子[自适应加速度因子,式(7)],使粒子在全局搜索和局部搜索之间切换,实现例子间的信息素增量的自适应策略,构建自适应粒子群优化算法。

惯性权重调整,在收敛初期保持较大的惯性权重,以促进全局搜索,随着迭代进行,逐步减小惯性权重,增强局部搜索能力。

$$\omega = \omega_{max} \left(\frac{\omega_{min}}{\omega_{max}} \right)^{\frac{iter}{iter_{max}}} \quad (6)$$

式(6)中: ω_{max} 、 ω_{min} 为最大、最小惯性权重; $iter$ 为迭代次数; $iter_{max}$ 最大迭代次数。

加速度因子调整,根据粒子在簇内和全局最优解之间的相对位置,动态调整个体和群体加速度因子。

$$c_i = c_{i,min} + \frac{f_{best} - f_i}{f_{best} - f_{worst}} (c_{i,max} - c_{i,min}) \quad (7)$$

式(7)中: c_i 为粒子 i 的加速度因子; $c_{i,max}$ 、 $c_{i,min}$ 为粒子 i 的最大、最小加速度因子; f_i 为粒子 i 的适应度值; f_{best} 、 f_{worst} 为当前群体中的最优、最差适应度值。

通过动态调整粒子的学习速度和方向,使其能够更有效地搜索全局最优解,特别是在处理连续变量时,信息素增量根据每次迭代开始时找到的最优解的启发式值自适应调整。这种方法有助于保持探索和利用之间的有效平衡,寻找最优的参数组合,从而提高算法的收敛性,以最小损失率拟合历史产量数据。

2 模型建立

2.1 待定参数优化模型建立

递减模型由 4 个参数特征化:初始产量率 q_i 、递减率 d_i 、递减曲线指数 b 、时间复合函数影响因子 m 。在历史产量数据上采用 A-PSO 算法寻找让递减模型具有最优历史生产拟合效果参数组。首先定义目标函数用于评价优化模型的性能,同时确

定模型待定参数优化阈值,这些超参数的阈值将确定一个以超参数取值为因变量的求解空间,避免出现拟合或者欠拟合的情况。PSO算法在给定的求解空间内寻找能够最优化拟合的参数组合,即通过最小化目标函数来优化待定参数^[28]。

$$\begin{cases} \min f(X) \\ g_i(X) \leq g_i, \quad i = 1, 2, \dots, n \end{cases} \quad (8)$$

在模型拟合的过程中,将模型拟合到生产数据上,并使用最佳拟合参数来计算决定系数(R -squared, R^2),以评估拟合的质量。同时,通过计算残差的标准差来计算拟合曲线和未来预测的不确定性,参数优化过程中可到一组对应的超参数值 x_i^k ,整体优化策略如下。

(1)定义目标函数来评估模型的性,这个函数通常是基于预测值和实际值之间的误差。

(2)在A-PSO中,每个粒子代表了一组潜在的解决方案,即模型参数的一个组合,需要随机初始化一群粒子的位置和速度。

(3)为算法设置适当的参数,如粒子群的大小、最大迭代次数、惯性权重、个体学习因子和社会学习因子。

(4)迭代优化:①由粒子当前位置和速度,以及历史最优位置和全局最优位置,更新粒子的位置和速度;②根据目标函数评估每个粒子的适应度,即模型的拟合程度;③根据粒子的适应度更新历史最优位置和全局最优位置。

(5)最终的 g_{best} 代表了优化后的模型参数,根据全局最优位置得到最优的参数组合,即为优化后的产量递减模型参数。

2.2 递减模型建立

在进行产量数据分析前,需要进行一些必要的数据处理步骤包括数据清洗、数据标准化或归一化、处理缺失值、拆分训练集和测试集等,以确保数据的质量和模型的准确性,模型建立流程如图3所示。

使用自适应粒子群优化算法A-PSO对递减模型参数进行优化,在参数控件中初始化粒子,以每个例子的位置和速度初始化为随机值,目标函数定义为拟合数据的均方误差(mean square error, MSE),用于计算每个例子的适应度。

$$MSE = \frac{1}{N} \sum_{i=1}^n [x(t_i, R) - \hat{x}_i]^2 \quad (9)$$

式(9)中: N 为样本数量; $x(t_i, R)$ 在时间 t_i 和参数 R 下的模型输出值; R 为模型待优化的参数向量; \hat{x}_i 为第 i 个时间点对应的观测值。

对于每个粒子,记录当前的最优位置(个体最佳位置 p_{best});新全局最佳位置(全局最佳位置 g_{best});

