

<https://doi.org/10.3799/dqkx.2026.197>



基于层次化堆叠自动编码器的钻井实时岩性识别方法

蒋联好¹, 陈茜^{1,2,3*}, 李奥¹, 杨能普¹, 吴岳忠¹

1. 湖南工业大学交通与电气工程学院, 湖南株洲 412007
2. 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
3. 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: 岩性识别在油气勘探中起着至关重要的作用。钻井数据能够提供经济高效的实时岩性表征,但其应用常受到岩性信号微弱、特征强耦合以及复杂非线性关系的限制。为克服这些局限,提出了一种基于层次化堆叠自动编码器的钻井实时岩性识别方法。该方法构建了由原始钻井参数、短时能量中间特征和最大信息系数驱动的正则化机制组成的分层特征学习框架,以增强钻井数据中弱岩性信息的表达能力,引导模型优先学习与岩性相关性较强的特征。在四个钻井数据集上的实验验证表明,所提出的方法整体性能优于 7 种基准方法,在 A 井上实现了 95.1% 的准确率和 93.6% 的 F1 分数,在 B 井上实现了 92.1% 的准确率和 86.0% 的 F1 分数。此外,该模型在跨井预测中表现出良好的泛化能力,对 C 井和 D 井的预测准确率分别达到 94.2% 和 95.4%,为实时岩性识别提供了一种稳健的解决方案。

关键词: 岩性识别; 钻井数据; 深度学习; 短时能量。

中图分类号: TE19

文章编号: 1000-2383(2026)08-2990-14

收稿日期: 2026-01-09

Hierarchical Stacked Autoencoders for Real-Time Lithology Identification While Drilling

Jiang Lianhao¹, Chen Xi^{1,2,3*}, Li Ao¹, Yang Nengpu¹, Wu Yuezhong¹

1. School of Transportation and Electrical Engineering, Hunan University of Technology, Zhuzhou 412007, China
2. Hubei Key Laboratory of Advanced Control and Intelligent Automation for Complex Systems, Wuhan 430074, China
3. Engineering Research Center of Intelligent Technology for Geo-Exploration, Ministry of Education, Wuhan 430074, China

Abstract: Lithology identification plays a crucial role in oil and gas exploration. Although drilling data can provides costeffective and realtime lithology characterization, its effectiveness is often constrained by weak lithological signals, strong feature coupling, and complex nonlinear relationships. To overcome these limitations, this study presents a hierarchical stacked autoencoderbased method for real-time lithology identification while drilling. The proposed method constructs a hierarchical feature learning framework composed of raw drilling parameters, shorttime energy intermediate features, and a maximal information coefficientdriven regularization mechanism. This framework enhances the representation of weak lithological information in drilling data and guides the model to preferentially learn features with stronger correlations to lithology. Experimental validation on four drilling datasets demonstrates that the proposed method outperforms seven benchmark methods overall. The proposed model

基金项目: 国家自然科学基金项目 (No. 62303177, 52302390); 湖南省自然科学基金项目 (No. 2024JJ6209, 2025JJ70057); 111 计划 (No. B17040); 湖南省教育厅科研项目 (No. 25C0372)。

作者简介: 蒋联好 (2000—), 男, 硕士研究生, 研究方向为复杂地质环境建模。ORCID: 0009-0006-1284-8270. E-mail: m24081100032@stu.hut.edu.cn

* **通讯作者:** 陈茜, ORCID: 0009-0007-7192-8219. E-mail: xichen@hut.edu.cn

引用格式: 蒋联好, 陈茜, 李奥, 杨能普, 吴岳忠, 2026. 基于层次化堆叠自动编码器的钻井实时岩性识别方法. 地球科学, 51(8): 2990—3003.

Citation: Jiang Lianhao, Chen Xi, Li Ao, Yang Nengpu, Wu Yuezhong, 2026. Hierarchical Stacked Autoencoders for Real-Time Lithology Identification While Drilling. *Earth Science*, 51(8): 2990—3003.

achieved 95.1% accuracy with an F1 score of 93.6% on Well A and 92.1% accuracy with an F1 score of 86.0% on Well B. Moreover, the model exhibited good generalization capability in crosswell prediction, yielding accuracies of 94.2% for Well C and 95.4% for Well D, offering a robust solution for realtime lithology identification.

Key words: lithology identification; drilling data; deep learning; shorttime energy.

0 引言

岩性识别是根据岩石特征对岩性单元进行分类的过程(Xu *et al.*, 2021),在提高油气勘探效率、降低钻井风险方面具有重要作用(Li *et al.*, 2021).现有研究多基于测井数据,综合运用统计分析和模式识别等方法进行岩性识别(王民等, 2023; 武宏亮等, 2025).然而,在复杂地质环境中,测井数据的获取仍面临诸多制约:采集成本高、耗时较长,还存在测井工具故障风险(Wang and Cao, 2023).此外,多数钻井现场并未配备专业测井工具,进一步限制了该项技术的应用.为实现经济高效且实时的岩性识别,研究者开始将钻井数据作为可替代的数据源(Wang *et al.*, 2023).

钻井数据是典型的时间序列数据,如钻速、钻压、转速和扭矩等,具有高实时性和连续性特征,由地面和井下传感系统在钻井作业过程中连续采集(Du *et al.*, 2024).这类参数能够表征钻井过程对地层特征的机械响应,进而为地层岩性识别等相关研究提供可靠数据支撑(Lazarová *et al.*, 2022).

