基于经验回放持续学习的钻速预测方法研究

孙韫泽[1]，黄新武[1,2*]，王 瑜[1,2]，栗 柱[1]
（1.中国地质大学(北京)工程技术学院，北京 100083；2.中国地质大学(北京)深部探测与成像全国重点实验室，北京 100083）

摘要：针对钻井过程地层与工况随井深变化引发概念漂移、静态模型难以适应、简单增量更新易产生灾难性遗忘的问题，提出一种基于时间卷积网络(TCN)与经验回放的持续学习钻速预测方法。以USROP公开数据集为研究对象，利用因果滑动窗口构造11变量钻井序列，以机械钻速(ROP)为监督目标；采用“先预测、后更新”的预序贯评价范式，A2、A3、A4井段用于模型训练与持续学习策略选择，A5井段开展外部测试，并以A2、A3、A4锁定井段审查旧知识保持情况。结果表明：A5井测试中，持续学习模型R^2、RMSE和MAE分别为0.906、4.055 m/h和1.843 m/h，RMSE和MAE较静态基础模型分别降低8.64%和31.35%，较朴素增量微调模型分别降低6.66%和19.64%；锁定井段审查中RMSE为1.946 m/h，优于朴素增量微调模型的4.839 m/h与静态基础模型的2.108 m/h，有效缓解了灾难性遗忘。该方法兼顾新井段适应能力与旧知识稳定性，可为智能钻井随钻动态预测与参数闭环优化提供技术支撑。

关键词：机械钻速；钻速预测；时间卷积网络；持续学习；经验回放；灾难性遗忘；概念漂移；智能钻井
中图分类号：P634.9 **文献标识码**：A **文章编号**：2096-9686(2026)06-0033-09

Research on a rate of penetration prediction method based on continual learning with experience replay

SUN Yunze[1], HUANG Xinwu[1,2*], WANG Yu[1,2], LI Zhu[1]
(1. *School of Engineering and Technology, China University of Geosciences, Beijing* 100083, *China*; 2. *State Key Laboratory of Deep Earth Exploration and Imaging, China University of Geosciences, Beijing* 100083, *China*)

Abstract: To address the problems that concept drift induced by varying formations and drilling conditions along well depth hinders the adaptation of static models, and that simple incremental updating tends to cause catastrophic forgetting, a continual learning method for rate of penetration (ROP) prediction based on a temporal convolutional network (TCN) and experience replay is proposed. Using the publicly available USROP dataset, causal sliding windows were employed to construct 11-variable drilling sequences, with ROP as the supervised target. A "predict-first, update-later" prequential (test-then-train) evaluation paradigm was adopted: the sections of Wells A2, A3 and A4 were used for model training and continual learning strategy selection, the A5 well section was used for external testing, and the locked sections of Wells A2, A3 and A4 were used to examine old knowledge retention. The results show that in the A5 well test, the continual learning model achieved R^2, RMSE and MAE values of 0.906, 4.055 m/h and 1.843 m/h, respectively; its RMSE and MAE decreased by 8.64% and 31.35% compared with the static baseline model, and by 6.66% and 19.64% compared with the naive incremental fine-tuning model. In the locked-section examination, the RMSE of the continual learning model was 1.946 m/h, lower than 4.839 m/h of the naive incremental fine-tuning model and 2.108 m/h of the static baseline model, indicating that catastrophic forgetting was effectively mitigated. The proposed method balances the

收稿日期：2026-07-31；**修回日期**：2026-09-17 **DOI**：10.12143/j.ztgc.2026.06.004
基金项目：国家科技重大专项专题(编号：2024ZD1003105.4)
第一作者：孙韫泽，男，汉族，2002年生，硕士研究生，地质资源与地质工程专业，研究方向为钻探自动化与智能化控制，北京市海淀区学院路29号，2002240041@email.cugb.edu.cn。
通信作者：黄新武，男，汉族，1972年生，副教授，地质工程专业，博士，研究方向为钻探自动化与智能化、工程物探、资源与环境勘查等，北京市海淀区学院路29号，hxw666@hotmail.com。
引用格式：孙韫泽，黄新武，王瑜，等.基于经验回放持续学习的钻速预测方法研究[J].钻探工程，2026，53(6)：33-41.
SUN Yunze, HUANG Xinwu, WANG Yu, et al. Research on a rate of penetration prediction method based on continual learning with experience replay[J]. Drilling Engineering, 2026, 53(6): 33-41.

adaptability to new well sections and the stability of old knowledge, and can provide technical support for real-time dynamic prediction while drilling and closed-loop parameter optimization in intelligent drilling.

Key words: rate of penetration; rate of penetration prediction; temporal convolutional network; continual learning; experience replay; catastrophic forgetting; concept drift; intelligent drilling

0 引言

机械钻速(rate of penetration,ROP)是衡量钻进效率的直接指标,关系到钻井周期与工程成本。钻压、转速、扭矩、排量、钻头状态和地层性质共同作用于钻速,且这些因素之间存在明显的非线性耦合。经验公式和机理模型便于解释工程规律,但其参数往往依赖具体的地层和施工条件,工况发生变化后,预测误差容易增大。

数据驱动方法为描述这种复杂关系提供了新的途径。刘胜娃等[1]针对定向井工况建立人工神经网络钻速预测模型;宋先知等[2]在塔里木盆地数据上比较多种方法后,认为支持向量机回归具有较好的准确性和稳定性。仉文岗等[3]以TBM掘进速度为研究对象,将随机森林(RF)与粒子群优化、遗传算法、差分进化和贝叶斯优化相结合,并借助敏感性分析筛选关键变量。其研究对象虽不同于钻井,但表明传统机器学习模型的预测表现不仅取决于算法类型,也受超参数设置和输入变量质量影响。