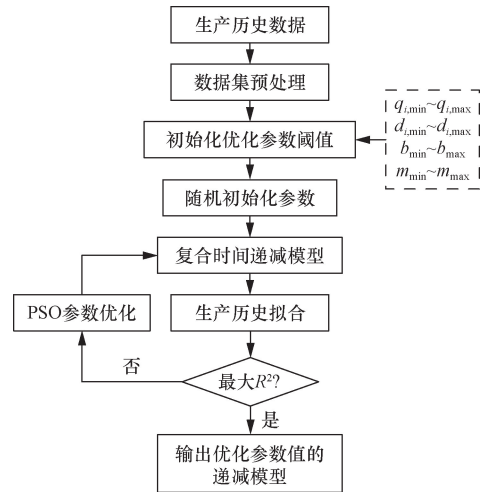


图3 模型建立流程图
Fig. 3 Model building flow chart

根据粒子位置和速度更新公式更新。同时采用 R^2 衡量每组参数在历史生产数据的拟合效,用于衡量独立变量对因变量变异性的解释程度。 R^2 介于 $0 \sim 1$,其中 $R^2 = 0$ 表示模型无法解释任何变异性,而 $R^2 = 1$ 表示模型完美地解释了所有变异性。

$$R^2 = \frac{1 - SS_{res}}{1 - SS_{tot}} \quad (10)$$

式(10)中: SS_{res} 为残差平方和,即观测值与模型预测值之差的平方和; SS_{tot} 为总平方和,即观测值与观测值平均数之差的平方和。

在复合时间递减模型的非线性背景下,结合自适应粒子群优化(A-PSO)算法能够对时间序列及其导数进行稳健的估计,这对于重建高分辨率的过程变化记录至关重要。A-PSO通过动态调整算法的控制参数,增强了优化过程的自适应性,进一步提高了算法在复杂系统中的表现。同时,其优化能力使其能够有效融合稀疏采样的时间序列数据与模拟的产量变化,从而全面捕捉产量递减过程的细微变化。通过这种方式,A-PSO不仅改善了模型在时间上的动态预测能力,还在实际应用中显著优化了模型的性能,进而提升了预测的准确性和可靠性。

3 实例应用

3.1 数据处理

数据预处理是石油工程中对原始采气数据进行清洗、转换、规范化等处理的过程,由于传感器故障、采集错误或其他操作问题导致数据错误、缺失。为了确保数据分析和建模的准确性,需要对这些缺失值进行合理的处理以便于进行更精确的分析、建模或优化。对于数据中存在的缺失值,采用了高效的随机森林插值法,该方法通过以下步骤来进行空

缺值的填充。

(1)对数据集中的缺失值用相应变量的中位数/均值、众数进行初始填充。

(2)将已知的变量作为模型输入,同时把含有缺失值的变量作为标签值来训练随机森林模型。

(3)使用训练好的模型来预测并填补缺失值。

3.2 区块应用

使用 CN 页岩气区块部分井的实测数据对单井历史产量数据进行拟合分析和预测,以该区块 2015—2022 年日产气量数据作为该模型测试数据建立产量递减模型并检验模型实际效果。由该区块实际情况合理设置这些参数的范围,以确保模型的拟合效果和预测的准确性,同时将参数限制在一定的范围内变化在一定的范围内变化。此外,还设置了拟合曲线和预测曲线的显著性水平,表示希望模型的拟合和预测结果具有较高的置信度,同时在未来产量预测的过程中,预测了历史数据之后指定天数的未来产量,通过预测准确情况可以为模型准确性提供依据。

3.3 对比分析

以该区块生产井拟合预测结果如图 4 所示,其不确定拟合带和预测不确定带明显低于基础递减模型,如图 5 所示,T-HDM 递减模型计算 EUR 值更接近于真实生产数据拟合预测效果有明显提升。

HDM 递减模型在描述初期和后期递减时相对简化,但并没有考虑到页岩气井的复杂开采特性。超双曲模型适用于传统油气田,但在页岩气的开发中,由于页岩气井的储层特性,它的拟合效果不一定理想,特别是在高压水力压裂或长时间生产情况下,模型的预测能力可能较差。Duong 模型虽然在一定程度上能捕捉页岩气井的前期快速递减特性,但仍然存在简化假设,对于生产后期的递减过程拟合差。T-HDM 模型能够更加灵活和精确地反映页岩气井的产量衰减过程,从而提供更可靠的预测,尤其适用于非常规油气的开采。

