

天然气地球科学  
Natural Gas Geoscience  
ISSN 1672-1926,CN 62-1177/TE

## 《天然气地球科学》网络首发论文

- 题目： 基于概率与岩石物理信息神经网络的测井多参数反演方法  
作者： 高溯宁，徐朝晖，田淼，徐怀民  
收稿日期： 2025-01-21  
网络首发日期： 2025-05-21  
引用格式： 高溯宁，徐朝晖，田淼，徐怀民. 基于概率与岩石物理信息神经网络的测井多参数反演方法[J/OL]. 天然气地球科学.  
<https://link.cnki.net/urlid/62.1177.te.20250520.1744.004>



**网络首发：**在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

**出版确认：**纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

DOI: 10.11764/j.issn.1672-1926.2025.05.002

# 基于概率与岩石物理信息神经网络的测井 多参数反演方法

高翊宁<sup>1</sup>, 徐朝晖<sup>\*1</sup>, 田森<sup>2</sup>, 徐怀民<sup>1</sup>

(1.中国石油大学(北京)地球科学学院, 北京 102249;

2.页岩油气富集机理与高效开发全国重点实验室, 北京 102206)

**摘要:**准确预测储层物性参数是储层评价和生产决策中的关键环节。测井数据反演的常用方法主要包括岩石物理模型、统计分析及深度学习方法。岩石物理模型虽具备较强的物理解释性,但实验数据获取困难,而深度学习方法虽能建模复杂非线性关系,但缺乏物理约束。提出了一种基于概率与岩石物理信息神经网络的测井多参数反演方法。该方法结合了知识驱动的岩石物理正演模型与数据驱动的深度学习神经网络,并通过贝叶斯神经网络对岩石物理超参数进行概率估计,实现了孔隙度、含水饱和度及声波时差的联合预测和不确定性量化。实验结果表明,临界孔隙度及配位数等参数对岩石物理模型的影响机制复杂,且在高声波时差条件下,参数敏感性更高,对预测结果的影响更加突出。与常规深度学习方法相比,该方法通过嵌入岩石物理正演约束,提高了模型在数据质量或数据量受限情况下的鲁棒性,能够实现具有物理规律一致性的多参数预测,并在砂岩储层物性预测中展现出更高的准确性。

**关键词:**测井多参数反演; 贝叶斯神经网络; 深度学习; 岩石物理模型; 不确定性量化

中图分类号: TE132.1

文献标识码: A

## 0 引言

在油气勘探与开发过程中,孔隙度等储层物性参数是储层评价、产能预测及油气储量估算的重要指标。准确的孔隙度预测对于指导储层开发至关重要<sup>[1-2]</sup>。实验室方法包括直接测量(如阿基米德法、气体压差法、高压压汞法)、间接测量(如核磁共振、CT扫描)和辅助分析(如扫描电镜和薄片分析),这些方法能够适用于不同岩石特性,直接且精确地测量岩心孔隙度<sup>[3]</sup>。然而,由于成本高、耗时长且过程复杂,难以在全井段实现大规模应用。因此,孔隙度的广泛预测仍主要依赖测井数据,基于测井数据的孔隙度预测逐渐发展为一种高效且成熟的技术,为储层评价和开发提供了重要支持。

传统孔隙度预测方法通常利用岩石物理模型,通过建立测井数据与储层属性之间的物理关系,推断储层孔隙度等关键物性参数。ARCHIE<sup>[4]</sup>基于电性导电理论,建立了孔隙度与岩石电阻率和水饱和度的关系模型,用于计算砂岩储层的孔隙度和水饱和度。GASSMANN<sup>[5]</sup>基于弹性波传播理论,通过描述饱和岩石的弹性特性,建立了孔隙度与岩石骨架弹性模量和流体性质之间的关系模型。WYLLIE 等<sup>[6]</sup>基于声波传播的时间平均理论,建立了孔隙度与声波时差之间的线性关系模型,用于含水砂岩和碳酸盐岩储层的孔隙度初步估算。XU 等<sup>[7]</sup>基于混合岩石模型理论,建立了泥质含量对纵波速度和横波速度的影响模型,计算了非均质砂岩储层的孔隙度。NUR 等<sup>[8]</sup>提出了临界孔隙度模型,适用于低孔隙度储层,强调了临界孔隙度对岩石弹性模量的影响。DVORKIN 等<sup>[9]</sup>提出的软砂模型,基于颗粒接触理论,建立了孔隙度与纵波和横波速度之间的关系,实现了未胶结或弱胶结的松散砂岩储层的孔隙度计算。在此基础上,研究者进一步改进并应用这些模型。叶端南等<sup>[10]</sup>构建了砂泥岩储层的岩石物理交会模型,更精细地识别了储层的孔隙度和含泥量特

