

<https://doi.org/10.3799/dqkx.2026.098>



基于双域自适应混合专家模型的深海钻探过程声波时差软测量方法

陶梓兴^{1,3,4}, 曹卫华^{1,2,3,4*}, 甘超^{1,2,3,4}

1. 中国地质大学(武汉)未来技术学院, 湖北武汉 430074
2. 中国地质大学(武汉)人工智能与自动化学院, 湖北武汉 430074
3. 复杂系统先进控制与智能自动化湖北省重点实验室, 湖北武汉 430074
4. 地球探测智能化技术教育部工程研究中心, 湖北武汉 430074

摘要: 针对深海钻探过程中测井参数(声波时差)获取代价大、且传统数据驱动的声波时差软测量方法在跨井应用中泛化能力不足等问题, 提出一种基于双域自适应混合专家模型的深海钻探过程声波时差软测量方法。该方法融合多源钻探数据, 根据低频可迁移的趋势域与高频相关的残差域, 分别构建声波时差多专家软测量模型; 在此基础上, 引入自适应混合权重, 通过多源无监督信号动态评估两域的可信度, 实现声波时差的自适应融合。在多口实际钻井数据上的对比实验表明, 所提方法在跨井预测精度与稳定性方面均优于 SVR、RF、RNN、LSTM 及 Transformer 等对比模型, 平均误差降低约 15%。该方法在仅依靠钻前勘探与钻井数据的前提下, 有效平衡了预测精度与跨井应用的稳定性, 适用于深海钻探环境下的声波时差实时软测量。

关键词: 声波时差; 跨井泛化; 软测量; 双域建模; 自适应专家集成; 声波。

中图分类号: TE51

文章编号: 1000-2383(2026)08-3224-12

收稿日期: 2026-02-28

A Dual-Domain Adaptive Mixture-of-Experts-Based Soft Measurement Method for Sonic Transit Time in Deep-Sea Drilling Processes

Tao Zixing^{1,3,4}, Cao Weihua^{1,2,3,4*}, Gan Chao^{1,2,3,4}

1. School of Future Technology, China University of Geosciences (Wuhan), Wuhan 430074, China
2. School of Artificial Intelligence and Automation, China University of Geosciences (Wuhan), Wuhan 430074, China
3. Hubei Key Laboratory of Advanced Control and Intelligent Automation for Complex Systems, Wuhan 430074, China
4. Engineering Research Center of Intelligent Technology for Geo-Exploration, Ministry of Education, Wuhan 430074, China

Abstract: In deepwater drilling operations, the acquisition of logging parameters such as sonic transit time (DTCO) is associated with high cost and operational constraints, while conventional data-driven soft-sensing methods often exhibit limited generalization capability in cross-well applications. To address these challenges, this study proposes a dual-domain adaptive mixture-of-experts-based soft measurement method for sonic transit time in deep-sea drilling processes. This method integrates multi-source drilling data and constructs separate multi-expert soft measurement models for acoustic travel time based on low-frequency migratory trend

基金项目: 国家自然科学基金重点项目(No.62333019)。

作者简介: 陶梓兴(2001—), 男, 博士研究生, 研究方向为深海资源勘探过程环境融合感知。ORCID: 0009-0006-8559-3993. E-mail: taozixing@cug.edu.cn

*** 通讯作者:** 曹卫华, ORCID: 0000-0002-9677-9586. E-mail: weihuacao@cug.edu.cn

引用格式: 陶梓兴, 曹卫华, 甘超, 2026. 基于双域自适应混合专家模型的深海钻探过程声波时差软测量方法. 地球科学, 51(8): 3224-3235.

Citation: Tao Zixing, Cao Weihua, Gan Chao, 2026. A Dual-Domain Adaptive Mixture-of-Experts-Based Soft Measurement Method for Sonic Transit Time in Deep-Sea Drilling Processes. *Earth Science*, 51(8): 3224-3235.

domains and high-frequency residual domains. Building on this, adaptive mixed weights are introduced to dynamically assess the reliability of the two domains using multi-source unsupervised signals, thereby achieving adaptive fusion of acoustic travel times. Comparative experiments conducted on multiple real drilling datasets demonstrate that the proposed method consistently outperforms benchmark models, including SVR, RF, RNN, LSTM, and Transformer, in terms of cross-well prediction accuracy and stability, achieving an average error reduction of approximately 15%. This method effectively balances prediction accuracy with the stability of cross-well application whilst relying solely on pre-drilling exploration and drilling data, and is suitable for real-time sonic transit time soft measurement in deep-sea drilling environments.

Key words: sonic slowness; cross-well generalization; soft sensing; dual-domain modeling; adaptive mixture of experts; acoustic wave.

0 引言

深海区域覆盖了地球表面约60%的面积,是地球系统中最为广阔的组成部分.该区域不仅富集油气资源、多金属硫化物和富钴结壳等战略性矿产,同时也是研究板块构造演化、沉积体系发育及深部地球物质循环过程的重要天然实验场.因此,深海资源勘探、大洋科学钻探以及深远海综合科学考察已成为当前地球科学与海洋工程领域的前沿方向(Wen *et al.*, 2023; Du *et al.*, 2024),对钻探技术和原位信息获取能力提出了持续提升的要求.

作为连接深海科学目标与工程实施的核心技术手段,深海钻探在资源评价与科学认知中发挥着不可替代的作用.然而,与陆地及浅水环境相比,深海钻探作业需长期处于高静水压力、低温及强海流等极端海洋环境中,同时还面临沉积结构复杂、地层非均质性强及地质条件快速变化等挑战(Xiang *et al.*, 2024).这些因素叠加使得钻井风险显著增加,对钻探过程中地层状态的实时感知和动态决策能力提出了更为严苛的要求(Xiang *et al.*, 2024).