近年来,机器学习技术在利用钻井数据进行岩性识别方面受到越来越多的关注(Li *et al.*, 2023).例如, Mahmoud *et al.*(2021)比较了多种神经网络模型,包括人工神经网络和自适应神经模糊推理系统,结果表明,神经网络在地层岩性预测中表现出较好的泛化能力. Chen *et al.*(2025)提出了一种基于长短期记忆网络的架构,该架构融合了双重注意力机制和小龙虾优化算法,侧重于提取空间与通道信息,相比传统静态模型能够更有效地适应复杂地质条件.然而,原始钻井数据中普遍存在强噪声干扰,往往会阻碍关键岩性信息的提取,这使得数据预处理成为开展岩性识别的重要环节. Yan *et al.*(2024)提出了一种将卡尔曼滤波与自适应加权k近邻算法相结合的方法,证明在分类前对输入信号进行预处理可提高岩性识别精度.频域特征的重要性也日益受到关注.例如, Zhang *et al.*(2025)将小波变换与自注意力机制相结合,提出了自注意力交叉小波变换模型,该模型通过同时利用时域和频域动

态特征,可有效提升复杂岩性的识别准确性与鲁棒性.此外,部分研究通过引入中间参数来提升模型的可解释性. Liang *et al.*(2022)开发了一种将钻井参数转换为中间参数,如机械比能,用于表征岩石强度和地层特性,从而丰富输入信息并提高模型性能.

综上,基于钻井数据的岩性识别仍面临诸多挑战.首先,钻井数据中的噪声极易掩盖岩性变化所引起的波动,导致地层过渡模糊.其次,各类钻井参数之间存在的强耦合性和复杂的非线性关系,进一步限制了分类精度的提升.为了克服这些困难,本文提出了一种基于最大信息系数正则化的堆叠自动编码方法(maximal information coefficient regularization-based stacked autoencoder, MR-SAE),通过分层特征学习,以建立钻井参数与岩性之间的内在关联,增强数据可靠性并降低噪声干扰,从而实现复杂地质条件下的高效岩性识别.本文的贡献体现在以下3个方面:

(1)基于多口真实钻井数据的混合建模框架:本研究仅利用实际钻井现场的钻井数据,构建了适用于岩性识别的混合建模框架,获得了准确且稳定的结果,为钻井工程的应用提供了参考.

(2)分层特征学习结构:为捕获深度序列中的幅频变化信息,所提方法采用层次化结构,构建了由原始钻井参数、短时能量中间特征和最大信息系数驱动正则化机制组成的分层特征学习结构.同时,利用一种自适应滑动窗口方法捕获与岩性高度相关的局部能量特征,从而增强常规钻井数据中的岩性信息,提高对岩性变化的敏感度.

(3)最大信息系数驱动的正则化机制:将最大信息系数作为正则化项引入堆叠自动编码器的预训练阶段.与传统的无监督预训练不同,该机制能够量化输入特征与岩性之间的非线性相关性,引导模型优先保留与岩性相关性较强的特征,从而有效降低特征耦合并抑制噪声.

本文的结构安排如下:第2章描述了钻井数据并分析了其与岩性的关系;第3章介绍了所提方法的模型框架;第4章详细阐述了建模过程;第5章利

表 1 用于建模分析的部分数据集
Table 1 Datasets used for analysis

		深度(m)	钻速(m/h)	扭矩(Nm)	转速(rpm)
A 井	Min	41.07	0.13	26.20	19.60
	Max	1 049.60	218.80	5 033.99	99.16
	Mean	548.56	3.39	2 184.77	49.76
	Std.	296.81	3.01	559.31	7.71
B 井	Min	655.30	0.22	13.24	1.69
	Max	2 296.94	29.79	1 887.23	107.31
	Mean	1 454.87	6.23	997.64	47.79
	Std.	500.36	4.52	188.66	14.06
C 井	Min	0.00	20.00	64.00	20.00
	Max	25.50	635.00	1 499.00	799.00
	Mean	11.51	103.82	528.06	496.99
	Std.	8.02	78.99	564.12	174.19
D 井	Min	0.00	60.00	60.00	98.00
	Max	25.51	660.00	177.00	701.00
	Mean	14.13	102.96	93.67	628.93
	Std.	7.12	59.10	12.67	41.61

用钻井数据验证了所提方法的有效性;第 6 章对全文进行了总结.

1 地质背景

本研究使用了来自 3 个不同区块的现场数据,共涉及 4 口井.该数据集具有样本规模大、岩性类型多样和地质背景复杂等特点,对保障预测模型的准确性与可靠性具有重要意义.表 1 列出了用于岩性识别建模分析的部分钻井参数统计特征,包括钻井深度、钻速、扭矩、转速.表中 Min、Max、Mean 和 Std 分别代表单变量数据的最小值、最大值、平均值和标准差.

选取了 A 井和 B 井的 19 600 个样本开展后续分析,其中 A 井位于中国湖北省襄阳市,B 井位于犹他州米尔福德地区.受地质条件控制,这两口井的地层岩性变化迅速,钻井参数波动明显(Gwynn *et al.*, 2018;Gan *et al.*, 2022).同时,两口井的岩性构成存在差异,具体如图 1a 和图 1b 所示.A 井岩性比例略有失衡,约为 36:30:17:11:6;B 井则呈现极度不平衡的比例,约为 63:23:7:3:3:2,此类分布不平衡对后续岩性分类模型的性能可能产生影响.

C 井和 D 井位于中国湖北省葛店地区相邻两口井的钻井数据,该区域地层结构复杂,岩性组成多样,致使不同地层的钻井响应存在差异.本研究从这两口井共采集了 9 400 个钻井样本,两口井具有




图 1 4 口井岩性分布图
Fig. 1 Lithology distribution of four wells

相似的岩性构成,且各岩性类型比例较为均衡.总体而言,上述来自不同井位的综合数据集充分体现了地质条件的多样性,对实现岩性精准识别与钻井作业决策制定具有重要意义.