收稿日期: 2025-01-21; 修回日期: 2025-05-02.

基金项目: 国家自然科学基金项目“针对断控缝洞型储层三维地质建模的智能地质统计学方法”(编号: 42302334)资助。

作者简介: 高翊宁(1997-), 女, 新疆库尔勒人, 博士研究生, 主要从事测井和地震数据的智能处理与解释研究. E-mail: Ening9705@hotmail.com.

通信作者: 徐朝晖(1980-), 男, 山东东营人, 博士, 副教授, 主要从事油气地质大数据与人工智能研究. E-mail: xuzhaohui@cup.edu.cn.

征。黄伟传等<sup>[11]</sup>基于 Gassmann 模型，研究了不同流体条件下密度和剪切模量的变化，提出了一种应用于储层预测的岩石物理分析技术。李燕等<sup>[12]</sup>进一步分析了 Gassmann 模型的机理，通过正反演相结合的方法，对横波速度进行了优化估算，提高了复杂储层孔隙度的预测精度。张佳佳等<sup>[13]</sup>通过泰勒级数展开和阻尼最小二乘法，实现了基于岩石物理公式的储层孔隙度等物性参数的精确反演。这些方法在不同储层条件下改进并应用了经典的岩石物理模型，通过声波时差、密度和电阻率等测井曲线预测孔隙度，为预测结果提供了物理约束，使之具备良好的地质合理性和物理解释性。然而，岩石物理模型中所需的参数通常难以直接测量，需要实验支持或主观赋值，从而增加了预测的误差和不确定性。同时，随着岩石类型和储层环境的变化，这些模型的适用性也会受到限制。因此，尽管传统岩石物理方法在地质解释性上具备优势，但其参数获取难度和主观赋值的局限性限制了其在大规模储层预测中的应用。

除了岩石物理公式，研究人员还采用经验关系拟合、统计分析及贝叶斯理论等方法进行孔隙度预测<sup>[14-17]</sup>。尽管这些方法在一定程度上提高了预测准确性，但它们依然存在物理解释性较低或依赖主观经验的局限性。近年来，随着机器学习技术的发展，研究者开始探索通过支持向量机、随机森林及梯度提升决策树等算法建立测井数据与孔隙度等储层物性参数之间的非线性关系<sup>[18-21]</sup>。自 HINTON 等<sup>[22]</sup>提出深度学习概念以来，深度学习的兴起进一步推动了储层物性参数预测的发展。研究者在孔隙度预测中应用了多种深度学习方法，如深度神经网络<sup>[23-24]</sup>，通过非线性映射关系提升了孔隙度的预测准确性；循环神经网络<sup>[25]</sup>，利用其对时间序列特征的捕捉能力，进一步优化了测井数据序列信息的表征效果；卷积神经网络<sup>[26-27]</sup>，通过提取测井数据的空间特征，有效增强了模型的预测准确性。然而，这类纯数据驱动模型在性能上往往依赖于大量高质量的标记样本数据，当数据稀缺或质量较差时模型性能会显著下降。此外，由于缺乏物理约束，这些方法可能导致预测结果缺乏地质合理性。为了提高预测的准确性和地质解释性，近年来的研究者尝试将物理规律引入神经网络模型，通过正演计算为反演过程提供物理约束。VASHISTH 等<sup>[28]</sup>在孔隙度预测中引入岩石物理和波物理信息神经网络，以增强模型在数据有限情况下的地质合理性。LV 等<sup>[29]</sup>结合物理信息神经网络、实验数据和数值模拟，实现了更高的预测精度。DENG 等<sup>[30]</sup>通过在模型中引入测量噪声、先验成分信息和岩石物理约束，提高了基于测井的矿物和流体性质等物性参数的评估结果，并量化了预测不确定性。