声波时差(sonic transit time, DTCO)是测井中最重要的地层弹性参数之一,用于表征纵波在地层中的传播迟缓程度,其数值与纵波传播速度呈倒数关系.由于声波时差对地层孔隙度、岩性及压实程度高度敏感,能够有效反映沉积压实与胶结演化过程以及地层流体充填特征,因此在地层特征识别、岩石物性评价(徐春露等, 2017; Chen *et al.*, 2021; 徐珂等, 2023)以及地层速度模型建立等方面发挥着基础性作用.尤其是在钻探工程中,声波时差常被用作异常压实与压力异常识别的重要依据(Tao *et al.*, 2025),并作为孔隙压力预测(Eaton, 1972; Chen *et al.*, 2022a)和井壁稳定性分析的关键输入参数之一,这使得声波时差在钻探过程中的实时获取与可靠解释显得尤为关键.

传统上,声波时差主要依赖完井后电缆测井或

随钻测井获取,并与电阻率、密度等参数共同用于地层评价与压力分析(Zhang *et al.*, 2022).随钻测量、随钻测井技术已成为深海钻探过程中实时信息获取的技术基础,在陆上和海上钻探中得到广泛应用(苏义脑等, 2023).然而,在海上钻探特别是成本敏感的作业场景中,智能化随钻测井声波仪器价格高、维护与下井风险大,现场可用的随钻测量参数常被限制在少量曲线,如自然伽马、电阻率等,导致声波时差在钻进过程中的获取受到明显制约.

近年来,随着神经网络与软测量技术的发展,利用易获取的钻探数据推断难以直接测量的井底关键地质参数成为可能.软测量作为一种间接估计方法,通过建立数学模型,利用易测的过程变量(如钻速、钻压、自然伽马等)对难测的关键参数(如声波时差)进行实时预测,其本质是实现从“已知数据”到“待估参数”的映射过程.相关研究表明,基于历史钻进序列数据并结合LSTM、注意力机制等序列建模方法,可显著提升对随钻地质与工程参数的预测精度与作业安全性(Akinyemi *et al.*, 2023; Bertini and Lavi, 2025; Yang *et al.*, 2025).同时,蒙特卡洛模拟(Lothe *et al.*, 2020)、混合偏最小二乘回归(Gan *et al.*, 2021)、模糊聚类(Chen *et al.*, 2022b)等方法,也已在钻探过程参数预测中得到应用.这些进展为钻探过程中声波时差的实时估计提供了可行路径.

综上所述,在海上油气钻探过程中,针对声波时差难以实时获取、测量手段受限等问题,开展井底声波时差软测量方法研究具有重要的工程应用价值与现实意义.通过构建复杂深海钻探环境下面向跨井泛化的双域自适应混合专家声波时差软测量方法,不仅可为后续孔隙压力预测、地层力学分析及井壁稳定性评价提供关键输入参数,也为实现复杂海洋环境下的安全、高效钻探奠定坚实基础.

本文的主要贡献在于:(1)针对钻探过程中声波时差难以实时获取的问题,提出了一种基于双域

自适应混合专家模型的深海钻探过程声波时差软测量方法。(2)构建了趋势—残差双域建模策略,提升模型在跨井应用中的泛化能力与稳定性。(3)在双域融合阶段,设计了一种基于钻井深度区间与数据分布的自适应融合机制,增强了模型在复杂工况下的泛用性。(4)基于真实海上钻探数据对所提方法进行了测试,验证了模型的优异性。

本文结构如下:第1节概述钻探背景;第2节阐述所提方法的建模框架,并讨论相关建模方法论,包括对建模过程的详细说明;第3节通过对比不同模型的声波时差预测结果,评估所提软测量方法的预测精度与跨井泛化能力;第4节总结研究成果。

1 钻探背景与特征描述

本章对研究区地质背景及本文使用的多源数据类型、获取方式与总体特征进行说明,为后续模型构建与验证提供基础。

1.1 地质背景

本研究选取3口海上油气井数据开展实验对比与验证,分别为建模井(井A)、邻井(井B)与盲井(井C),其空间位置关系如图1所示。3口井均位于澳大利亚西北海域的卡那封盆地(Carnarvon Basin)。卡那封盆地为大型海相沉积盆地,沉积体系类型丰富、构造演化过程复杂,是澳大利亚最重要的油气勘探开发与生产区之一。




图1 建模井(井A)、邻井(井B)及盲井(井C)位置示意图
Fig.1 Location map of modeled (well A), neighboring (well B) and blind (well C) wells

从区域构造演化角度来看,卡那封盆地的形成与发展受多期构造—沉积作用的共同控制。整体上,沉积环境经历了由浅海向深海的持续迁移与演化,形成了类型多样的沉积岩系,主要包括砂岩、页岩、灰岩以及局部发育的盐沼沉积等。在古气候变化与构造活动的双重影响下,盆地地层在横向与纵向上均表现出显著的非均质性特征。

与此同时,深水沉积区常伴随快速沉积与欠压实作用,易诱发异常地层压力的发育,使地层压力与地层物性参数(如地震速度、密度及孔隙度)之间的耦合关系更加复杂,从而显著增加地质参数的不确定性(Feng *et al.*, 2020)。在长期地质演化过程中,持续的拉张应力进一步塑造了该盆地复杂的构造变形样式及多样化的孔隙压力分布格局,对钻探工程的安全性及可靠性提出了更高要求(Gartrell, 2000)。

1.2 多源钻探数据及其特征分析

深海钻探作业涉及从钻前勘探到钻后测井的全过程,形成了覆盖地震勘探、随钻测量、随钻测井及钻后测井的多源数据体系。如何有效融合这些多源异构数据,建立从易测参数到声波时差的映射关系,是构建高精度、强泛化软测量模型的关键。

这些数据的获取方式与示例如表1所示。

地震数据属于钻前勘探数据,可用于识别断层、褶皱等构造形态与地层几何特征,是构建区域地质认识与井位结构设计的重要依据(Ramu *et al.*, 2021)。基于地震速度开展地层参数预测通常依赖解释经验与速度建模质量,当构造复杂、速度横向变化显著或资料品质受限时,预测不确定性会明显增大。