1.1 岩性变化的响应

在钻井作业过程中,不同地层的力学特性存在显著差异,主要体现在硬度、密度和可钻性等方面.因此,钻速和扭矩等钻井参数表现出明显的动态响应特征.为了突出变化特性并减小信号波动的影响,本研究引入信号处理技术(王若平等, 2024),构建了短时能量特征作为中间参数,该特征通过捕获短时窗口内的局部波动,能够反映岩性变化.短时能量的计算公式如下所示:

$$E_n = \sum_{k=n-N+1}^n x^2(k), \tag{1}$$

其中: $x(k)$ 是信号的幅值, N 为窗口内的样本数.计算短时能量,就是信号在第 n 个点开始,在给定窗口范围内所有样本幅值平方和的统计量.

本文选取了两口井的钻井数据,分析短时能量特征对岩性变化的响应.图 2 展示了钻速和扭矩的变化趋势.可以看出,二者能够在一定程度上反映岩性变化,但由于岩石硬度、底部钻具组合以及环境噪声等因素的影响,这些参数存在明显的波动.

相比之下,构建的短时能量特征能够对研究层段内的幅值变化进行更精确、更灵敏的描述.在图2a中,当岩性从细砂岩变为灰岩时,钻速呈增大趋势,但伴随剧烈波动,此时钻速短时能量也能捕捉到这一趋势,且曲线更为平滑.在图2b中,当岩性从花岗岩过渡到花岗闪长岩时,钻速短时能量呈现下降趋势,而扭矩短时能量则呈上升趋势.此外,当岩性由花岗闪长岩过渡到片麻岩时,短时能量特征在岩性界面处出现峰值.

值得注意的是,部分岩性界面处的信号变化是渐变特征,而非突变特征,这主要与相邻地层之间存在混合岩性有关.上述这些结果表明,短时能量能够有效放大钻井信号中的局部波动,使地层变化特征更加明显.

这一现象可以从物理机制和信号处理原理两方面解释.当地层性质发生突变时,钻头和岩石界面会产生瞬态冲击,导致信号能量局部集中.短时能量方法通过滑动窗口量化这种局部能量,进而在岩性界面处产生明显的峰值.相较于依赖绝对幅值的原始钻井参数,短时能量特征聚焦于信号波动强度和变化速率,对钻井作业扰动和随机噪声等干扰因素具备更强的鲁棒性.

2 模型框架设计

本研究基于堆叠自动编码器(stacked autoencoders, SAE)提出了一种层次化钻井实时岩性识别方法,其总体框架如图3所示,主要包括3个阶段.首先针对原始数据中的强噪声和强耦合干扰,第一阶段采用小波滤波对原始信号进行去噪处理,然后选取对岩性变化敏感的钻井参数特征构建短时能量特征作为中间参数,以增强常规钻井数据中的岩性特征.在下一阶段,针对输入特征与岩性标签之间的强非线性关系,将最大信息系数(maximal information coefficient, MIC)引入堆叠自动编码器的预训练阶段,构建MIC驱动的正则化机制.在编码过程中,高维输入被映射到低维潜在空间,同时利用MIC量化各特征与岩性标签之间的相关性,并将其作为权重矩阵的自适应惩罚项,以强化判别性特征的提取,有效抑制噪声与冗余信息干扰.最后,在模型微调阶段,将预训练后的编码器进行堆叠连接,并在其后接入Softmax分类层,构建最终的网络,实现多类别岩性识别任务.

3 建模方法

本节详细阐述所提方法的建模过程.由于钻井数据存在多种类型的噪声、特征耦合以及强非线性问题,因此开展数据预处理并构建高精度岩性识别模型具有重要的研究意义与工程价值.

3.1 数据去噪

在钻井工程中,现场采集的原始数据通常包含多种类型的噪声,会大幅降低后续数据分析的可靠性(Geekiyanage *et al.*, 2021). Chen *et al.* (2022b)在孔隙压力预测的研究中引入了小波滤波策略,结果表明,该方法能够对原始数据进行预处理,有效提高估算精度.本研究采用相同的小波滤波方法对原始钻井数据进行预处理,选取dmey函数作为小波基函数,并执行两层小波分解.小波变换及小波逆变换的定义如下:

$$W_x(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-\tau}{s}\right) dt, \quad (2)$$

$$x(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W_x(s, \tau) \frac{1}{s^2} \psi\left(\frac{t-\tau}{s}\right) d\tau ds, \quad (3)$$

其中: s 和 τ 分别代表伸缩因子和尺度因子, $\psi(t)$ 是所选择的小波基, C_ψ 为小波因子.受篇幅限制,本文选取4口井中部分参数的滤波结果进行展示如图4a~4d所示,该滤波方法在有效抑制高频噪声的同时,很好地保留了原始数据的整体变化趋势.

3.2 动态特征构建

有限深度窗口内钻井参数的局部变化可通过短时能量进行统计表征,合理构建短时能量特征能够捕捉岩性的突变特征.而构建有效短时能量特征的关键在于选取对岩性敏感的钻井参数并确定时间窗口大小.

研究表明,钻速与岩石强度及岩性变化具有显著相关性,其变化特征与地层界面位置吻合良好,是岩性识别的关键参数(You *et al.*, 2024). Yue *et al.* (2022)提出扭矩在地层界面处表现出明显的响应特征,具有优异的界面敏感性.因此,本研究同时选取钻速和扭矩构建短时能量特征,以增强钻速信号对岩性变化的瞬态响应表征能力.