本研究针对现有孔隙度预测方法中数据依赖性强且缺乏物理约束的问题，提出了一种结合数据驱动与物理约束的多参数测井反演流程。该方法框架包括：一个用于估算测井数据与储层物性参数关系的深度学习反演模型，一个基于贝叶斯神经网络对岩石物理模型超参数进行重新参数化的模块，以及一个基于岩石物理模型的正演模块。通过对岩石物理模型的超参数进行重新参数化，模型在保持物理意义的同时，能够根据输入数据动态模拟储层特征，并利用贝叶斯推断量化预测不确定性，从而增强模型的可靠性和解释性。通过与传统深度学习方法的对比实验，该方法在数据条件受限时仍保持良好的鲁棒性，并实现了多参数联合预测的物理一致性和有效性。

## 1 原理与方法

### 1.1 基于物理信息的反演过程

地球科学研究中，通过数学模型将测井数据映射到储层物性参数，是研究储层特征的基础方法之一。这一映射关系可表示为：

$$\mathbf{d} = \mathcal{F}(\mathbf{m}) + \mathbf{e} \quad (1)$$

其中， $\mathcal{F}(\cdot)$ 表示从储层物性参数到测井响应的正演过程。观测数据  $\mathbf{d} = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_n]$ ，在本研究中为测井数据， $n$  为测井曲线的数量。模型变量  $\mathbf{m}$ ，表示孔隙度和含水饱和度等储层物性参数。误差项  $\mathbf{e}$  表示测量过程中的噪声或误差。

在本研究中，反演模型的目标是基于观测数据来近似求解出模型变量。反演过程可视为正演过程的逆

过程, 即 $\mathcal{R} \cong \mathcal{F}^{-1}$ 。本研究使用深度学习模型作为反演框架, 以建立观测数据与模型预测之间的映射关系:

$$\hat{\mathbf{m}} = \mathcal{R}(\mathbf{d}; \boldsymbol{\theta}) \quad (2)$$

其中,  $\boldsymbol{\theta}$ 表示深度神经网络的参数集合, 包括权重和偏差。在模型训练过程中, 通过最小化预测值 $\hat{\mathbf{m}}$ 与真实值 $\mathbf{m}$ 之间的均方误差损失函数, 以迭代更新模型参数:

$$\mathbf{L}_m(\boldsymbol{\theta}) = \frac{1}{N} \sum_{i=1}^N \|\mathcal{R}(\mathbf{d}; \boldsymbol{\theta}) - \mathbf{m}\|_2^2 \quad (3)$$

其中,  $N$ 表示用于训练的岩心物性参数样本数。

为了在深度学习反演过程中引入物理约束, 本研究在总损失函数 $\mathbf{L}_t(\boldsymbol{\theta})$ 中加入两类物理约束项:

$$\mathbf{L}_t(\boldsymbol{\theta}) = \alpha_1 \mathbf{L}_m(\boldsymbol{\theta}) + \alpha_2 \mathbf{L}_d + \alpha_3 \mathbf{KL} \quad (4)$$

其中,  $\alpha_i (i = 1, \dots, 3)$ 表示权重因子, 用以控制各项损失的相对贡献比例。正演模拟的约束项 $\mathbf{L}_d$ , 表示通过正演过程生成的测井数据与观测测井数据之间的差异。此外, 为了在反演过程中同步估计岩石物理正演模型中的超参数(如临界孔隙度、配位数), 本研究不人为设定固定超参数值, 而是通过贝叶斯神经网络对其进行重新参数化。为了确保超参数估计的合理性, 贝叶斯神经网络的变分分布与后验分布之间的Kullback-Leibler 散度同样作为约束项 $\mathbf{KL}$ 加入总损失函数中, 以量化岩石物理超参数估计的不确定性。在训练过程中, 通过不断迭代优化模型参数 $\boldsymbol{\theta}$ 和超参数的变分分布, 使总损失函数最小化, 从而实现具有物理一致性的反演模型。