钻井参数数量多、相关性强,冗余变量会干扰模型训练。周长春等[4]将相关性分析、方差过滤和互信息评价结合,构建融合特征选择方法;胥知画等[5]进一步利用粒子群算法优化筛选阈值,并在多口井数据上比较BP、决策树、梯度提升树和随机森林等模型。这些工作改善了离线训练阶段的特征质量和模型泛化能力,但其评价通常建立在相对固定的训练集与测试集划分上,难以反映模型面对连续新井段时的性能变化。

钻进数据沿井深持续产生,地层特征、钻头磨损程度和操作参数也会随之变化。甘超等[6]通过区域多井数据优选和模型预训练建立初始预测模型,再结合增量更新开展深部地质钻探过程的动态预测。张琦等[7]采用滑动窗口更新策略进行在线区间预测,在给出钻速预测值的同时刻画不确定性。李同意等[8]从主井与历史井实时数据流比对出发讨论模型更新与复用。Gan等[9]利用移动井深窗口交替完成建模和预测。Bertini等[10]则将钻速预测置于数据流学习框架下,讨论概念漂移处理对预测误差和计算效率的影响。不同研究的技术路线并不相同,但共同指向一个问题:模型需要随新工况更新,而不能仅依赖初始训练结果。

在预测器设计上,时间卷积网络(TCN)通过因果卷积、扩张卷积和残差连接提取不同时间尺度的序列特征。Bai等[11]指出,卷积时序结构在多类序列建模任务中具有较强竞争力。Sun等[12]将TCN与Informer用于多步钻速预测,验证了时序卷积结构处理连续钻进数据的可行性。与仅使用当前时刻参数的静态模型相比,TCN能够在不使用未来信息的条件下利用更长范围的历史工况信息。

目前的研究已涉及特征优选、多井资料利用、在线更新和预测不确定性,但关注重点大多是新到达样本上的即时精度。模型在新井段持续更新后,是否仍能保持对早期工况的预测能力,尚缺少针对性的检验。持续学习强调模型在顺序到达、分布可能变化的数据上学习新知识,同时尽量保持已有任务性能[13-14]。钻进过程中的地层变化、钻头状态变化和操作参数调整可视为概念漂移[15];若模型反复利用近期样本更新,可能出现新知识覆盖已有表征的灾难性遗忘[16]。预序贯(test-then-train)评价规定“先预测、获得真实值后再更新”的顺序[17],经验回放则通过在更新时混入代表性历史样本,为兼顾新旧工况提供了可行方法[18]。

为此,本文探索利用经验回放持续学习框架,形成“离线初始化—数据流预测—标签成熟—增量更新—旧知识审查”的完整流程,并完成经验回放持续学习模型、朴素增量微调模型与静态批量学习模型的对比试验,以及模型适应新数据后对之前井段知识的保持性试验。

1 数据来源与预处理

1.1 数据来源与变量构成

试验采用Tunkiel等[19]发布的University of Stavanger Rate of Penetration(USROP)公开基准数据集。该数据集包含7口井近20万条采样记录,可支持跨井与连续井段评价。本文利用其中A2、A3、

A4、A5共4口井开展有关研究,原始字段包括测量井深(MD)、钻压(WOB)、立管压力(SPPA)、扭矩(Torque)、转速(RPM)、排量(TFLO)、泥浆密度(MudWeight)、井径(Diameter)、大钩载荷(HKLD)、垂深(TVD)、伽马值(Gamma)及ROP。表1为各数据字段及其工程含义。

表1　数据字段及工程含义

Table 1　Data fields and engineering meanings

变量类别	变　量	主　要　含　义
井深与轨迹	MD、TVD	表征钻进位置及井眼轨迹变化
机械参数	WOB、Torque、RPM、HKLD	表征钻头载荷、旋转与钻具受力状态
水力与流体参数	SPPA、TFLO、MudWeight	反映循环系统、携岩与井底水力条件
井眼与地层参数	Diameter、Gamma	反映井径和地层响应差异
预测目标	ROP	机械钻速,单位为m/h

1.2　数据清洗

为降低原始随钻数据中重复采样、局部异常及采样间隔不一致对模型训练的影响,首先按照测量深度对数据进行升序排列,并对重复深度记录的数值变量取中位数。随后构建间隔为0.05 m的统一深度数据列,采用中位数聚合,降低数据对瞬时噪声的敏感性。

Hampel方法是一种基于滑动窗口、中位数和中位数绝对偏差(MAD)的稳健离群点识别方法,可降低异常观测对过程建模的影响[20]。针对钻压、立管压力、地面扭矩和大钩载荷等连续变量,采用窗口长度为5的Hampel方法识别局部异常,仅修正持续长度不超过2个网格的异常点。对于多参数同步变化或伴随转速改变的连续变化予以保留,以避免误删真实工况转换。对于转速、排量、泥浆密度和井径等存在阶段式变化的参数,不进行平滑处理。对于跨度不超过1 m且两端均存在有效观测的短缺口,连续变量采用线性插值,阶梯变量采用最近邻填补;长缺失区间保持为空。ROP作为预测目标,不进行平滑、插值或异常替换,仅保留真实观测标签。最终筛选正常钻进、目标有效且输入特征完整的样本,并在建模阶段仅利用训练集统计量完成标准化,防止测试信息泄露。