较大的窗口能够捕捉更宽泛的能量变化,但可能掩盖重要的局部细节;而较小的窗口对短时信号变化响应更灵敏,却更容易受噪声干扰.为此,本研究提出了一种基于最大信息系数驱动的短时能量窗口优化策略(具体如算法1所示),以确定最优窗




图 2 短时能量与地层岩性相关性

Fig. 2 Correlation between short-time energy and formation lithology

口尺寸,此尺寸是基于当前深度点窗口内的历史数据计算当前短时能量,用来表征地层岩性垂向变化规律. 确保计算得到的短时能量特征与岩性具有最强的相关性. 候选窗口集范围设为 $W=\{50, 60, 70, 80, 90, 100\}$,该范围是根据采样分辨率与典型

岩性层厚度共同确定的.

本研究中 4 口井对应的滑动窗口尺寸如图 5 所示,结果显示不同井及不同钻井参数的最优窗口尺寸存在差异. 在图 5b 中,钻速短时能量的 MIC 在 $W=70$ 时达到全局最高,与岩性相关性最强,而扭矩




图3 方法总体框架

Fig. 3 Overall framework of the method

短时能量的最优窗口为 $W=60$ 。这一差异在图 4c 中更为明显, 钻速短时能量倾向于采用较大窗口 ($W=100$) 以捕捉整体趋势, 而扭矩短时能量则在最小窗口 ($W=50$) 处相关性最强, 这些结果表明, 不同钻井参数对岩性变化的响应尺度并不相同, 因此有必要针对不同参数自适应确定最优窗口尺寸。

3.3 基于最大信息系数的正则化

考虑到钻井数据中固有的强耦合性和高非线性, 本研究引入 SAE 开展相关研究。SAE 作为深度学习领域中常用的无监督特征学习模型, 能够从原始高维、强耦合和非线性数据中自动提取分层抽象特征表示 (Chen *et al.*, 2022a)。它由多个自编码器堆叠而成, 每个自编码器包含编码器和解码器两部分。编码器通过非线性映射函数将高维输入数据映射到低维隐层空间, 以提取数据的潜在特征; 解码器则利用这些特征重构原始输入 (刘玉琳等, 2025)。通过最小化输入与输出之间的重构误差, 驱动网络捕捉最具代表性的结构。设 x_i 和 x'_i 分别表示输入样本和重构样本, N 为样本数 SAE 的重构损失如式 4 所示。通过这种多层非线性映射, SAE 能够从原始数据中逐层提取抽象特征表示。这些特征不仅捕捉数据中的线性关系, 还能捕捉复杂的非线性关系。此外, 通过分层预训练与微调, SAE 能够有效

增强特征表达能力, 提高模型的鲁棒性和预测性能。

$$J(W) = \frac{1}{2N} \sum_{i=1}^N (x'_i - x_i)^2. \quad (4)$$

不同输入特征对目标变量的预测重要性各不相同。然而, 在 SAE 的无监督预训练阶段, 权重矩阵是随机初始化的, 且模型仅以最小化输入重构误差为优化目标。在此过程中网络缺乏特定任务的监督信号, 倾向于盲目强调那些有助于重构输入的特征, 而没有明确考虑它们与后续预测任务的相关性。因此, 该阶段忽略了输入特征和目标变量之间的相关性信息, 从而对后续监督任务的性能产生不利影响 (Ou *et al.*, 2022)。针对这一问题, 本文通过将 MIC 与 L_2 正则化相结合, 提出了 MR-SAE 算法。该算法通过修改预训练阶段的损失函数, 控制输入特征的权重参数。SAE 第一层使用增强后的特征作为输入, 其 MIC 权重由输入特征与标签之间的相关性确定, 而第二层以上的 MIC 权重, 其输入是上一层编码器提取的隐藏特征, 然后计算与标签之间的相关性得到, 这种计算方法能够更加关注与目标变量密切相关的特征, 并赋其更大的权重系数。

为了利用 MR-SAE 算法建立钻井岩性识别模型, 首先计算各钻井参数与岩性之间的最大信息系数。最大信息系数是一种相关性度量指标, 它先将




图 4 小波滤波去噪前后对比曲线

Fig. 4 Comparison curves before and after wavelet filtering denoising

算法 1:基于 MIC 的短时能量滑动窗口优化
(1)输入:钻井数据 $X=\{x_1,\cdots,x_n\}$,岩性标签 $Y=\{y_1,\cdots,y_n\}$,候选窗口 $W=\{w_1,\dots,w_K\}$.
(2)输出:最优滑动窗口 w^*
(3)For 每一个候选窗口 W do
(4)计算短时能量序列:
(5) $E_w[i]=\sum_{j=\max(1,i-w+1)}^i x_j^2, \forall i \in [1,n]$
(6)通过 MIC 评估相关性:
(7) $\rho_w = \text{MIC}(E_w, Y)$
(8)End for
(9)选择相关性最大的窗口:
$w^* = \arg \max_{w \in W} \{\rho_w\}$
(10)Return w^*

两个变量 X 和 Y 之间的关系表示为二维空间中的散点图. 随后,采用不同的划分方案(如不同的网格数和纵横比)将该空间划分为小网格. 最后,计算每种网格划分下的互信息,选取最大值并进行归一化处理,得到该系数. 最大信息系数 $MIC(X, Y)$ 的计算公式定义为:

$$MIC(X, Y) = \max_{a \times b < B} \frac{I(X, Y)}{\log_2 \min(a, b)}, \quad (5)$$

其中: a 和 b 分别表示水平方向和垂直方向上划分格子的个数. B 的大小一般设置为数据量的0.6次方左右,最大信息系数的取值范围为 $(0, 1]$,0表示变量相互独立,而1则表示完全相关.