## 1.2 岩石物理约束的正演模拟过程

在本研究中, 深度学习反演模型用于预测孔隙度 $\hat{\phi}$ 和含水饱和度 $\hat{S}_w$ 。这些预测结果被作为正演模拟的输入, 以通过岩石物理模型生成理论声波时差测井曲线。本节将详细描述正演模拟的各步骤及其所需要的岩石物理模型。

### (1) 基质参数计算

本研究采用了Dvorkin 和 Nur 提出的经典岩石物理模型<sup>[31]</sup>, 在此模型中, 基质模量的计算基于矿物组分的等效模型, 通过Voigt-Reuss-Hill平均公式计算得到基质体积模量 $K_{mat}$ 、剪切模量 $G_{mat}$ 和密度 $\rho_{mat}$ :

$$K_{mat} = \frac{1}{2} \left( \sum_{i=1}^n K_{minc,i} \cdot V_{minc,i} + \left( \sum_{i=1}^n \frac{V_{minc,i}}{K_{minc,i}} \right)^{-1} \right) \quad (5)$$

$$G_{mat} = \frac{1}{2} \left( \sum_{i=1}^n G_{minc,i} \cdot V_{minc,i} + \left( \sum_{i=1}^n \frac{V_{minc,i}}{G_{minc,i}} \right)^{-1} \right) \quad (6)$$

$$\rho_{mat} = \sum_{i=1}^n \rho_{minc,i} \cdot V_{minc,i} \quad (7)$$

其中,  $K_{minc,i}$ 和 $G_{minc,i}$ 分别表示第*i*种矿物的体积模量和剪切模量, 单位为GPa;  $\rho_{minc,i}$ 为第*i*种矿物的密度, 单位为g/cm<sup>3</sup>;  $V_{minc,i}$ 为其体积分数, 通过贝叶斯抽样方法从高斯分布中随机采样得到。表1列出了矿物的弹性参数值和体积分数采样范围。

表1 矿物的弹性参数

Table 1 Elastic parameters of minerals

弹性参数	石英	长石	黏土	云母
体积模量/GPa	37	75	21	52
剪切模量/GPa	44	27	9	18
密度/(g/cm <sup>3</sup> )	2.65	2.56	2.50	2.7
体积分数/%	(40,50)	(15,20)	(10,15)	(5,10)

### (2) 流体参数与总密度计算

利用混合流体体积模量公式，计算油水混合流体的体积模量 $K_f$ 和密度 $\rho_f$ ：

$$\frac{1}{K_f} = \frac{\hat{S}_w}{K_{water}} + \frac{1-\hat{S}_w}{K_{oil}} \quad (8)$$

$$\rho_f = \hat{S}_w \cdot \rho_{water} + (1 - \hat{S}_w) \cdot \rho_{oil} \quad (9)$$

总密度 $\rho_{bulk}$ 表达为：

$$\rho_{mat} = \sum_{i=1}^n \rho_{minc,i} \cdot V_{minc,i} \quad (10)$$

其中， $K_{water}$ 和 $K_{oil}$ 分别表示水和油的体积模量，单位为GPa； $\rho_{water}$ 和 $\rho_{oil}$ 分别水和油的密度，单位为g/cm<sup>3</sup>。表2为流体的弹性参数值。

表2 流体的弹性参数

Table 2 Elastic parameters of fluids

弹性参数	水	油
体积模量/GPa	3.06	1.20
密度/(g/cm <sup>3</sup> )	1.03	0.85

### (3) 颗粒接触模量计算

通过 Hertz-Mindlin 方程<sup>[32]</sup>计算颗粒接触体积模量 $K_{HM}$ 和剪切模量 $G_{HM}$ ：

$$K_{HM} = \sqrt[3]{\frac{P_e [Z(1-\phi_0) \cdot G_{mat}]^2}{18[\pi(1-v)]^2}} \quad (11)$$

$$G_{HM} = \frac{5-4v}{5(2-v)} \sqrt[3]{\frac{3P_e [Z(1-\phi_0) \cdot G_{mat}]^2}{2[\pi(1-v)]^2}} \quad (12)$$