清洗后,少量异常数据得到修正,短距离的缺失值得到了合理填补,长距离的缺失区间则保留,避免产生虚假数据。处理后的数据整体趋势与原始数据一致,但异常尖峰有所减少,数据连续性和稳定性得到改善。图1为A4井段数据清洗前后对比。

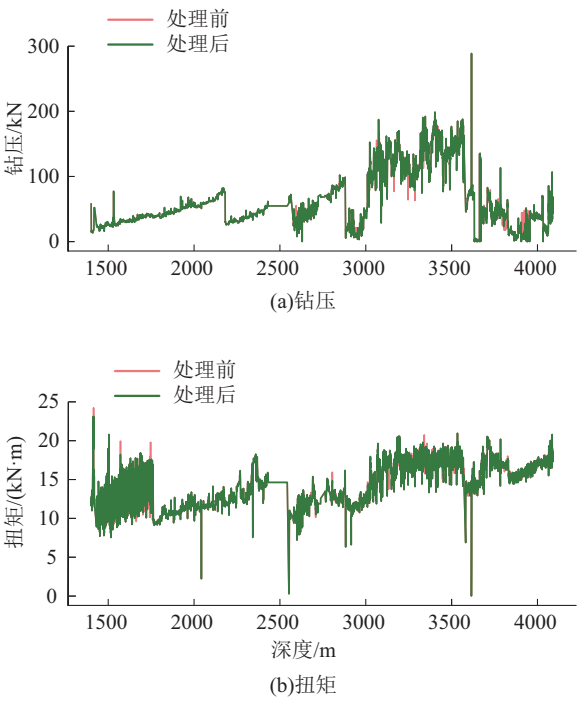

图1　A4井段数据清洗前后对比

Fig.1　Comparison of data before and after data cleaning for Well A4 section

1.3　数据标准化

在数据预处理阶段,不同的特征属性的数据量级存在显著差异,例如平均立管压力的特征值跨度较大,而扭矩的特征值跨度又太小。这种量级上的巨大差异可能会对模型的性能产生不利影响。为了消除因量级差异产生的影响,并提高模型的预测准确度,需要对数据进行标准化处理,确保所有的特征都处于同一数量级。

Z-Score标准化基于原始数据的均值和标准差进行标准化处理,使处理后的数据服从标准正态分布。该函数可将不同量级的数据转化为标准化值,确保数据间的可比性。计算过程:

$$x'_{i,j}=(x_{i,j}-\mu_j)/\sigma_j \tag{1}$$

式中:$x'_{i,j}$——标准化后的特征值;$x_{i,j}$——第i个样本中第j个特征的原始值;μ_j——训练集中的均值;σ_j——标准差。

2 持续学习方法与工作流程

2.1 持续学习与概念漂移

持续学习(continual learning)是指模型面对按顺序到达、分布可能变化的数据时,持续学习新井段数据特征并尽量保持既有预测能力的一种预测方式[14]。设第k个数据块为D_k,模型参数为θ_k,更新算子为U,则:

$$\theta_k = U(\theta_{k-1}, D_k) \tag{2}$$

在钻进过程中,输入分布$P(X)$可能因操作范围变化而改变,条件关系$P(\mathrm{ROP}|X)$也可能因地层或钻头状态变化而改变,这类随数据流演化的分布变化可归入概念漂移问题[21]。

持续学习的核心是稳定性与可塑性的平衡:可塑性要求模型快速适应新井段,稳定性要求学习新井段后尽量保持旧井段预测能力。神经网络若只在最新数据上反复微调,可能出现新知识覆盖原有参数表征,即灾难性遗忘[14-16]。因此,持续学习不能简化为"继续训练",还必须包含知识保持机制和遗忘评价。

2.2 持续学习与经验回放工作流程

本文将按井深排序的数据划分为$D_1, D_2, \cdots, D_k$等连续数据块。对任一新块D_k,系统首先使用更新前模型$f_{\theta_{k-1}}$生成预测并记录误差;待获得该数据块的真实钻速后,才允许其参与模型更新;随后使用当前数据块与回放样本得到新的模型参数,更新后的模型只能评价下一数据块及其后的数据。该过程属于数据流学习中常用的预序贯评价方式[10]。

Rolnick等[18]指出,经验回放机制能够兼顾模型学习新知识的可塑性与保留旧知识的稳定性,通过在当前更新批次中混入历史代表样本,避免模型完全由最新井段主导。本文设置固定容量的历史数据池,每次更新时从中抽取历史样本,并与当前数据流样本共同训练。

$$\hat{y}_k = f_{\theta_{k-1}}(X_k) \tag{3}$$

$$\theta_k = U(\theta_{k-1}, D_k \cup M_k) \tag{4}$$

式中:$\hat{y}_k$——预测值;X_k——第k个数据块的数据序列;M_k——从历史回放池抽取的代表性样本。

静态基础模型与持续学习模型使用相同初始权重和相同数据,两者的差异是前者参数被冻结,后者在每块评价结束后更新参数。

2.3 滑动窗口构造

本文建立滑动窗口(图2),模型将基于可见的钻井数据学习识别并挖掘钻井数据和地质参数之间的复杂关系,设窗口长度为$L=40$,第t个样本的输入Z_t由截至当前位置已经获得的连续数据构成:$Z_t=[X_{t-L+1}, \cdots, X_t]$,其中每个$X_t$包含钻压、立管压力、扭矩、转速、排量、泥浆密度、井径、大钩载荷、垂深、伽马值、历史ROP共11个变量,测量井深MD仅用于数据排列、井段划分和预测结果定位,不作为模型输入;模型直接输出未来4步ROP,即$\hat{Y}_t=\left[\widehat{\mathrm{ROP}}_{t+1}, \cdots, \widehat{\mathrm{ROP}}_{t+4}\right]$。本文设置窗口必须在连续段内部构造,不允许跨越高深度断点,避免不相邻的钻井数据导致模型学习到虚假变化。