最大信息系数采用基于网格的离散化方法,能够有效量化连续钻井参数与离散岩性标签之间的




图 5 短时能量自适应窗口

Fig. 5 Adaptive window for short-time energy

统计依赖关系,并具有较强的泛化能力.将计算得到的最大信息系数值融入堆叠自动编码器预训练阶段的损失函数,具体如下所示:

$$J(W) = \frac{1}{2N} \sum_{i=1}^N (x'_i - x_i)^2 + \frac{\alpha}{2} \sum_{n=1}^{N_x} \sum_{m=1}^{N_h} (1 - \text{MIC}(x_n, y)) W_{nm}^2, \quad (6)$$

其中: α 是正则化系数, N_h 代表隐藏层神经元个数, N_x 表示输入层神经元个数, W 为权重参数.通常,带有惩罚项的损失函数仅对网络的权重参数 W 施加正则化约束,而不对偏置或输入变量进行限制.它通过基于特征与标签之间的相关性施加权重惩罚,从而抑制不相关特征对模型的影响.惩罚项采用 L_2 正则化.以编码部分的权重更新为例,其梯度下降函数变为:

$$\begin{aligned} W_{nm}^{t+1} &= W_{nm}^t - \eta \nabla_w J(W) - \\ &\quad \eta \cdot \alpha (1 - \text{MIC}(x(n), y)) W_{nm}^t, \quad (7) \\ &= (1 - \eta \cdot \alpha (1 - \text{MIC}(x(n), y))) W_{nm}^t \\ &\quad - \eta \nabla_w J(W) \end{aligned}$$

其中: η 是学习率, $\nabla_w J(W)$ 为损失函数对权重参数的偏导.由式4可知,当 $\text{MIC}(x(n), y)$ 增大时, $(1 - \eta \cdot \alpha (1 - \text{MIC}(x(n), y)))$ 也随之增大,这意味着第 n 个钻井参数对应的权重衰减程度减小,迭代完成后对其赋予的权重也就更大,使得这种自适应衰减机制有效引导网络优先关注岩性信息丰富的特征.

3.4 类别加权平衡调整

针对岩层厚度差异导致钻井数据中岩性类别

分布不均衡问题,在MR-SAE算法的微调阶段,采用加权交叉熵损失函数作为优化目标.具体而言,对于样本数量较小的岩性类别,赋予较大的类别权重,以引导模型更加充分地学习少数类特征,降低误分类风险.加权损失函数 L_w 的表达式如下:

$$L_w = - \sum_{c=1}^C w_c y_c \log(p_c), \quad (8)$$

其中: y_c 表示类别的真实标签, p_c 为模型Softmax层输出的第 c 类预测概率, C 为岩性类别总数. w_c 为类别 c 的权重.在本研究中,类别权重设为对应类别样本数量平方根的倒数,即样本数量越少,其类别权重越大.

4 实验与讨论

本研究采用第2章所述4口井的钻井数据,对所提出的MR-SAE模型进行全面评估.不同井的实验目的有差异:其中,A井和B井用于开展单井实验及对比分析,在相同实验条件下验证所提方法相较于其他算法的性能;C井和D井用于开展跨井预测实验,重点评估模型在未知场景下的泛化性能.

钻井作业遵循由浅至深的顺序,因此数据集划分策略须与这一物理过程保持一致.为此,本研究采用深度序列交叉验证策略,样本严格按钻井深度排序,不进行随机打乱,如图6所示.

评价指标方面,本文采用准确率衡量模型的整体分类性能,考虑到不同岩性层厚度差异会导致样本分布不均衡,并进一步引入宏平均下的精确率、

召回率与F1分数,以更全面反映模型在类别不均衡条件下的分类性能.此外,本文还引入马修斯相关系数进行性能评估,以补充评价模型在类别不均衡场景下的判别稳定性.

为保证MR-SAE模型获得最优配置,并确保实验过程的一致性和可重复性,本研究采用Optuna超参数调优框架进行优化(Akiba *et al.*, 2019).共进行了500次优化试验,并以验证集准确率作为目标函数指导参数选择,所得最优参数如表2所示.

4.1 不同数据集上的模型对比

本研究采用了5种流行的机器学习方法,即随机森林(RF)、K近邻(KNN)、支持向量机(SVM)、网格搜索-人工神经网络(GS-ANN)以及小波变换自交叉注意力模型(SACWT).为探究短时能量和最大信息系数正则化项的影响,设计了3种模型:未使用短时能量和最大信息系数正则化的原始堆

叠自动编码器模型(SAE)、仅使用短时能量而未使用最大信息系数正则化的SAE模型(N1),以及所提方法,即同时使用短时能量和最大信息系数正则化的MR-SAE模型(Proposed).

各方法在A井和B井上的单井实验结果汇总于表3.在A井实验中,所提出的MR-SAE模型整体性能最优结果.例如,在测试集上,所提方法达到了95.1%的准确率,分别比RF、KNN、SVM、GS-ANN和SACWT高出8.6%、10.2%、10.6%、9.7%和1.9%.在B井的实验中,所提方法继续展现出较好的性能,准确率为92.1%,精确率为89.5%,召回率为86.3%,F1分数为86.0%.值得注意的是,尽管SACWT取得了略高的94.1%准确率,但其精确率、召回率和F1分数分别显著偏低,仅为78.5%、77.4%和75.7%,表明该模型在不同岩性上的分类稳定性较差,也说明仅依赖准确率可能高估模型性能.同时,图7的箱线图显示,所提方法在重复实验中表现出优异的稳定性,而其他对比方法普遍存在波动大或精度不足的问题.这凸显了所提方法在稳定性和准确性方面的综合优势.