泊松比 $v$ 由下式计算：

$$v = \frac{3K_{mat}-2G_{mat}}{6K_{mat}+2G_{mat}} \quad (13)$$

其中， $P_e$ 表示有效压力， $Z$ 为配位数， $\phi_0$ 为临界孔隙度。

### (4) 干岩石模量计算

采用修正的 Hashin-Shtrikman 下界公式<sup>[33]</sup>计算干岩石的体积模量 $K_{dry}$ 和剪切模量 $G_{dry}$ ：

$$K_{dry} = \left( \frac{3\gamma}{3K_{HM}+4G_{HM}} + \frac{3(1-\gamma)}{K_{mat}} \right)^{-1} - \frac{4}{3} G_{HM} \quad (14)$$

$$G_{dry} = \left( \frac{6\gamma}{6G_{HM}+\psi \cdot G_{HM}} + \frac{6(1-\gamma)}{6G_{mat}+\psi \cdot G_{HM}} \right)^{-1} - \frac{1}{6} \psi \cdot G_{HM} \quad (15)$$

其中，

$$\gamma = \frac{\hat{\phi}}{\phi_0} \quad (16)$$

$$\psi = \frac{9K_{HM}-8G_{HM}}{K_{HM}+2G_{HM}} \quad (17)$$

### (5) 饱和岩石模量与声波速度计算

通过 Gassmann 方程<sup>[5]</sup>计算饱和岩石的体积模量 $K_{sat}$ 和剪切模量 $G_{sat}$ ，以及纵波速度 $V_p$ ：

$$K_{sat} = K_{dry} + \frac{\left( \frac{1-K_{dry}}{K_{mat}} \right)^2}{\frac{\hat{\phi}}{K_f} + \frac{1-\hat{\phi}}{K_{mat}} + \frac{K_{dry}}{K_{mat}^2}} \quad (18)$$

$$G_{sat} = G_{dry} \quad (19)$$

$$V_p = \sqrt{\frac{3K_{sat}+4G_{sat}}{3\rho_{bulk}}} \quad (20)$$

### (6) 声波时差计算

最后得到正演模拟的理论声波时差测井响应:

$$\hat{d} = \frac{1000}{3.28084V_p} \quad (21)$$

正演模拟结果被用作约束项，以增强反演模型的训练效果。其损失函数可表示为:

$$\begin{aligned} L_d(\boldsymbol{\theta}) &= \frac{1}{N} \sum_{i=1}^N \left\| \mathcal{F}(\mathcal{R}(\mathbf{d}; \boldsymbol{\theta})) - \mathbf{d} \right\|_2^2 \\ &= \frac{1}{N} \sum_{i=1}^N \left\| \hat{\mathbf{d}} - \mathbf{d} \right\|_2^2 \end{aligned} \quad (22)$$

这种结构使得正演模拟中的岩石物理模型直接参与反演模型的训练，从而通过正演过程的物理约束提升预测的可解释性与可靠性。此外，岩石物理模型中的超参数由贝叶斯神经网络进行重新参数化。

## 1.3 岩石物理超参数估计

在正演模拟过程中，临界孔隙度和配位数等岩石物理超参数对模拟结果的准确性至关重要。然而，这些参数通常无法通过直接测量获得，而是依据岩心测试或经验研究来定义，其取值存在较大不确定性。为了更稳健地估计这些超参数，本研究采用贝叶斯神经网络（Bayesian Neural Network, BNN）对这些超参数进行估计，并与正演模拟和反演预测过程同步优化。

### (1) 贝叶斯神经网络框架

岩石物理超参数的估计由贝叶斯神经网络实现，其形式可表示为:

$$\hat{\mathbf{m}}_p = \mathcal{T}(\mathbf{d}; \boldsymbol{\theta}_p) \quad (23)$$