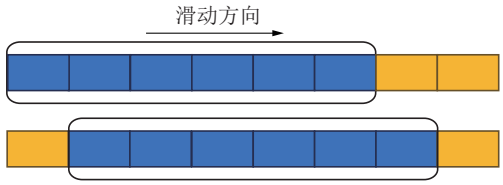

图2 滑动窗口图解

Fig.2 Schematic diagram of sliding window

3 模型评价与结果分析

3.1 数据集划分

本试验将数据按井划分,由于不同井的数据之间既有相似共通的特性,也存在各自独有的特性,若只选择一口井进行训练与验证,将模型应用于其他井时,不同井之间的差异将导致模型的精度降低,模型泛化性较差,所以在模型训练与验证时,需要选择多口不同井的数据,以学习到这些不同井数据的共性,忽略掉单口井自有的特性,才能使模型在未来钻井作业中具备更高的预测精度。据此,本文选择四口井的钻井数据,其中三口井的数据用于模型训练与验证,一口没有参与模型训练与验证的井用于模型测试。将A2、A3、A4井尾部约12%井段进行锁定,用于检查是否出现灾难性遗忘。A2、A3、A4三口井用于模型训练与验证,按井深划分训练与验证的数据,采用交叉验证的方法,按井深顺序选择未锁定井段上部或者下部50%的数据用于模型超参数调整和持续学习策略调整,剩下未锁定的数据用于模型训练,共6组试验。确定参数后,将A2、A3、A4未锁定井段合并重新训练,并利用从未

参与调参的A5井实施外部测试。由于A5上半部分数据存在大量深度断点,本文选择A5中的连续井段,即测深MD>3293 m的井段作为外部测试数据。数据集划分如图3所示。

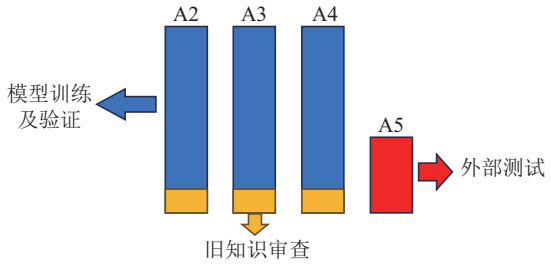

图3　数据集划分示意

Fig.3　Schematic diagram of dataset division

3.2　试验设计及评价指标

为评价不同模型在连续钻井数据上的预测能力,并为持续学习基础预测模型的选择提供依据,选取具有代表性的经验/机理模型、传统机器学习模型及深度时序模型开展对比试验。其中,经验/机理模型包括Bingham模型和Bourgoyne-Young(B-Y)模型,传统机器学习模型包括RF和XGBoost,时序深度学习模型包括LSTM、GRU和TCN。各数据驱动模型采用一致的输入特征、训练样本及评价指标。为提高钻速预测模型的性能,本文采用超参数优化框架(Optuna框架)对模型超参数进行自动优化。Optuna采用动态构图模式(define-by-run)搜索空间,并支持高效采样与无前景试验动态调整[22]。本文以验证集评价指标作为目标函数,通过多次试验获得优选超参数组合,使模型具备较好的跨井能力。

本文的预测能力评价指标采用R^2、RMSE和MAE。其中决定系数R^2评价整体趋势拟合能力,判断预测曲线能否跟随ROP整体的趋势,并比较不同模型的整体拟合能力。平均绝对误差MAE可以直观评价一般井段的预测精度,比较模型对常规工况的改善程度。如果持续学习模型的MAE明显下降,说明该模型可以纠正大量普通井段中的预测偏差。均方根误差RMSE侧重表征大误差与突变工况下的预测效果,可检验模型是否存在少数严重预测错误、识别严重预测偏差,并评判模型对钻速峰值与突变的预测能力。为避免数据泄露,A5井外部测试数据不参与超参数搜索,仅用于最终评价模型的预测精度及跨井泛化能力。表2给出了本文开展训练及测试时所得的模型最优超参数。

表2　模型最优超参数

Table 2　Optimal hyperparameters of each model

模　型	超　参　数	最优超参数
RF	决策树数量	300
	最大特征比例	0.7
	叶节点最小样本数	2
XGBoost	基学习器数量	500
	最大树深	7
	学习率	0.05
	样本采样比例	0.85
	特征采样比例	0.8
	L2正则化系数	1
LSTM	隐藏单元数	64
	循环层数	2
	Dropout比例	0.1
	优化器	AdamW
	学习率	5×10^{-4}
	权重衰减	1×10^{-4}
	批大小	512
GRU	隐藏单元数	64
	循环层数	2
	Dropout比例	0.1
	优化器	AdamW
	学习率	5×10^{-4}
	权重衰减	1×10^{-4}
	批大小	512
TCN	通道数	48
	残差块数量	2
	感受野	25
	卷积核大小	5
	Dropout比例	0.1001
	优化器	AdamW
	学习率	1.54×10^{-3}
	权重衰减	7.24×10^{-7}
	批大小	512