图6 深度序列交叉验证
Fig. 6 Depth-sequential cross-validation

表 2 MR-SAE 算法超参数调优		
Table 2 MR-SAE algorithm hyperparameter tuning		
超参数	取值范围	最优参数
堆叠层数	2, 3, 4	2
预训练学习率	[0.000 1, 0.1]	0.004
预训练迭代次数	[10, 80]	16
微调阶段学习率	[0.001, 0.1]	0.005
微调迭代次数	[100, 1 000]	380
正则化系数 α	[0.01, 1]	0.6

表 3 A 井与 B 井不同岩性识别模型性能对比									
Table 3 Performance comparison of different models for lithology identification on Well A and Well B									
	指标	RF	KNN	SVM	GS-ANN	SACWT	SAE	N1	Proposed
井 A	准确率	0.865	0.849	0.845	0.854	0.932	0.858	0.919	0.951
	精确率	0.923	0.895	0.900	0.713	0.911	0.886	0.932	0.960
	召回率	0.768	0.734	0.729	0.681	0.901	0.778	0.878	0.923
	F1 分数	0.811	0.770	0.771	0.700	0.888	0.794	0.895	0.936
	马修斯系数	0.826	0.794	0.801	0.830	0.910	0.791	0.861	0.937
井 B	准确率	0.790	0.650	0.728	0.821	0.941	0.754	0.864	0.921
	精确率	0.834	0.722	0.612	0.823	0.785	0.696	0.821	0.895
	召回率	0.664	0.555	0.610	0.706	0.774	0.614	0.737	0.863
	F1 分数	0.668	0.523	0.549	0.707	0.757	0.651	0.733	0.860
	马修斯系数	0.646	0.400	0.511	0.698	0.859	0.760	0.806	0.865

进一步分析表明,MR-SAE模型的良好性能可归因于短时能量与最大信息系数引导的正则化的共同作用.为验证短时能量的有效性,在SAE与N1




图 7 不同算法模型在两口井的箱线图

Fig. 7 Box plots of different algorithm models for two wells




图 8 加入短时能量前后对比

Fig.8 Comparison before and after short-time energy addition

之间进行了消融研究.如表3所示,在A井上准确率提高了约6%,在B井上提高了约11%.这一提升主要归因于短时能量一方面能够弥补钻井参数中岩性信息不足的缺陷,增强了参数与岩性之间的相关性;另一方面,能够捕捉不同岩性层对应的局部信号变化,也可以从图8看出,加入短时能量后,两口井上所有基线模型的准确率均获得一致的提升.而最大信息系数正则化则通过约束模型聚焦于与岩性标签存在高度非线性依赖关系的关键特征,助力模型提取更具判别性与鲁棒性的特征表示.N1与Proposed的对比验证了该机制的有效性,加入最大信息系数正则化后,A井准确率从91.9%提升至95.1%,B井从86.4%提升至92.1%,通过引导潜在特征学习与短时能量形成互补.

综上所述,模型方法对比与消融研究表明,短时能量与最大信息系数的结合增强了MR-SAE模型的特征学习能力.这种协同作用使得模型能够从钻井数据中提取出更具判别性的特征,充分印证了方法设计的合理性.

4.2 混淆矩阵分析

由于地层厚度变化,不同岩性类型的样本分布不均衡.厚的地层样本多,而薄的地层样本少,这容易导致模型偏向多数类,而降低对少数岩性的识别.因此,混淆矩阵可作为评估各类别分类性能的工具,其对角线元素表示正确分类样本,非对角线元素表示错误分类.

A井的混淆矩阵如图9所示.多数模型能够准确识别灰岩等岩性,但白云岩与炭质白云岩的区分仍存在挑战,主要是两种岩性在原始特征空间中的特征重叠度较高.然而,所提出的MR-SAE模型能够有效提取其特征关系,在所有对比模型中表现最优,对白云岩的识别准确率达到74.7%.B井的对比结果如图10所示,结果表明MR-SAE模型在大多数岩性上均表现出良好的分类性能,其中对花岗冲积层和片麻岩的识别准确率分别达到98.2%和100.0%.主要的混淆发生在闪长岩、花岗闪长岩和花岗岩之间,归因于它们具有相似的矿物组成.相比之下,SACWT模型虽在花岗冲积层、花岗闪长岩和花岗岩上表现良好,但在片麻岩和长英质岩脉上的准确率分别仅为62.0%和31.1%,凸显了SACWT模型对样本量的依赖,在数据稀少的类别上泛化性能较差.综上,在加权交叉熵损失函数的优化作用下,结合最大信息系数正则化与短时能量,MR




图 9 不同模型在 A 井上的混淆矩阵

Fig. 9 Confusion matrices of different models on Well A
LST. 灰岩;CDL. 炭质白云岩;CSH. 炭质页岩;DL. 白云岩;FST. 细砂岩




图 10 不同模型在 B 井上的混淆矩阵

Fig. 10 Confusion matrices of different models on Well B
GR. 花岗岩;GN. 片麻岩;DI. 闪长岩;GD. 花岗闪长岩;FD. 长英质岩脉;AL. 花岗岩冲积层

-SAE模型对少数类样本表现出更强的识别能力和鲁棒性,从而提高了分类准确率。

4.3 跨井预测实验

为进一步评估模型在不同地质条件下的泛化

能力和鲁棒性,开展了跨井预测实验。在钻井作业中,不同井在岩性分布、地层序列和信号响应方面均存在差异。因此,与同井测试集评估相比,在未知井上进行测试,能够比同井测试集评估更加严格检