随钻测井数据与随钻测量数据在钻进过程中实时采集,能够提供连续的随钻信息,是开展在线评价与软测量建模的核心数据来源之一。随钻测量参数如钻压、钻速、转速、扭矩等由平台实时记录,是反映井底受力与破岩过程、井眼清洁与摩阻变化的重要指标,也是当随钻测井曲线受限时刻画工况

表1 多源钻探与测井数据及其获取方式

Table 1 Multi-source drilling and logging data and their acquisition methods

数据	描述	示例
地震数据	钻前数据,通过地震勘探获取	单程时间、双程时间、平均速度等
随钻测井	钻进过程中获取的随钻测井数据	伽马、电阻率、井斜角等
随钻测量	钻进过程中获取的随钻测量数据	钻速、钻压、转速、扭矩等
钻后测井	钻后数据,通过电缆测井作业获取	声波时差、地层密度、孔隙度等

与地层响应的关键信息来源。

钻后测井数据一般在钻后获取,曲线精度与分辨率通常高于随钻数据,能够更可靠地反映地层真实性与流体状态。本文涉及的钻后测井参数仅包括声波时差。该数据在本文中主要用于:一是作为监督学习标签或对照基准,二是用于验证随钻软测量结果的可靠性。

本文所用多源数据及其统计特征见表2。

综合井A、井B与井C的统计特征对比可以看出,不同井在钻探响应与地层物性方面存在差异。以钻速为例:井A的平均钻速相对较低(26.2),但标准差较大(23.57),表明钻进过程中钻速波动明显,可能与地层可钻性变化、井底工况波动或钻探参数调整共同相关;井B平均钻速较高(103.43)且波动幅度较大,提示该井段可能存在更强的可钻性差异或更频繁的工况/参数切换;井C的钻速波动相对较小(标准差20.53),从统计意义上说明其钻进过程更稳定。总体而言,上述差异反映了研究区地层与工程条件的复杂性,也说明建立能够适应跨井差异的软测量模型具有必要性。

2 声波时差软测量方法

从地质与工程机理角度看,声波时差的变化通常可分解为两类具有不同物理来源的成分:一类是受层序结构、岩性组合及速度场控制的低频、平滑变化趋势;另一类则是由局部岩性非均质、钻探参数扰动及测量噪声等因素引起的高频偏离项。若直接采用单一端到端模型对声波时差进行整体预测,模型往往在训练井内表现良好,但在目标井中容易受到分布漂移的影响,导致系统性偏差。

针对上述问题,本文提出一种基于双域自适应混合专家模型的深海钻探过程声波时差软测量方法。该方法将声波时差的预测任务划分为趋势域与残差域两个互补子问题,在趋势域学习输入到输出的总体映射与趋势一致性,在残差域学习相对声波时差物理变化趋势的修正项,强调对局部偏差的刻画。在每个域内构建由多种机器学习模型组成的专家集,通过自适应权重调整实现趋势域与残差域的域内融合,最终再对趋势域与残差域的结果进行融合。该策略既保证了预测结果在跨井应用中的稳健性,又提高了模型对局部异常变化的刻画能力。方法整体流程如图2所示。

2.1 数据预处理

在钻探过程中,由于设备故障、环境干扰、操作误差以及地质条件复杂等因素,测得的数据不可避免地会出现异常值。如,在高温高压条件下仪器性能可能发生不稳定,钻井液侵入会对测井信号产生干扰,数据传输过程中也可能引入噪声。这些异常数据若未得到有效处理,将对后续分析及工程决策产生不利影响。因此,在进行声波时差预测之前,有必要对异常值进行识别与剔除,以提高数据的可靠性与模型预测的准确性。

常用的异常值检测方法包括Z-score方法和四分位距(interquartile range, IQR)方法。然而,钻井与测井参数通常随井深变化呈现出明显的线性增长或减小趋势。图3给出了井A中若干典型钻井与测井参数随深度变化的趋势特征。

从图3中可以看出,钻速、泥浆流量以及声波时差整体呈现出明显的线性递减趋势,而钻压和扭矩则表现出显著的线性递增趋势。这种随深度变化的趋势性特征为异常值识别带来了较大挑战。作为通用统计方法,Z-score和IQR方法在数据存在显著趋势变化时,其异常检测能力往往受到限制,从而降低了其在钻井测井数据处理中的适用性。

为解决上述问题,提出了一种基于滑动窗口的异常值识别算法(算法A1),如表3所示,以提升钻井数据的整体质量。

在该算法中, x_i 表示数据序列中的第*i*个数据点, μ_i 和 δ_i 分别表示 x_i 所在滑动窗口内的均值与标准差。异常值识别完成后,若直接将其剔除将导致数据缺失。因此,本文采用异常值相邻样本的均值对其进行替换,以保证数据的连续性。

因此,在异常值处理完成后,还需对数据进行进一步的滤波与去噪处理(Geekiyanaage *et al.*, 2021)。小波滤波因其良好的时频局部化特性和优异的降噪能力,被广泛应用于钻井数据处理领域。鉴于钻井数据中的噪声主要表现为低频特征(Gan *et al.*, 2019),本文采用多层小波分解进行滤波处理。小波变换与重构过程可表示为:

$$W_f(e, s) = \frac{1}{\sqrt{e}} \int_{-\infty}^{\infty} X(t) \varphi\left(\frac{t-s}{e}\right) dt, \quad (1)$$

$$f(t) = \frac{1}{c_\varphi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{e^2} W_f(e, s) \varphi\left(\frac{t-s}{e}\right) deds, \quad (2)$$