在模型拟合的过程中,将模型拟合到生产数据上,并使用最佳拟合参数来计算 R^2 ,以评估拟合的质量,同时,通过归一化均方差来计算拟合曲线和未来预测的不确定性。

此外,模型质量对比采用赤池信息量准则 (akaike information criterion, AIC) 和贝叶斯信息准则 (Bayesian information criterion, BIC),对于同一个数据样本,AIC 和 BIC 数值小的模型更好。

$$\begin{cases} AIC = 2k - 2\ln L \\ BIC = k\ln m - 2\ln L \end{cases} \quad (11)$$

式(11)中: m 为数据点数; k 为模型参数个数; L 为模

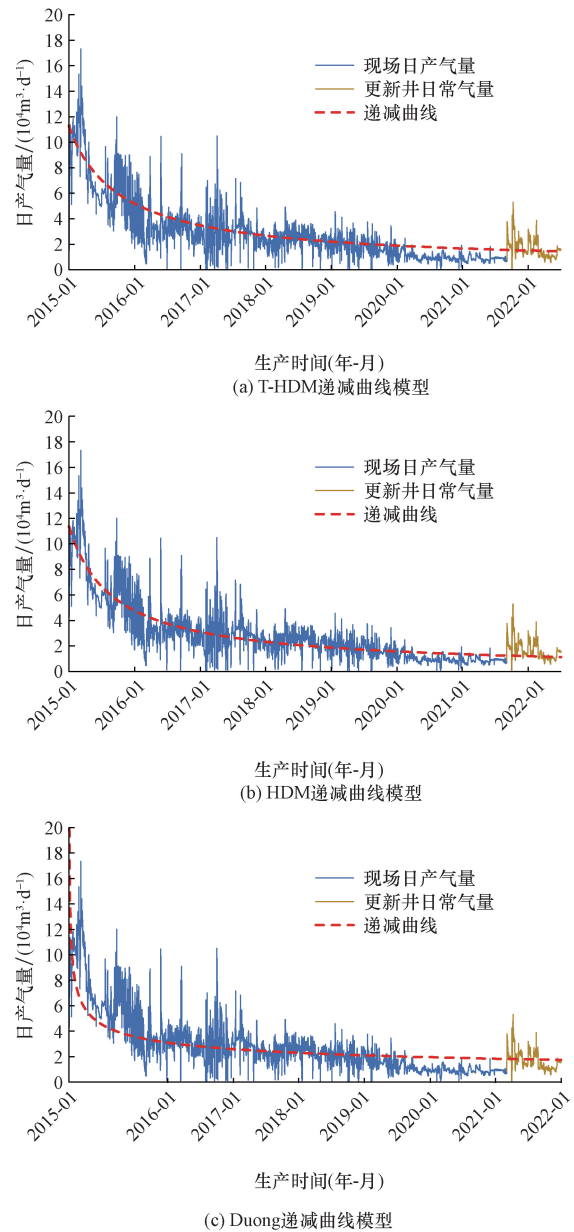


图 4 递减模型拟合效果图

Fig. 4 Decreasing model fitting prediction effect diagram

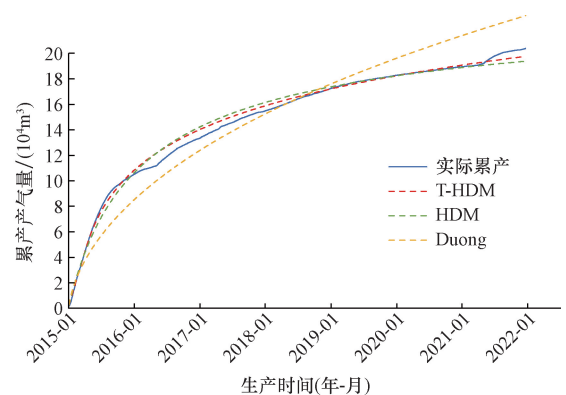


图 5 预测累计产量对比图

Fig. 5 Comparison chart of predicted cumulative production

型的最大似然估计值。

如表 1 所示,复合时间递减模型 T-HDM 较 HDM 模型的 R^2 有明显提升,拟合误差也得到较好的控制。同时,AIC 和 BIC 数值都减小了 25%,说明模型的拟合效果得到了改善,T-HDM 能更准确地描述了数据的变化趋势,能更好地捕捉生产模式。

表 1 递减模型对比

Table 1 Decline model comparison

| 模型 | $R^2/\%$ | NMSE | AIC | BIC |
|-------|----------|-------|-----------|-----------|
| T-HDM | 87.853 | 0.121 | 3 068.488 | 3 092.161 |
| HDM | 74.628 | 0.177 | 4 112.060 | 4 129.815 |
| Duong | 70.212 | 0.197 | 4 890.023 | 4 921.412 |