表 4 跨井模型验证性能对比									
Table 4 Performance comparison of cross-well model validation									
	指标	RF	KNN	SVM	GS-ANN	SACWT	SAE	N1	Proposed
训练:C 井 测试:D 井	准确率	0.768	0.768	0.757	0.878	0.919	0.836	0.930	0.954
	精确率	0.798	0.810	0.802	0.898	0.925	0.871	0.928	0.952
	召回率	0.704	0.726	0.728	0.849	0.911	0.843	0.919	0.948
	F1 分数	0.728	0.746	0.747	0.868	0.917	0.839	0.924	0.950
	马修斯系数	0.895	0.317	0.426	0.352	0.891	0.668	0.840	0.915
训练:D 井 测试:C 井	准确率	0.929	0.514	0.576	0.583	0.935	0.794	0.892	0.942
	精确率	0.943	0.642	0.711	0.785	0.925	0.872	0.912	0.942
	召回率	0.899	0.458	0.546	0.577	0.924	0.708	0.848	0.922
	F1 分数	0.911	0.397	0.447	0.501	0.924	0.672	0.859	0.929
	马修斯系数	0.771	0.741	0.758	0.824	0.889	0.765	0.888	0.938




图 11 D 井岩性识别结果可视化

Fig. 11 Visualization of lithology identification results for Well D

模型基于 C 井数据构建

验模型的适用性和可靠性。C 井和 D 井位于同一地质区域,岩性类型相同。因此,本文设计了两种跨井验证场景:场景 1(在 C 井上训练,在 D 井上测试)和场景 2(在 D 井上训练,在 C 井上测试)。

两种场景下的实验结果汇总于表 4,在场景 1 的实验中,所提方法取得了最佳的综合性能,准确率为 95.4%,F1 分数为 95.0%,马修斯系数为 91.5%。相比之下,RF、KNN 和 SVM 的准确率在 75.7%~76.8% 之间,低于所提方法,图 11 的定性对比进一步验证了这些优势,MR-SAE 预测的岩性与真实岩性分布较为一致。尽管 GS-ANN 和 SACWT 总体上能够反映地层岩性分布,但在岩性过渡附近仍存在局部分类误差。

为进一步检验模型的跨域稳定性,互换训练井

与测试井开展反向验证,结果显示所提 MR-SAE 模型仍保持 94.2% 的预测准确率。相比之下,KNN 和 SVM 的性能严重下降,准确率分别降至 51.4% 和 57.6%,表明其对领域偏移高度敏感。相应的岩性预测结果可视化如图 12 所示,KNN 和 SVM 表现出连续错误预测,反映出它们在跨井泛化能力上的局限性。相比之下,MR-SAE 模型的预测结果与实际岩性分布相匹配,不同深度地层的岩性及其变化趋势能够准确识别。

上述实验结果证实,最大信息系数正则化机制与短时能量使 MR-SAE 模型能够学习到可迁移性的通用特征表示,在未知井况下依旧能够维持高精度的分类性能,表明其在智能钻井和实时岩性监测系统的实际部署中具有良好的应用潜力。




图 12 C 井岩性识别结果可视化

Fig. 12 Visualization of lithology identification results for Well C
模型基于 D 井数据构建

5 结论

本研究提出了一种融合分层特征学习的最大信息系数正则化堆叠自动编码器 MR-SAE,用于复杂钻井过程中的实时岩性识别.该方法在一定程度上缓解了岩性信号弱、特征耦合性强及复杂非线性关系等关键问题.该方法构建了短时能量作为中间参数,并采用自适应窗口捕获与地层变化相关的局部能量波动.同时,通过将最大信息系数作为正则化项引入堆叠自动编码器的预训练阶段,使模型能够更高效地提取与岩性相关的特征,抑制噪声和无关信息.

基于 4 口真实钻井数据的实验表明,所提方法在单井识别和跨井预测任务中均表现出较好的分类性能.具体而言,该方法在 A 井和 B 井上分别实现了 95.1% 和 92.1% 的识别准确率,对 C 井和 D 井的预测准确率分别达到 94.2% 和 95.4%.消融实验进一步证实,短时能量特征增强与最大信息系数正则化的协同效应是实现模型高性能的关键.此外,C 井和 D 井的跨井预测实验验证了模型在适应不同地质领域方面具有强大的鲁棒性和泛化能力.未来研究将聚焦于优化模型以提高对少数类别的敏感性,从而进一步提升其精度和可靠性.

References

Akiba, T., Sano, S., Yanase, T., et al., 2019. Optuna: A Next-Generation Hyperparameter Optimization Framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*.

Anchorage AK USA: ACM, 2623–2631. <https://doi.org/10.1145/3292500.3330701>

Chen, J., Gui, Z., Rui, Y. C., et al., 2025. A Dual Attention-Based Deep Learning Model for Lithology Identification while Drilling. *Journal of Rock Mechanics and Geotechnical Engineering*, 18(2): 1177–1192. <https://doi.org/10.1016/j.jrmge.2025.03.051>

Chen, J. M., Fan, S. S., Yang, C. H., et al., 2022a. Stacked Maximal Quality-Driven Autoencoder: Deep Feature Representation for Soft Analyzer and Its Application on Industrial Processes. *Information Sciences*, 596: 280–303. <https://doi.org/10.1016/j.ins.2022.02.049>

Chen, X., Cao, W. H., Gan, C., et al., 2022b. 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>

Du, S., Huang, C., Ma, X., et al., 2024. A Review of Data-Driven Intelligent Monitoring for Geological Drilling Processes. *Processes*, 12(11): 2478. <https://doi.org/10.3390/pr12112478>

Gan, C., Cao, W. H., Liu, K. Z., et al., 2022. A Novel Dynamic Model for the Online Prediction of Rate of Penetration and Its Industrial Application to a Drilling Process. *Journal of Process Control*, 109: 83–92. <https://doi.org/10.1016/j.jprocont.2021.12.002>