使用上述超参数优化后得到的模型超参数分别构建钻速预测模型,进行交叉验证试验后7个预测模型预测的平均误差如图4、表3所示。

如上述试验结果所示,TCN模型预测准确性均优于其他对比模型,所以将该模型作为后续的持续

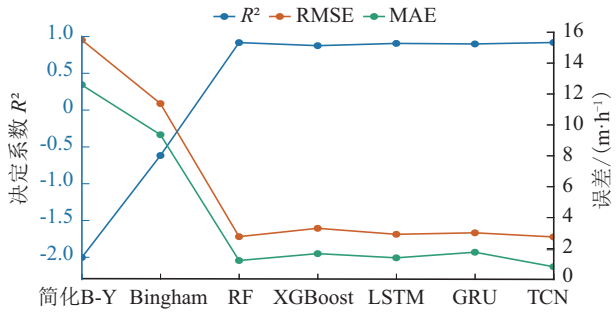

图4 各模型评估系数分布

Fig.4 Distribution of evaluation coefficients for each model

表3 各模型预测平均误差

Table 3 Mean prediction error of each model

模 型	R^2	RMSE/(m·h^{-1})	MAE/(m·h^{-1})
TCN	0.9021	2.7886	0.8773
RF	0.9008	2.8069	1.2764
GRU	0.8827	3.0528	1.8073
LSTM	0.8899	2.9568	1.4489
XGBoost	0.8595	3.3411	1.7178
Bingham	−0.6188	11.3398	9.3416
简化B-Y	−1.9916	15.4155	12.5517

学习基础预测模型。接下来对该模型进行持续学习策略调整,结果如表4所示。

表4 经验回放持续学习最优参数

Table 4 Optimal parameters for experience replay continual learning

项 目	最优设置
每次更新数据块	40
每次经验回放样本数	160
持续学习率	4.13×10^{-4}
增量训练轮次	3

3.3 A5井段钻速预测测试和性能分析

本文分别构建基础模型、朴素增量微调模型、持续学习模型三个模型来进行消融试验,其中基础模型在训练结束后参数始终冻结:

$$\theta_k = \theta_{k-1} \tag{5}$$

朴素增量微调模型只学习最新数据,但不加入历史回放池,见式(2)。持续学习模型则按式(4)学习新数据的同时加入经验回放,同时学习新样本和历史样本。

试验开始时三种模型的初始参数保持一致,为降低神经网络随机初始化及批次采样对试验结果的影响,本文分别采用随机种子21、42、84开展3次独立重复试验。表5中的评价指标均为3次试验结果的平均值,用于评价模型的总体性能与稳定性。持续学习模型在A5上的R^2相较基础模型提高0.019,RMSE、MAE分别下降8.64%、31.35%。MAE改善幅度大于RMSE;相较朴素增量微调模型,R^2提高了0.014,RMSE、MAE分别下降6.66%、19.64%。持续学习模型取得了三种方法中的最优结果,结果表明持续学习模型的优势并非仅来自继续训练,历史经验回放对模型更新也具有额外的贡献。其中,MAE的改善幅度大于RMSE,说明持续学习主要减少了大量常规井段中的预测偏差,但对少数ROP剧烈突变点产生的大误差改善相对有限。

表5 A5井段测试结果

Table 5 Test results of Well A5 section

模 型	R^2	RMSE/(m·h^{-1})	MAE/(m·h^{-1})
基础模型	0.887	4.438	2.685
朴素增量微调模型	0.892	4.344	2.294
持续学习模型	0.906	4.055	1.843

预测曲线无法对多个随机种子的结果直接求平均,因此选取综合评价指标最接近三次试验均值的随机种子21作为代表性试验,用于绘制真实ROP与预测ROP对比曲线,如图5所示。图中展示了基础模型、朴素增量微调模型和持续学习模型在A5外部井段的钻速预测结果。三种模型均能较好地跟踪ROP随测量深度变化的总体趋势,R^2均达到0.89左右,说明初始TCN已经学习到钻井参数与ROP之间的主要非线性关系。但三者在局部突变、极值幅度和新井段适应能力方面存在明显差异。

基础模型在高钻速区间、钻速快速下降及快速上升区域,预测幅度通常小于真实变化幅度,说明从A2、A3、A4学习到的特征并不能完全适应A5中的地层和工况分布。朴素增量微调模型R^2提高至0.892,RMSE、MAE分别下降至4.344、2.294 m/h。与基础模型相比,其RMSE下降约2.12%,说明朴素增量微调模型利用A5近期数据进行增量更新后,可以纠正部分跨井偏差,使预测曲线更接近真实ROP。然而,该方法只使用近期数据更新参数,容易受到当前数据块局部分布和异常波动的影响。