其中， $\mathcal{T}(\cdot)$ 表示贝叶斯神经网络从测井数据到岩石物理超参数的映射函数， $\boldsymbol{\theta}_p$ 为网络的可训练参数，包括权重和偏差项，用于控制贝叶斯神经网络的映射能力。进而正演模拟的约束项损失函数可进一步写作:

$$L_d(\boldsymbol{\theta}, \boldsymbol{\theta}_p) = \frac{1}{N} \sum_{i=1}^N \left\| \mathcal{F}(\mathcal{R}(\mathbf{d}; \boldsymbol{\theta}), \mathcal{T}(\mathbf{d}; \boldsymbol{\theta}_p)) - \mathbf{d} \right\|_2^2 \quad (24)$$

### (2) 变分推断与后验分布近似

贝叶斯神经网络的目标是通过优化超参数的后验分布 $p(\boldsymbol{\theta}_p | \mathbf{d})$ ，逼近模型参数的最优分布。由于直接求解后验分布通常不可行，本研究采用变分推断方法，用变分分布 $q_\lambda(\boldsymbol{\theta}_p)$ 近似后验分布。假设变分分布为高斯分布:

$$q_\lambda(\boldsymbol{\theta}_p) = \mathcal{N}(\boldsymbol{\theta}_p | \boldsymbol{\mu}, \boldsymbol{\sigma}^2) \quad (25)$$

其中， $\boldsymbol{\mu}$ 和 $\boldsymbol{\sigma}^2$ 是变分分布的参数。通过优化这些参数，动态调整神经网络的权重和偏差，从而获得更合理的岩石物理超参数估计。

### (3) KL散度与优化目标

为了评估变分分布 $q_\lambda(\boldsymbol{\theta}_p)$ 与后验分布 $p(\boldsymbol{\theta}_p | \mathbf{d})$ 的接近程度，引入KL散度:

$$KL[q_\lambda(\boldsymbol{\theta}_p) \| p(\boldsymbol{\theta}_p | \mathbf{d})] = \int q_\lambda(\boldsymbol{\theta}_p) \log \frac{q_\lambda(\boldsymbol{\theta}_p)}{p(\boldsymbol{\theta}_p | \mathbf{d})} d\boldsymbol{\theta}_p \quad (26)$$

由于后验分布通常不可直接计算，KL散度可表示为:

$$KL = \mathbb{E}_{q_\lambda(\boldsymbol{\theta}_p)} [\log q_\lambda(\boldsymbol{\theta}_p) - \log p(\mathbf{d} | \boldsymbol{\theta}_p) - \log p(\boldsymbol{\theta}_p)] \quad (27)$$

其中， $p(\mathbf{d} | \boldsymbol{\theta}_p)$ 为似然函数，表示给定网络参数 $\boldsymbol{\theta}_p$ 下，测井数据 $\mathbf{d}$ 的可能性。 $p(\boldsymbol{\theta}_p)$ 为超参数的先验分布。因此优化目标等价于最大化变分下界:

$$\lambda^* = \operatorname{argmax}_{\lambda} \mathbb{E}_{q_{\lambda}(\theta_p)} [\log p(\mathbf{d}|\theta_p)] - KL[q_{\lambda}(\theta_p) \| p(\theta_p|\mathbf{d})] \quad (28)$$

贝叶斯神经网络通过优化变分参数  $\lambda = (\mu, \sigma^2)$ , 逐步更新变分分布  $q_{\lambda}(\theta_p)$ , 使其逼近后验分布  $p(\theta_p|\mathbf{d})$ , 以获得合理的超参数估计。

#### (4) $KL$ 散度的模型集成

在反演模型的训练过程中,  $KL$  散度作为约束项  $KL(\theta_p, \lambda)$  添加到总损失函数中, 用于约束岩石物理超参数的学习过程。通过优化  $KL$  散度, 贝叶斯神经网络的参数  $\theta_p$  被动态调整, 以生成岩石物理超参数估计  $\hat{\mathbf{m}}_p$ , 确保反演结果符合岩石物理约束。