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>
- Gwynn, M., Allis, R., Hardwick, C., et al., 2018. Rock Properties of FORGE Well 58-32, Milford, Utah. *GRC Transactions*, 42
- Lazarová, E., Kruláková, M., Krúpa, V., et al., 2022. Regime and Rock Identification in Disintegration by Drilling Based on Vibration Signal Differentiation. *International Journal of Rock Mechanics and Mining Sciences*, 149: 104984. <https://doi.org/10.1016/j.ijrmms.2021.104984>
- Li, Q. F., Peng, C., Fu, J. H., et al., 2023. A Comprehensive Machine Learning Model for Lithology Identification While Drilling. *Geoenergy Science and Engineering*, 231: 212333. <https://doi.org/10.1016/j.geoen.2023.212333>
- Li, Z. R., Wu, Y. P., Kang, Y., et al., 2021. Feature-Depth Smoothness Based Semi-Supervised Weighted Extreme Learning Machine for Lithology Identification. *Journal of Natural Gas Science and Engineering*, 96: 104306. <https://doi.org/10.1016/j.jngse.2021.104306>
- Liang, H. B., Chen, H. F., Guo, J. H., et al., 2022. Research on Lithology Identification Method Based on Mechanical Specific Energy Principle and Machine Learning Theory. *Expert Systems with Applications*, 189: 116142. <https://doi.org/10.1016/j.eswa.2021.116142>
- Liu, Y. L., Bai, Y., Cui, B., et al., 2025. A Survey on Automated Feature Engineering for Machine Learning. *Computer Applications and Software*, 42(1): 1—10, 40(in Chinese with English abstract).
- Mahmoud, A. A., Elkatatny, S., Al-AbdulJabbar, A., 2021. Application of Machine Learning Models for Real-Time Prediction of the Formation Lithology and Tops from the Drilling Parameters. *Journal of Petroleum Science and Engineering*, 203: 108574. <https://doi.org/10.1016/j.petrol.2021.108574>
- Ou, C., Zhu, H. Q., Shardt, Y. A. W., et al., 2022. Quality-Driven Regularization for Deep Learning Networks and Its Application to Industrial Soft Sensors. *IEEE Transactions on Neural Networks and Learning Systems*, 36(3): 3943—3953. <https://doi.org/10.1109/TNNLS.2022.3144162>
- Wang, C., Xue, Q. L., He, Y. M., et al., 2023. Lithological Identification Based on High-Frequency Vibration Signal Analysis. *Measurement*, 221: 113534. <https://doi.org/10.1016/j.measurement.2023.113534>
- Wang, J., Cao, J. X., 2023. A Lithology Identification Approach Using Well Logs Data and Convolutional Long Short-Term Memory Networks. *IEEE Geoscience and Remote Sensing Letters*, 20: 7506405. <https://doi.org/10.1109/LGRS.2023.3322677>
- Wang, M., Yang, J. L., Wang, X., et al., 2023. Identification of Shale Lithofacies by Well Logs Based on Random Forest Algorithm. *Earth Science*, 48(1): 130—142(in Chinese with English abstract).
- Wang, R. P., Chen, Y., Wang, D., et al., 2024. Vehicle Interior Abnormal Noise Recognition Based on Muti-Feature Extraction and Svm Optimized by Gray Wolf Optimization. *Computer Applications and Software*, 41(3): 41—48(in Chinese with English abstract).
- Wu, H. L., Lai, Q., Feng, Z., et al., 2025. Progress on Key Technologies for Logging Evaluation of Deep and Ultra-Deep Carbonate Reservoirs. *Earth Science*, 50(7): 2844—2860(in Chinese with English abstract).
- Xu, Z. H., Shi, H., Lin, P., et al., 2021. Integrated Lithology Identification Based on Images and Elemental Data from Rocks. *Journal of Petroleum Science and Engineering*, 205: 108853. <https://doi.org/10.1016/j.petrol.2021.108853>
- Yan, T., Xu, R., Sun, S. H., et al., 2024. A Real-Time Intelligent Lithology Identification Method Based on a Dynamic Felling Strategy Weighted Random Forest Algorithm. *Petroleum Science*, 21(2): 1135—1148. <https://doi.org/10.1016/j.petsci.2023.09.011>
- You, M. L., Hong, Z. K., Tan, F., et al., 2024. Stratigraphic Identification Using Real-Time Drilling Data. *Journal of Rock Mechanics and Geotechnical Engineering*, 16(9): 3452—3464. <https://doi.org/10.1016/j.jrmge.2024.02.012>
- Yue, Z. W., Yue, X. L., Wang, X., et al., 2022. Experimental Study on Identification of Layered Rock Mass Interface along the Borehole while Drilling. *Bulletin of Engineering Geology and the Environment*, 81(9): 353. <https://doi.org/10.1007/s10064-022-02861-2>
- Zhang, J. F., Liu, Y., Ma, Y. H., et al., 2025. Real-Time Lithology Identification from Drilling Data with Self & Cross Attention Model and Wavelet Transform. *Geoenergy Science and Engineering*, 244: 213427. <https://doi.org/10.1016/j.geoen.2024.213427>

中文参考文献

- 刘玉琳, 白杨, 崔斌, 等, 2025. 面向机器学习的自动化特征工程研究综述. *计算机应用与软件*, 42(1): 1—10, 40.
- 王民, 杨金路, 王鑫, 等, 2023. 基于随机森林算法的泥页岩岩相测井识别. *地球科学*, 48(1): 130—142.
- 王若平, 陈严, 王东, 等, 2024. 基于多特征提取与灰狼算法优化SVM的车内异响识别方法. *计算机应用与软件*, 41(3): 41—48.
- 武宏亮, 赖强, 冯周, 等, 2025. 深层—超深层碳酸盐岩储层测井评价关键技术进展. *地球科学*, 50(7): 2844—2860.