其中: $\varphi(t)$ 表示小波基函数,本文使用的dmey函数, e 为尺度因子, s 为平移因子, c_φ 为小波常数。

表 2 多源数据的统计特征描述
Table 2 Statistical characterization of multi-source data

井	描述	参数										
		单程时间	双程时间	平均速度	RMS 速度	钻速	钻压	转速	扭矩	泥浆流量	电阻率	声波时差
A	均值	1 584.04	3 171.78	1 942.42	2 025.97	26.20	7.38	84.04	7.42	3.48	1.15	96.56
	标准差	191.12	372.28	149.70	189.66	23.57	3.27	34.88	3.49	0.18	0.27	22.26
	最小值	1 195.60	2 403.61	1 698.23	1 728.24	1.01	0	0	0	2.93	0.58	56.25
	最大值	1 883.85	3 742.70	2 203.55	2 361.74	150.51	19.00	174.25	21.99	4.02	1.81	149.98
	方差	36 526.80	138 594.23	22 411.34	35 972.66	555.56	10.69	1 216.64	12.15	0.03	0.07	495.50
B	均值	1 363.82	2 732.22	1 773.57	1 813.75	103.43	6.43	115.22	4.32	4.12	0.82	121.38
	标准差	88.41	176.91	40.64	46.32	55.55	2.28	7.34	1.79	0.17	0.17	16.22
	最小值	1 205.00	2 414.42	1 705.78	1 736.78	7.45	0.96	92.00	0.16	3.54	0.42	70.13
	最大值	1 505.28	3 015.26	1 852.84	1 909.05	276.66	15.59	138.65	9.79	4.36	1.62	153.66
	方差	7 816.65	31 296.42	1 651.46	2 145.78	3 085.53	5.22	53.95	3.20	0.03	0.03	262.96
C	均值	1 599.76	3 212.30	1 866.84	1 925.98	60.58	3.57	103.53	5.49	2.52	0.90	93.09
	标准差	61.09	122.25	53.35	69.45	20.53	1.28	11.62	1.08	0.05	0.11	10.09
	最小值	1 487.68	2 988.05	1 777.82	1 811.44	13.85	0.94	77.01	1.85	1.96	0.56	55.45
	最大值	1 702.87	3 418.54	1 958.39	2 044.58	121.02	7.47	122.93	9.41	2.63	1.24	123.54
	方差	3 731.64	14 944.87	2 846.19	4 823.46	421.43	1.63	134.98	1.16	0	0.01	101.76




图2 所提出的声波时差软测量方法框架

Fig.2 Proposed DTCO soft measurement framework




图3 井A的部分钻井和测井数据

Fig.3 Partially drilling and logging data for well A

表3 SWZ-Score异常检测算法

Table 3 SWZ-Score anomaly detection algorithm

算法 A1:SWZ-Score
(1) 输入:钻井过程特征参数
(2) 输出:异常值序列
(3) 对 $I=0:N$ do 进行循环%对应第 i 个样本 x_i
(4) 为样本 x_i 选取对应的滑动窗口
(5) 计算窗口间数据的均值 μ_i 和方差 δ_i
(6) 计算样本 x_i 的 z 值: $z_i = (x_i - \mu_i) / \delta_i$
(7) 如果 $z_i > 3$, 标记为异常值
(8) 结束循环
(9) 输出异常值序列

2.2 声波时差双域混合软测量方法

本文所提出的声波时差软测量方法包含趋势域模型、残差域模型和双域自适应混合融合策略三部分,本节将进行详细阐述.

2.2.1 声波时差趋势域模型 趋势域建模的目标是直接学习声波时差与多源输入特征之间的整体映射关系,用以刻画声波时差随井深变化的全局趋势特征.当井深为 z ,输入特征向量为 $X(z)$ 时,趋势域预测模型可表示为:

$$\hat{y}_{\text{trend}}(z) = f_{\text{trend}}(X(z)), \quad (3)$$

其中: $\hat{y}_{\text{trend}}(z)$ 为趋势域预测的声波时差值。

考虑到声波时差与输入特征之间既包含相对稳定的趋势关系, 又存在明显的非线性与序列相关性, 趋势域并非采用单一模型, 而是构建由 3 类互补专家组成的集成模型。

专家一为趋势回归专家, 通过函数分解的方式, 将声波时差的预测拆分为全局趋势项与统计残差项之和, 从而在保证趋势稳定性的同时刻画预测不确定性。其形式为:

$$\hat{y}^{(1)}(z) = g(X_l(z)) + h(X_r(z)), \quad (4)$$

其中: X_l 表示描述声波时差低频变化趋势的特征集合; X_r 表示局部偏离的残差特征集合; 趋势函数 $g(\cdot)$ 采用 Ridge 回归建模, 用于提取声波时差随深度及宏观地层条件变化的稳定趋势; 残差函数 $h(\cdot)$ 采用基于梯度提升决策树的回归模型, 对残差项进行建模。

专家二采用 XGBoost 回归模型, 用于学习声波时差与多源特征之间的复杂非线性映射关系, 其预测形式可写为:

$$\hat{y}^{(2)}(z) = \sum_{k=1}^K \gamma_k h_k(X(z)), \quad (5)$$

其中: $h_k(\cdot)$ 表示第 k 棵回归树, γ_k 为对应树的权重。XGBoost 能够有效捕捉特征间的非线性交互关系, 对岩性变化、工程参数耦合等复杂情况具有较强表达能力。

专家三为序列依赖专家, 由于钻井测井数据在深度方向通常具有较强的自相关性与层段连续性, 点对点建模容易忽略纵向结构信息, 因此通过构造滞后项与滚动统计量来描述声波时差的纵向连续性。模型先对声波时差的整体趋势进行二次函数拟合, 并对拟合残差进行 XGBoost 学习, 从而实现相对趋势偏离的建模:

$$\hat{y}^{(3)}(z) = \hat{y}_{\text{st}}(z) + f_{\text{seq}}(X_{\text{seq}}(z)), \quad (6)$$

其中: $\hat{y}_{\text{st}}(\cdot)$ 是拟合出来的二次趋势曲线, $f_{\text{seq}}(\cdot)$ 是 XGBoost 模型, $X_{\text{seq}}(z)$ 是序列特征数据。

尽管趋势域内 3 类专家分别从趋势分解、非线性映射与序列依赖等不同角度刻画声波时差的趋势变化特征, 但由于井间地质条件差异、输入分布偏移以及模型假设不同, 各专家在不同井段与不同工况下的预测可靠性并不一致。因此, 有必要在趋势域内部引入自适应专家融合机制, 以实现多专家输出的动态加权。