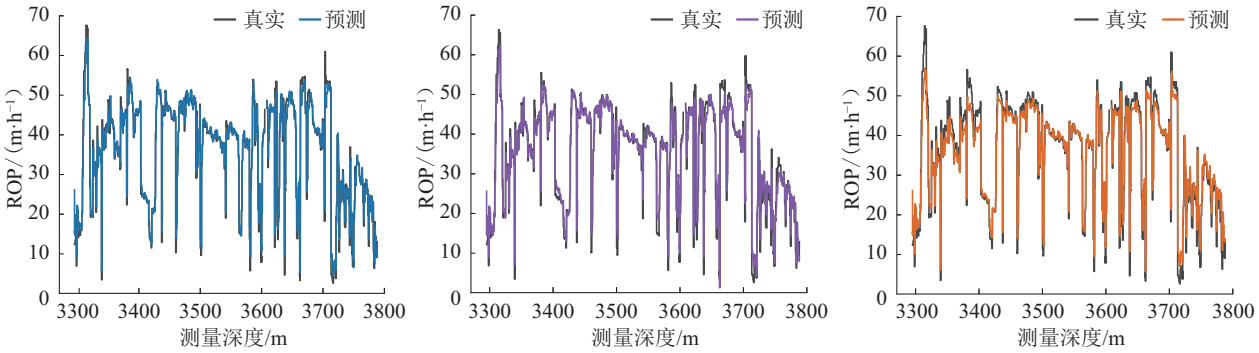

（a）持续学习模型：R^2=0.905，RMSE=4.090 m/h，MAE=1.898 m/h

（b）朴素增量微调模型：R^2=0.893，RMSE=4.330 m/h，MAE=2.291 m/h

（c）基础模型：R^2=0.890，RMSE=4.386 m/h，MAE=2.531 m/h

图5　各模型A5井段预测结果对比

Fig.5　Comparison of prediction results of various models for Well Section A5

在部分钻速急剧变化区间内，预测曲线仍存在局部振荡或趋势偏差。其性能改善相对有限，说明简单地继续训练并不能充分解决新井段适应问题。

从预测曲线看，持续学习模型在稳定钻进区间与真实曲线的重合程度最高，对中高ROP平台、低ROP区间及工况变化后的恢复过程均具有更好的跟踪能力。这说明经验回放在吸收A5新数据特征的同时，引入历史代表样本约束模型更新，降低了模型被近期局部样本过度支配的风险，在新井段适应能力与既有知识稳定性之间取得了更好的平衡。

3.4　A5井段钻速预测误差分块分析

将A5井段按20 m深度分块后开展钻速预测误差分析，如图6所示，持续学习模型在26个井段中有17个井段的RMSE低于基础模型，19个井段的RMSE低于朴素增量微调模型。持续学习对比其他模型的优势并非只由个别井段贡献，而是在大部分A5井段中均有体现。但是持续学习模型在以下井段仍存在较大误差：3420～3440 m RMSE为4.901 m/h，3580～3600 m RMSE为4.900 m/h，3620～3640 m RMSE为7.997 m/h，3660～3680 m RMSE为6.235 m/h，3700～3720 m RMSE为6.939 m/h。预测曲线显示，这些井段通常伴随ROP快速降低、快速升高。TCN能够跟随主要变化趋势，但预测过程中对突变发生深度和极值幅度变化的判断仍存在偏差。

3.5　三种模型的旧知识保持性能对比分析

利用A2、A3、A4锁定井段开展旧知识保持测试，表6为测试结果统计分析情况。基础模型参数在A5井段测试中始终冻结，本身不存在参数更新引起的遗忘，可以作为判断是否产生遗忘的基准。虽然朴素增量微调在A5上取得一定精度提升，但在旧井段中RMSE和MAE大幅增加，说明模型参数被近期A5样本主导，发生了明显的灾难性遗忘。持续学习模型在学习A5后，旧知识整体RMSE和MAE没有恶化，经验回放有效缓解了灾难性遗忘，使模型在适应A5目标数据流的同时，总体保持了已有井段知识。

图7为三种模型对A2井锁定井段旧知识保持结果对比情况。朴素增量微调模型的预测曲线虽然基本保持了真实ROP的变化趋势，但在大部分深度区间存在明显的系统性低估，尤其在中高钻速区间，预测值整体低于真实值。A2井段RMSE由2.254 m/h增至4.371 m/h，说明模型只利用A5新数据更新后，参数明显偏向A5数据分布，原先从A2学习的ROP映射关系遭到破坏，出现了明显的灾难性遗忘。持续学习模型虽然在局部突变位置存在轻微偏差，但没有出现朴素增量微调模型那样的整体低估，在钻速变化和多数低ROP突降位置均能保持较好的跟踪能力。

4　结论

（1）本文构建了TCN与经验回放相结合的持续学习预测模型。与静态批量学习模型的参数冻结、朴素增量微调模型的近期数据调整不同，本文采用先预测后更新的方式，并以经验回放和锁定井段审查同时评价可塑性与稳定性。