4 结论

(1)时间属性与超双曲递减的融合模型是一种有效的产量预测工具,它结合了指数递减和双曲递减两种模型的优点,能够较好地描述油气井在不同阶段的产量变化。

(2)采用自适应粒子群优化算法 A-PSO 进行递减模型待定参数选择,通过个体局部信息和群体全局信息的协同搜索,使得整个群体能够有效地向最优解靠拢,参数选择以实际生产数据为基础,使得拟合预测更具客观性,极大程度的避免了传统方式的主观性误差。

(3)使用时间属性与超双曲递减的融合模型通过对历史产量数据的拟合,可以精准预测气井的未来产量,比常规递减模型提高产量精度在 25% 以上。

参 考 文 献

[1] 徐兵祥,白玉湖,陈岭,等. 页岩气解析模型产量预测技术优化方案[J]. 科学技术与工程, 2021, 21(9): 3571-3575.
Xu Bingxiang, Bai Yuhu, Chen Ling, et al. Optimization of production forecasting technique using analytical models for shale gas wells[J]. Science Technology and Engineering, 2021, 21(9): 3571-3575.

[2] 孙焕泉,蔡勋育,胡德高,等. 页岩气立体开发理论与实践——以四川盆地涪陵页岩气田为例[J]. 石油勘探与开发, 2023, 50(3): 573-584.
Sun Huanquan, Cai Xunyu, Hu Degao, et al. Theory, technology and practice of shale gas three-dimensional development: a case study of Fuling shale gas field in Sichuan Basin, SW China[J]. Petroleum Exploration and Development, 2023, 50(3): 573-584.

[3] 闫建平,罗静超,石学文,等. 川南泸州地区奥陶系五峰组—志留系龙马溪组页岩裂缝发育模式及意义[J]. 岩性油气藏, 2022, 34(6): 60-71.
Yan Jianping, Luo Jingchao, Shi Xuewen, et al. Fracture development models and significance of Ordovician Wufeng Silurian Longmaxi shale in Luzhou area, southern Sichuan Basin[J]. Lithologic

Reservoirs, 2022, 34(6): 60-71.

[4] Tan L, Zuo L H, Wang B B. Methods of decline curve analysis for shale gas reservoirs [J]. Energies, 2018, 11(3). DOI: 103390/en11030552.

[5] Cathles L M, Milton L B. A commentary on ‘The greenhouse-gas footprint of natural gas in shale formations’ by R. W. Howarth, R. Santoro, and anthony ingraffa[J]. Climatic Change, 2012, 113(2): 525-535.

[6] 张荻荻,李治平,苏皓. 页岩气产量递减规律研究[J]. 岩性油气藏, 2015, 27(6): 138-144.
Zhang Diqiu, Li Zhiping, Su Hao. Production decline trend of shale gas[J]. Lithologic Reservoirs, 2015, 27(6): 138-144.

[7] 余果,刘海峰,李海涛,等. 川南页岩气峰值产量预测[J]. 天然气勘探与开发, 2023, 46(1): 97-104.
Yu Guo, Liu Haifeng, Li Haitao, et al. Prediction on peak production of shale gas, southern Sichuan Basin[J]. Natural Gas Exploration and Development, 2023, 46(1): 97-104.

[8] Shin H, Nguyen-Le V, Kim M, et al. Development of production-forecasting model based on the characteristics of production decline analysis using the reservoir and hydraulic fracture parameters in montney shale gas reservoir, Canada[J]. Geofluids, 2021, 2021: 1-12.

[9] Fetkovich M J, Fetkovich E J, Fetkovich M D. Useful concepts for decline curve forecasting, reserve estimation, and analysis [J]. SPE Reservoir Engineering, 1996, 11(1): 13-22.

[10] Manda P, Nkazi D B. The evaluation and sensitivity of decline curve modelling [J]. Energies, 2020, 13(11). DOI: 10.3390/en13112765.

[11] Rezaei-pour A, Dabir B, Ahmadi M. Data-driven approach to dynamic uncertainty quantification of oil well production: decline curve analysis and Hidden Markov model[J]. Geoenergy Science and Engineering, 2023, 229. DOI: 10.1016/j.geoen.2023.212131.

[12] Jha H S, Lee W J. Modifications for fracture damage and changing pressure drawdown to improve accuracy of Duong decline model[C]//SPE/AAPG/SEG Unconventional Resources Technology Conference. Austin; SPE, 2017. DOI: 10.15530/urtec-2017-2697591.

[13] Belyadi H, Fathi E, Belyadi F. Chapter seventeen-decline curve analysis, hydraulic fracturing in unconventional reservoirs [M]. 2nd ed. New York; Gulf Professional Publishing, 2019.