层间速度倒数的变化趋势通常与真实声波时

差在宏观尺度上保持一致, 因此将层间速度的倒数作为声波时差趋势的一致性约束, 若某一专家的预测在整体趋势上与层间速度的倒数存在明显偏离, 则该专家在当前井段的可信度应降低。层间速度计算公式为:

$$V_{\text{int}}(z) = \sqrt{\frac{d(V_{\text{rms}}^2(z)t(z))/dz}{dt/dz}}, \quad (7)$$

其中: $V_{\text{rms}}(z)$ 为均方根速度, $t(z)$ 为双程走时。

除趋势一致性外, 模型在目标井上的泛化能力还强烈依赖于输入特征是否落在训练分布范围内。为度量专家在目标井上的分布外风险, 本文在训练井上对关键输入特征计算稳健统计量, 并定义第 j 个专家的数据分布得分为:

$$s_j^{\text{ood}} = \text{median} \left(\left| \frac{x_j - \text{median}_j}{\text{IQR}_j} \right| \right), \quad (8)$$

其中: x_j 表示与第 j 个专家在当前区间上输入特征向量, median_j 和 IQR_j 分别为其在训练井上的中位数与四分位距。

为综合考虑趋势一致性与分布泛化性, 将上述两个指标进行归一化, 得到第 j 个专家的综合指标, 再对趋势域模型内所有专家指标进行 Softmax 映射, 得到趋势域内的每个专家的权重 ω_j^{trend} 。在上述权重约束下, 趋势域的最终预测结果为:

$$\hat{y}_{\text{trend}}(z) = \sum_{j=1}^3 \omega_j^{\text{trend}}(z) \hat{y}^{(j)}(z), \quad (9)$$

2.2.2 声波时差残差域模型 在复杂地层与工程扰动条件下, 声波时差的变化难以仅通过整体映射关系加以刻画。尽管趋势域模型能够较好反映声波时差的总体变化趋势, 但在局部层段仍可能存在系统性偏差。为进一步提高模型对局部异常与工程扰动影响的刻画能力, 本文引入残差域建模思想。

残差域以 $p_{\text{LF}}(z) = 1/V_{\text{int}}(z)$ 作为声波时差作为基线, 将声波时差分解为趋势项与残差项之和:

$$y(z) = p_{\text{LF}}(z) + r(z), \quad (10)$$

其中: $r(z)$ 表示实际声波时差相对于低频趋势的偏离量。残差域的建模目标即是对残差项 $r(z)$ 进行预测, 并通过残差修正提升声波时差的整体预测精度。

考虑到残差的成因具有多样性, 其统计特征在不同井段可能存在显著差异, 单一模型难以全面刻画残差行为。为此, 本文在残差域构建由 3 类专家模型组成的残差专家集, 以增强模型的表达能力与泛化性能。

由于线性模型在跨井应用中对分布漂移具有

较强的泛用性,同时其参数具有明确的物理解释意义,能够反映工程参数变化对声波时差残差的线性影响,因此专家一采用线性回归形式对残差进行建模,其形式为:

$$\hat{y}^{(4)}(z) = p_{LF}(z) + W^T X_{ridge}(z) + b. \quad (11)$$

在低频趋势项 $p_{LF}(z)$ 被剥离后,声波时差残差项主要反映局部岩性变化、孔隙结构非均质性以及工程扰动等高频因素的综合影响,通常呈现出明显的非线性异方差性与非对称性,极端偏差在特定层段(如破碎带、软硬互层)中更易出现,仅进行线性回归容易系统性低估特殊情况下的偏差幅度。

基于上述特性,本文引入基于梯度提升决策树回归模型,对残差进行建模.其形式为:

$$\hat{y}^{(5)}(z) = p_{LF}(z) + f_{gb}(X_{gb}(z)). \quad (12)$$

除统计分布特性外,声波时差残差在深度方向上同样具有显著的序列相关性与层段连续性.为刻画这一纵向依赖结构,本文在残差域中构建序列残差专家,通过显式引入深度滞后项与滚动统计特征,对残差进行序列学习,其预测形式为:

$$\hat{y}^{(6)}(z) = p_{LF}(z) + f_{seq}(X_{seq}(z)). \quad (13)$$

在残差域中,各专家并不直接预测声波时差的值,而是对低频趋势项 $p_{LF}(z)$ 之上的残差结构进行建模.因此在融合时应关注各专家生成的残差是否符合训练井中学习到残差统计规律。

通过对第 j 个专家的预测的残差结果 $r^{(j)}(z)$,与训练井 A 上的真实残差值 r_A ,进行残差一致性判断,得到残差分布得分:

$$s_j^{rood} = \text{median} \left(\left| \frac{r^{(j)}(z) - \text{median}_{r_A}}{IQR_{r_A}} \right| \right). \quad (14)$$

与趋势域专家融合策略相似,再结合残差域输入特征的数据分布得分,得到残差域内的每个专家的权重 ω_j^{res} .在上述权重约束下,残差域的最终预测结果为:

$$\hat{y}_{\text{res}}(z) = \sum_{j=4}^6 \omega_j^{\text{res}}(z) \hat{y}^{(j)}(z). \quad (15)$$

2.2.3 声波时差双域自适应混合融合方法 在上述方法中,趋势域负责刻画声波时差的整体幅值与低频趋势,强调跨井稳健性;残差域专注于对局部残差修正,强调对细尺度结构的响应能力。

为充分发挥两类模型的优势,本文提出一种基于无监督双域自适应混合融合策略,通过引入一个自适应控制系数 $\lambda(z)$,用于刻画在深度 z 处残差域

预测结果的可信程度,并据此动态调节趋势域与残差域在最终预测中的相对贡献。

在目标井中缺乏声波时差真值,无法直接基于预测误差评估残差域性能.为此,本文从物理一致性、残差统计一致性以及基线冲突程度3个互补角度,构建无监督可靠性信号,用于间接刻画残差域预测是否仍符合训练阶段所学习的物理与统计规律。