（2）A5外部数据流测试中，经验回放持续学习模型平均R^2为0.906，RMSE、MAE分别为4.055、

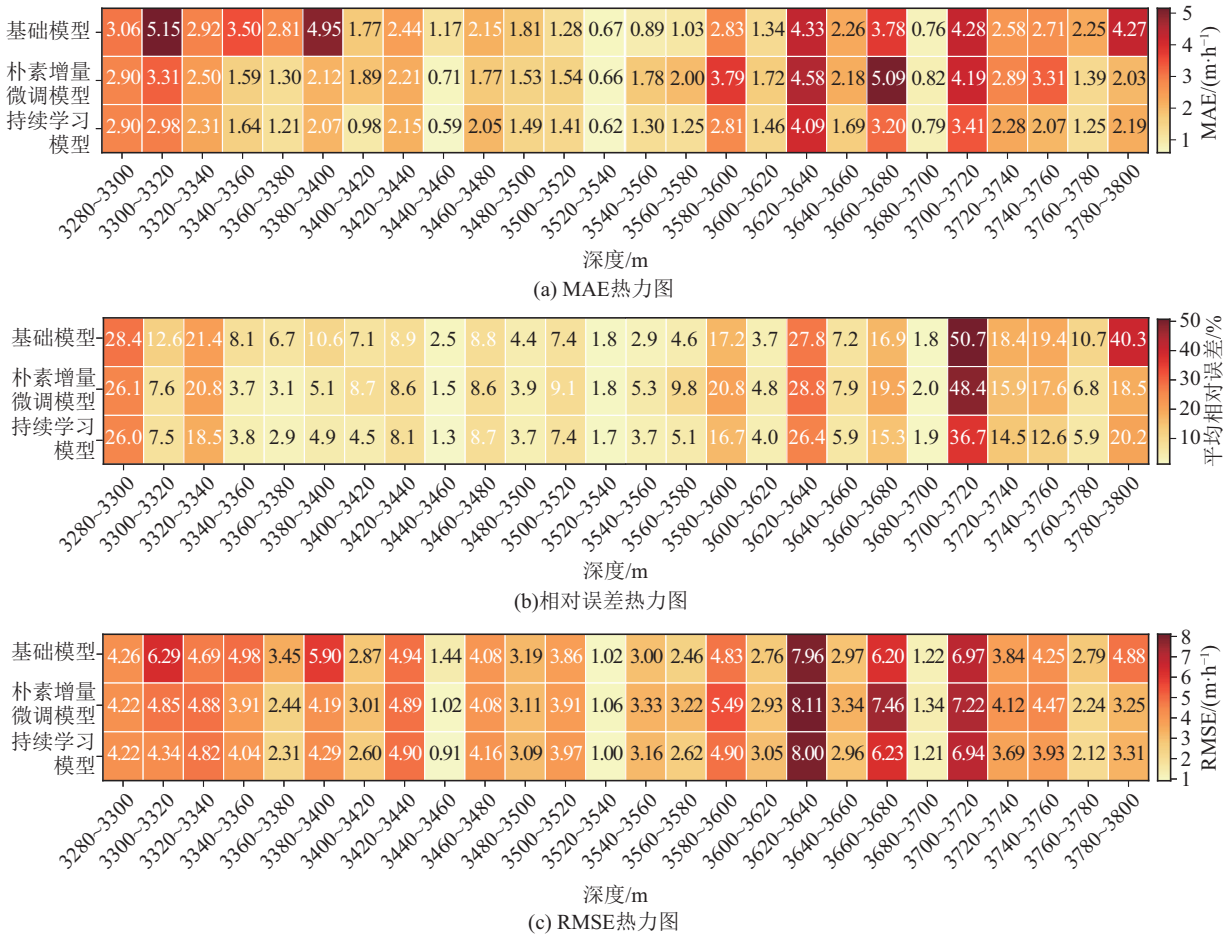

图6 A5井段分块MAE、相对误差、RMSE热力图

Fig.6 Heatmaps of block-wise MAE, relative error and RMSE for Well A5 section

表6 锁定井段审查测试结果统计分析

Table 6 Statistical analysis of test results in locked sections

模 型	RMSE/(m·h^{-1})	MAE/(m·h^{-1})
基础模型	2.108	1.105
朴素增量微调模型	4.839	4.501
持续学习模型	1.946	1.067

1.843 m/h,持续学习模型在A5上的R^2相较基础模型提高0.019,RMSE、MAE分别下降8.64%、31.35%;相较朴素增量微调模型,R^2提高了0.014,RMSE、MAE分别下降6.66%、19.64%。结果表明,经验回放持续学习能够提高钻速模型对新井地层及工况变化的动态适应能力。

(3)该方法为构建“随钻数据采集—钻速预测—模型更新—滚动优化”的智能钻井流程提供了技术基础。其工程意义在于利用已钻井段的数据持

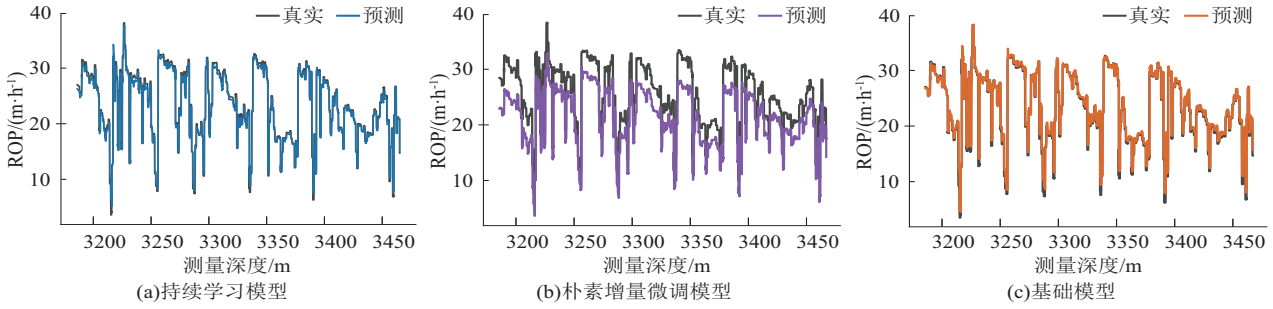

图7 A2井锁定井段三种模型旧知识保持结果对比

Fig.7 Comparison of old knowledge retention results of three models in locked sections of Well A2

续校正模型,使用于参数优化的预测模型输出尽可能贴合当前地层与实际工况,从而提高钻井参数决策的时效性和适应性,为提高机械钻速、减少无效钻进时间和降低钻井成本提供支持。

参考文献(References):

[1] 刘胜娃,孙俊明,高翔,等.基于人工神经网络的钻井机械钻速预测模型的分析与建立[J].计算机科学,2019,46(S1):605-608.
LIU Shengwa, SUN Junming, GAO Xiang, et al. Analysis and establishment of drilling speed prediction model for drilling machinery based on artificial neural networks[J]. Computer Science, 2019,46(S1):605-608.