[14] 张德良,吴建发,张鉴,等. 北美页岩气规整化产量递减分析方法应用研究——以长宁-威远示范区为例[J]. 科学技术与工程, 2018, 18(34): 51-56.
Zhang Deliang, Wu Jianfa, Zhang Jian, et al. An application of the normalized rate decline analysis method in Changning-Weiyuan Demonstration Area [J]. Science Technology and Engineering, 2018, 18(34): 51-56.

[15] 姚秀田. 水驱油藏产量递减主控因素确定与应用[J]. 科学技术与工程, 2021, 21(9): 3582-3587.
Yao Xiutian. The determination method of controlling factor of production decline and its application in water-flooding reservoirs[J]. Science Technology and Engineering, 2021, 21(9): 3582-3587.

[16] Wang H J, Qiao L, Lu S F, et al. A novel shale gas production prediction model based on machine learning and its application in optimization of multistage fractured horizontal wells[J]. Frontiers in Earth Science, 2021, 9. DOI: 10.3389/feart.2021.726537.

[17] Lu C H, Jiang H Q, Yang J L, et al. Shale oil production predic-

- tion and fracturing optimization based on machine learning[J]. Journal of Petroleum Science and Engineering, 2022, 217. DOI: 10.1016/j.petrol.2022.110900.
- [18] Zeng B, Chen G, Meng W, et al. Prediction, analysis and suggestions of shale gas production in China based on a new grey model with four parameters[J]. Alexandria Engineering Journal, 2024, 86: 258-276.
- [19] Ren B Q, Jiang C W. A review on the economic dispatch and risk management considering wind power in the power market[J]. Renewable and Sustainable Energy Reviews, 2009, 13(8): 2169-2174.
- [20] Wang D S, Tan D P, Liu L. Particle swarm optimization algorithm: an overview[J]. Soft Computing, 2018, 22(2): 387-408.
- [21] 吴忠维, 崔传智, 王振, 等. 特高含水期产量递减规律及递减率的计算公式[J]. 中国科技论文, 2018, 13(15): 1778-1782.
Wu Zhongwei, Cui Chuazhi, Wang Zhen. Production decline law and calculation formula of decline rate at ultra-high water cut stages[J]. China Sciencepaper, 2018, 13(15): 1778-1782.
- [22] 黄广庆. 特高含水期产量递减分析及递减率表征公式[J]. 科学技术与工程, 2019, 19(15): 99-104.
Huang Guangqing. Production decline analysis and characterization formula of decline rate at the ultra-high water cut stage[J]. Science Technology and Engineering, 2019, 19(15): 99-104.
- [23] 何德志. 大洼油田洼 20 区块产油量递减规律研究[J]. 岩性油气藏, 2009, 21(3): 105-107.
He Dezhi. Oil production decline law of Wa 20 block in Dawa Oilfield[J]. Lithologic Reservoirs, 2009, 21(3): 105-107.
- [24] 王勇. 碳酸盐岩油藏油水两相不稳定渗流理论研究[D]. 成都: 成都理工大学, 2017.
Wang Yong. Research on oil and water two-phase unsteady seepage in carbonate reservoir[D]. Chengdu: Chengdu University of Technology, 2017.
- [25] 白玉湖, 陈桂华, 徐兵祥, 等. 页岩气产量递减典型曲线模型及对比研究[J]. 中国石油勘探, 2016, 21(5): 96-102.
Bai Yuhu, Chen Guihu, Xu Bingxiang, et al. Comparison of typical curve models for shale gas production decline prediction[J]. China Petroleum Exploration, 2016, 21(5): 96-102.
- [26] 关翔予, 王庆辉. 基于 PSO 优化的形状记忆合金驱动器自适应滑模控制研究[J]. 工业仪表与自动化装置, 2024(2): 113-117.
Guan Xiangyu, Wang Qinghui. Research on adaptive sliding mode control of shape memory alloy driver based on PSO optimization[J]. Industrial Instrumentation & Automation, 2024(2): 113-117.
- [27] 王丽, 王山山, 杨威. 改进的粒子群波阻抗反演方法与应用[J]. 岩性油气藏, 2011, 23(1): 103-106.
Wang Li, Wang Shanshan, Yang Wei. Improved method of particle swarm impedance inversion and its application[J]. Lithologic Reservoirs, 2011, 23(1): 103-106.
- [28] Wang J, Kumbasar T. Parameter optimization of interval type-2 fuzzy neural networks based on PSO and BBBC methods[J]. IEEE/CAA Journal of Automatica Sinica, 2019, 6(1): 247-257.