首先利用深度 z 与双程走时计算平均速度,与输入特征中的 V_{ave} 理论上应保持一致.若二者偏离显著,说明当前井段的输入物理关系已发生变化,此时残差域预测对该井段的适用性应被削弱。

再利用公式14计算输出结果的残差与训练井 A 上残差的数据一致性。

最后判断趋势域预测的低频趋势可能与 $p_{LF}(z)$ 之间的误差大小,当误差大时允许残差域在融合中占据更高权重,有助于对趋势域偏移进行修正。

将上述3类无监督信号与训练井参考尺度进行归一化,分别得到 r_v, r_r, r_p ,并线性组合为综合可靠性评分:

$$S(z) = \omega_v r_v + \omega_r r_r + \omega_p r_p, \quad (16)$$

其中: $\omega_v, \omega_r, \omega_p$ 为各信号权重。

随后,通过 sigmoid 映射将综合评分 $S(z)$ 转换为混合系数:

$$\lambda(z) = \frac{1}{1 + \exp(k(S(z) - 1))}, \quad (17)$$

其中:参数 k 用于控制趋势域与残差域权重切换的平滑程度。

在获得自适应混合系数 $\lambda(z)$ 后,趋势域与残差域的预测结果按照如下形式进行融合:

$$\hat{y}_{\text{hyb}} = (1 - \lambda(z)) \hat{y}_{\text{trend}}(z) + \lambda(z) \hat{y}_{\text{res}}(z). \quad (18)$$

当 $\lambda(z)$ 较小,模型自动退化为以趋势域为主的稳健预测模型;而当 $\lambda(z)$ 较大,则充分利用残差域模型对局部残差的修正能力.通过该机制,模型在不同地质条件下实现了预测的稳定性与灵敏度的自适应平衡。

3 实验结果分析与讨论

所提出的方法基于 Python 语言实现.实验环境配置为 AMD 7940HS 处理器、16 GB 内存、NVIDIA GeForce RTX 4060 Laptop GPU,操作系统为 Windows 11.在进行模型测试时,设每口井的测试

样本总数为 n , 预测值记为 $\hat{y}_i$, 真实值记为 y_i . 模型预测性能采用平均绝对误差 (MAE)、均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 以及决定系数 (R^2) 4 种常用评价指标进行评估, 计算公式如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (19)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (20)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|, \quad (21)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (22)$$

3.1 数据预处理结果

以井 A 的数据为例, 经过 SWZ-Score 离群值剔除和小波滤波处理的数据如图 4 所示. 与原始数据相比, 异常值和随机噪声明显减少, 各参数随井深变化的整体趋势更加清晰, 数据连续性和稳定性得到显著改善. 这表明所采用的数据预处理方法能够有效提升钻井数据质量. 井 B 和井 C 作为测试井, 在模型预测前同样经过相同的预处理步骤, 以保证数据一致性.

3.2 声波时差软测量结果

在完成对所有井的数据预处理后, 采用井 A 数据训练模型, 井 B 和井 C 分别作为邻井测试集和盲

井测试集, 对所提方法的跨井泛化能力进行验证. 在预测任务设置上, 本文采用单步预测策略, 即利用当前 20 个深度点的历史数据, 预测当前深度点的声波时差值. 所有对比模型均采用相同的输入窗口长度和预测步长, 以保证实验的公平性. 预测结果如图 5 所示.

综合井 B 与井 C 的预测结果可以看出, 所建立的声波时差软测量模型不仅在邻井条件下具有较高的预测精度, 而且在盲井应用中仍能保持较好的趋势一致性与稳定性, 有较强的泛化能力. 总体而言, 该模型能够有效实现声波时差的软测量, 为缺失声波测井资料井段的参数补全提供了一种可靠手段.

3.3 对比实验

为进一步验证所提方法在声波时差预测任务中的有效性与优越性, 本文将其与多种常用机器学习与深度学习模型进行对比, 包括 SVM、RF、RNN、LSTM、Transformer 及 Autoformer, 预测结果及对应误差分布如图 6 所示.

从声波时差预测结果曲线可以看出, 在邻井 B 中, 各模型对声波时差的预测能力存在明显差异. 所提方法预测曲线与真实曲线在整体趋势和局部波动上均保持较高一致性, 能够较好地反映声波时差的变化特征; 相比之下, SVM 与 RF 虽能在部分深度区间内跟随实测趋势, 但在波动幅度和细节刻画方面存在一定偏差; 而 RNN、LSTM、Transform-




图 4 井 A 数据处理前后曲线对比

Fig.4 Comparison of curves for Well A before and after data processing

a. 钻速; b. 钻压; c. 扭矩; d. 泥浆流量; e. 声波时差

er 及 Autoformer 等模型在邻井 B 中预测稳定性较差,部分深度段出现明显偏离。

从预测误差曲线来看,所提方法的误差分布最为集中,绝大多数深度点的预测误差均控制在 $\pm 3\%$ 误差范围内,且误差波动幅度较小,表现出良好的稳定性。而其他对比方法的误差曲线波动较

大,部分模型在多个深度区间超出 3% 误差带,预测可靠性相对较低。

在盲井 C 中,尽管地层条件与训练井相差较大,所提方法仍能较好地捕捉声波时差的整体变化趋势,预测误差整体保持在较小范围内,体现出较强的泛化能力。相比之下,部分模型在盲井中的预测性能明显下降,误差增大,尤其是 RNN 和 Transformer 等模型,其误差波动较为显著。

为进一步定量衡量不同模型声波时差预测结果的准确性与稳定性,采用前文提到的 4 种评价指标对预测结果进行评价,各模型在邻井 B 与盲井 C 上的对比结果如表 4 所示。