[2] 宋先知,裴志君,王潘涛,等.基于支持向量机回归的机械钻速智能预测[J].新疆石油天然气,2022,18(1):14-20.
SONG Xianzhi, PEI Zhijun, WANG Pantao, et al. Intelligent prediction for rate of penetration based on support vector machine regression[J]. Xinjiang Oil & Gas, 2022,18(1):14-20.

[3] 仉文岗,唐理斌,陈福勇,等.基于4种超参数优化算法及随机森林模型预测TBM掘进速度[J].应用基础与工程科学学报,2021,29(5):1186-1200.
ZHANG Wengang, TANG Libin, CHEN Fuyong, et al. Prediction for TBM penetration rate using four hyperparameter optimization methods and random forest model[J]. Journal of Basic Science and Engineering, 2021,29(5):1186-1200.

[4] 周长春,姜杰,李谦,等.基于融合特征选择算法的钻速预测模型研究[J].钻探工程,2022,49(4):31-40.
ZHOU Changchun, JIANG Jie, LI Qian, et al. Research on drilling rate prediction model based on fusion feature selection algorithm[J]. Drilling Engineering, 2022,49(4):31-40.

[5] 胥知画,姜杰,周长春,等.基于粒子群优化的融合特征选择钻速预测模型研究[J].钻探工程,2025,52(2):134-143.
XU Zhihua, JIANG Jie, ZHOU Changchun, et al. Research on a rate of penetration (ROP) prediction model based on feature selection integrated with particle swarm optimization (PSO)[J]. Drilling Engineering, 2025,52(2):134-143.

[6] 甘超,汪祥,王鲁朝,等.基于区域多井数据优选与模型预训练的深部地质钻探过程钻速动态预测方法[J].钻探工程,2023,50(4):1-8.
GAN Chao, WANG Xiang, WANG Luzhao, et al. Dynamic prediction method of rate of penetration (ROP) in deep geological drilling process based on regional multi-well data optimization and model pre-training[J]. Drilling Engineering, 2023,50(4):1-8.

[7] 张琦,甘超,曹卫华.大洋钻探过程钻速在线区间预测方法——以微型钻探船室内模拟实验为例[J].钻探工程,2024,51(5):45-52.
ZHANG Qi, GAN Chao, CAO Weihua. An online interval prediction method for rate of penetration (ROP) during the ocean drilling: A case study on the indoor simulation experiments by micro drilling ship[J]. Drilling Engineering, 2024,51(5):45-52.

[8] 李同意,李谦,魏思维,等.基于实时数据流对比的钻速建模算法[J].钻探工程,2025,52(S1):97-104.
LI Tongyi, LI Qian, WEI Siwei, et al. The rate of penetration modeling algorithm based on real-time data stream comparison [J]. Drilling Engineering, 2025,52(S1):97-104.

[9] Gan C, Cao W H, Liu K Z, et al. A novel dynamic model for the online prediction of rate of penetration and its industrial application to a drilling process[J]. Journal of Process Control, 2022, 109:83-92.

[10] Bertini J R, Lavi B. Enhancing rate of penetration prediction in drilling operations: A data stream framework approach[J]. Engineering Applications of Artificial Intelligence, 2025, 143: 110034.

[11] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [EB/OL]. (2018-04-19) [2026-07-30]. https://arxiv.org/abs/1803.01271.

[12] Sun J, Huang W D, Du L, et al. Multi-length prediction of the drilling rate of penetration based on TCN-informer[J]. Electronics, 2025,14(22):4538.

[13] Parisi G I, Kemker R, Part J L, et al. Continual lifelong learning with neural networks: A review[J]. Neural Networks, 2019,113:54-71.

[14] De Lange M, Aljundi R, Masana M, et al. A continual learning survey: Defying forgetting in classification tasks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022,44(7):3366-3385.

[15] Gama J, Žliobaitė I, Bifet A, et al. A survey on concept drift adaptation [J]. ACM Computing Surveys (CSUR), 2014, 46(4):44.

[16] Kirkpatrick J, Pascanu R, Rabinowitz N, et al. Overcoming catastrophic forgetting in neural networks[J]. Proceedings of the National Academy of Sciences of the United States of America, 2017,114(13):3521-3526.

[17] Bifet A, Holmes G, Kirkby R, et al. MOA: Massive online analysis[J]. Journal of Machine Learning Research, 2010, 11 (52):1601-1604.

[18] Rolnick D, Ahuja A, Schwarz J, et al. Experience replay for continual learning[C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2019:32.

[19] Tunkiel A T, Sui D, Wiktorski T. Reference dataset for rate of penetration benchmarking[J]. Journal of Petroleum Science and Engineering, 2021,196:108069.

[20] Pearson R K. Outliers in process modeling and identification [J]. IEEE Transactions on Control Systems Technology, 2002,10(1):55-63.

[21] Lu J, Liu A J, Dong F, et al. Learning under concept drift: A review[J]. IEEE Transactions on Knowledge and Data Engineering, 2019,31(12):2346-2363.

[22] Akiba T, Sano S, Yanase T, et al. Optuna: A next-generation hyperparameter optimization framework[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage: Association for Computing Machinery, 2019:2623-2631.

(编辑　王跃伟)