从邻井 B 的评价指标可以看出,所提方法在 MAE、RMSE 和 MAPE 指标上均取得最优结果,分别为 5.286 8、6.981 0 和 4.580 2, R^2 达到 0.813 0,表明模型对声波时差曲线具有较高的拟合精度和相关性。相比之下,SVR 和 RF 的预测误差明显增大,而 RNN、LSTM、Transformer 和 Autoformer 等模型的 R^2 均为负值,说明其预测结果与实测值之间相关性较弱。

在盲井 C 的对比结果中,所提方法同样表现出较好的综合性能,其 MAE 和 RMSE 分别为 5.123 6 和 7.309 2,在所有模型中处于最低水平, R^2 为 0.460 7,优于大多数对比方法,仅与 LSTM 接近。尽管部分模型在盲井中仍具有一定预测能力,但整体精度和稳定性均不及所提方法,表明其泛化性能受限。

综合预测曲线、误差分布以及定量评价指标的




图 5 声波时差预测结果

Fig.5 DTCO prediction results

a. 井 B 预测结果; b. 井 C 预测结果




图 6 B 井与 C 井上所提方法预测结果与误差曲线

Fig.6 Prediction results and error curves for Wells B and C using the proposed method

a. B 井预测结果; b. B 井误差曲线; c. C 井预测结果; d. C 井误差曲线

表 4 不同模型在 B 井与 C 井上预测性能对比
Table 4 Comparison of predictive performance across different models for Wells B and C

井	模型	MAE	RMSE	MAPE	R ²
B	所提方法	5.286 8	6.981 0	4.580 2	0.813 0
	SVR	19.757 8	22.560 0	15.644 5	−0.953 0
	RF	5.847 7	8.375 9	5.139 9	0.730 8
	RNN	46.277 5	49.006 8	36.879 1	−8.217 0
	LSTM	33.250 6	36.181 2	26.216 5	−4.024 0
	Transformer	31.958 7	34.689 7	25.212 9	−3.618 0
	Autoformer	28.089 5	30.394 9	22.496 9	−2.545 0
C	所提方法	5.123 6	7.309 2	5.764 1	0.460 7
	SVR	6.312 5	8.322 5	6.914 4	0.300 8
	RF	6.496 3	8.403 7	7.237 3	0.287 1
	RNN	18.247 3	20.554 5	18.834 7	−3.265 0
	LSTM	5.575 5	7.390 9	6.181 6	0.448 6
	Transformer	9.225 6	10.943 4	9.765 2	−0.208 0
	Autoformer	7.483 4	9.576 4	8.075 8	0.074 3

对比结果可以看出,所提方法在邻井与盲井条件下均能够实现较高精度的声波时差预测,不仅在预测误差控制方面具有明显优势,而且在盲井中的泛化能力更为突出.该方法为缺失声波测井曲线的预测与补全提供了一种可靠手段,对后续地层评价与储层参数分析具有重要的工程应用价值.

4 结论

本文围绕海上钻探过程中声波时差难以实时获取、传统数据驱动模型在跨井应用中泛化能力不足的问题,提出了一种基于双域自适应混合专家模型的深海钻探过程声波时差软测量方法.该方法的核心思想是利用钻探过程中易于获取的参数,通过建模实现对难测参数声波时差的预测.具体而言,将声波时差预测分为具有较强可迁移性的低频趋势域与高频残差域,并分别构建多专家模型进行建模,有效缓解了单一模型在不同井间因地质条件差异引发的性能退化问题.

在此基础上,本文提出了一种自适应双域融合策略,动态评估两个域在不同井段的可信度,实现了双域预测结果的自适应加权融合.该策略在保证预测精度的同时显著增强了模型在跨井场景下的泛用性与稳定性,避免了残差修正在分布外工况下可能带来的风险放大.

基于多口实际海上钻井数据的对比实验结果表明,所提方法在跨井声波时差预测精度与稳定性

方面均优于 SVR、RF、RNN、LSTM、Transformer 等典型数据驱动模型,尤其在地质条件差异显著的测试井中仍能保持稳定的预测性能,验证了双域建模与自适应融合策略在提升跨井泛化能力方面的有效性.

综上所述,本文提出的双域自适应混合专家声波时差软测量方法,在不依赖测试井测井真值的前提下,实现了预测精度与跨井泛用性的有效平衡,具备良好的工程可实施性.该方法可为海上钻探过程中孔隙压力预测、地层力学参数反演及井壁稳定性评价提供可靠的实时输入,对复杂海洋环境下的安全、高效钻探具有重要的工程应用价值.

展望后续研究,可从以下几个方面展开:首先,本文方法主要基于钻井参数,未来可尝试融入区域地质先验信息,进一步增强模型在无井或少井区域的泛化能力;其次,随着深海钻探智能化水平的提升,可探索将本文方法与实时随钻决策系统相结合,构建钻前预测—钻中修正的闭环优化框架;此外,针对更复杂的地质场景(如裂缝性地层、水合物层等),可进一步优化双域分解策略,引入物理约束或机理模型,进一步提升模型的可解释性与可靠性.

References

Akinyemi, O. D., Elsaadany, M., Siddiqui, N. A., et al., 2023. Machine Learning Application for Prediction of Sonic Wave Transit Time: a Case of Niger Delta Basin. *Results in Engineering*, 20: 101528. <https://doi.org/10.1016/j.rineng.2023.101528>

Bertini, J. R., Lavi, B., 2025. Enhancing Rate of Penetration Prediction in Drilling Operations: a Data Stream Framework Approach. *Engineering Applications of Artificial Intelligence*, 143: 110034. <https://doi.org/10.1016/j.engappai.2025.110034>

Chen, X., Cao, W. H., Gan, C., et al., 2021. Semi-Supervised Support Vector Regression Based on Data Similarity and Its Application to Rock-Mechanics Parameters Estimation. *Engineering Applications of Artificial Intelligence*, 104: 104317. <https://doi.org/10.1016/j.engappai.2021.104317>

Chen, X., Cao, W. H., Gan, C., et al., 2022a. A Hybrid Partial Least Squares Regression-Based Real Time Pore Pressure Estimation Method for Complex Geological Drilling Process. *Journal of Petroleum Science and Engineering*, 210: 109771. <https://doi.org/10.1016/j.petrol.2021.109771>

Chen, X., Cao, W. H., Gan, C., et al., 2022b. A Hybrid Spatial Model Based on Identified Conditions for 3D Pore

- Pressure Estimation. *Journal of Natural Gas Science and Engineering*, 100: 104448. <https://doi.org/10.1016/j.jngse.2022.104448>
- Du, K., Xi, W. Q., Huang, S., et al., 2024. Deep-Sea Mineral Resource Mining: a Historical Review, Developmental Progress, and Insights. *Mining, Metallurgy & Exploration*, 41(1): 173—192. <https://doi.org/10.1007/s42461-023-00909-9>
- Eaton, B. A., 1972. The Effect of Overburden Stress on Geopressure Prediction from Well Logs. *Journal of Petroleum Technology*, 24(8): 929—934. <https://doi.org/10.2118/3719-pa>
- Feng, Y. W., Ren, Y., Zhang, G. C., et al., 2020. Petroleum Geology and Exploration Direction of Gas Province in Deepwater Area of North Carnarvon Basin, Australia. *China Geology*, 3(4): 623—632. <https://doi.org/10.31035/cg2020064>
- Gan, C., Cao, W. H., Liu, K. Z., et al., 2021. A New Spatial Modeling Method for 3D Formation Drillability Field Using Fuzzy C-Means Clustering and Random Forest. *Journal of Petroleum Science and Engineering*, 200: 108371. <https://doi.org/10.1016/j.petrol.2021.108371>
- Gan, C., Cao, W. H., Wu, M., et al., 2019. Prediction of Drilling Rate of Penetration (ROP) Using Hybrid Support Vector Regression: a Case Study on the Shennongjia Area, Central China. *Journal of Petroleum Science and Engineering*, 181: 106200. <https://doi.org/10.1016/j.petrol.2019.106200>
- Gartrell, A. P., 2000. Rheological Controls on Extensional Styles and the Structural Evolution of the Northern Carnarvon Basin, North West Shelf, Australia. *Australian Journal of Earth Sciences*, 47(2): 231—244. <https://doi.org/10.1046/j.1440-0952.2000.00776.x>
- Geekiyange, S. C. H., Tunkiel, A., Sui, D., 2021. Drilling Data Quality Improvement and Information Extraction with Case Studies. *Journal of Petroleum Exploration and Production Technology*, 11(2): 819—837. <https://doi.org/10.1007/s13202-020-01024-x>
- Lothe, A. E., Cerasi, P., Aghito, M., 2020. Digitized Uncertainty Handling of Pore Pressure and Mud-Weight Window Ahead of Bit: North Sea Example. *SPE Journal*, 25(2): 529—540. <https://doi.org/10.2118/189665-pa>
- Ramu, C., Sunkara, S. L., Ramu, R., et al., 2021. An ANN-Based Identification of Geological Features Using Multi-Attributes: a Case Study from Krishna-Godavari Basin, India. *Arabian Journal of Geosciences*, 14(4): 299. <https://doi.org/10.1007/s12517-021-06652-z>
- Su, Y. A., Dou, X. R., Gao, W. K., et al., 2023. Reflections and Outlook on the Development of Drilling-While-Measuring Technology for Oil and Gas Wells. *Bulletin of Petroleum Science*, 8(5): 535—554(in Chinese with English abstract).
- Tao, Z. X., Cao, W. H., Gan, C., 2025. Physically Interpretable Pore Pressure Prediction in Marine Strata through Embedded Depositional Mechanisms and Attention-Guided Learning. *SPE Journal*, 31(2): 946—962. <https://doi.org/10.2118/231425-pa>
- Wen, Z. X., Wang, J. J., Wang, Z. M., et al., 2023. Analysis of the World Deepwater Oil and Gas Exploration Situation. *Petroleum Exploration and Development*, 50(5): 1060—1076. [https://doi.org/10.1016/S1876-3804\(23\)60449-5](https://doi.org/10.1016/S1876-3804(23)60449-5)
- Xiang, M., Li, B., He, Y. M., et al., 2024. Research on Simulation Model of Deepwater Drilling and Optimization Method of Drilling Parameters Based on Energy. *Ocean Engineering*, 312: 119286. <https://doi.org/10.1016/j.oceaneng.2024.119286>
- Xu, C. L., Sun, J. M., Dong, X., et al., 2017. Novel Method for Predicting Pore Pressure in Shale Gas Reservoirs via Logging. *Acta Petrolei Sinica*, 38(06): 666—676(in Chinese with English abstract).
- Xu, K., Yang, H. J., Zhang, H., et al., 2023. Efficient Exploration Techniques for Deep Tight Gas Reservoirs Based on Geomechanical Methods: The Case of the Dibeigai Reservoir in the Kuqa Depression. *Earth Science*, 48(2): 621—639(in Chinese with English abstract).
- Yang, H., Feng, Y. C., Shang, G. Y., et al., 2025. A Sequence Learning Approach for Real-Time and A Head-of-Bit Pore Pressure Prediction Utilizing Drilling Data from the Drilled Section. *SPE Journal*, 30(2): 524—543. <https://doi.org/10.2118/223962-pa>
- Zhang, Z., Sun, B. J., Wang, Z. Y., et al., 2022. Formation Pressure Inversion Method Based on Multisource Information. *SPE Journal*, 27(2): 1287—1303. <https://doi.org/10.2118/209206-pa>

中文参考文献

- 苏义脑, 窦修荣, 高文凯, 等, 2023. 油气井随钻测量技术发展思考与展望. 石油科学通报, 8(5): 535—554.
- 徐春露, 孙建孟, 董旭, 等, 2017. 页岩气储层孔隙压力测井预测新方法. 石油学报, 38(6): 666—676.
- 徐珂, 杨海军, 张辉, 等, 2023. 基于地质力学方法的深层致密气藏高效勘探技术: 以库车坳陷迪北气藏为例. 地球科学, 48(2): 621—639.