### 1.4 模型总体架构

为了实现结合概率超参数估计与岩石物理约束的测井多参数反演方法, 本研究提出了一个综合性的模型框架, 如图 1 所示。该框架包括反演模块和正演模块, 并通过协同优化的损失函数实现数据驱动与物理一致性的结合。

反演模块由反演模型与重新参数化模型两部分组成。反演模型采用三层双向门控循环单元与注意力机制<sup>[34-35]</sup>相结合的网络结构, 能够捕捉测井数据的时序特征和局部关联性, 并预测储层物性参数(如孔隙度和含水饱和度)。重新参数化模型采用贝叶斯神经网络, 对岩石物理超参数(如临界孔隙度和配位数)进行概率估计。

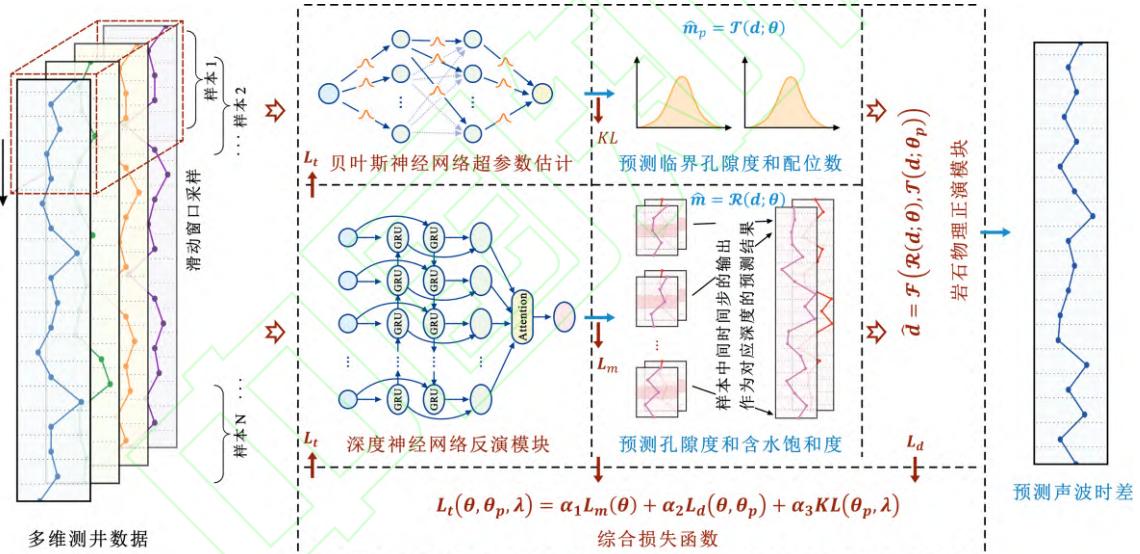


图 1 结合概率超参数估计与岩石物理约束的测井多参数反演工作流程

**Fig.1 Well log multi-parameter inversion workflow combining Bayesian estimation of rock physics hyperparameters and rock physics constraints**

正演模块通过引入经典岩石物理模型, 将反演模块输出的储层物性参数与岩石物理超参数映射为理论测井响应(如声波时差)。生成的理论测井数据与实际观测数据之间的误差被嵌入损失函数, 作为物理一致性约束, 以引导模型训练, 使其符合岩石物理规律。

在反演模块与正演模块协同优化的过程中, 综合损失函数(公式 4)有助于平衡数据驱动与物理约束, 其完整表达形式如下:

$$L_t(\theta, \theta_p, \lambda) = \alpha_1 L_m(\theta) + \alpha_2 L_d(\theta, \theta_p) + \alpha_3 KL(\theta_p, \lambda) \quad (29)$$

其中,  $L_m(\theta)$  表示预测储层物性参数与实测值之间的误差, 用于优化反演模型参数;  $L_d(\theta, \theta_p)$  表示理论测

井响应与观测测井数据之间的误差，用于优化正演模块中的物理约束； $KL(\theta_p, \lambda)$ 表示贝叶斯神经网络的变分分布与后验分布之间的KL散度，用于量化岩石物理超参数估计的不确定性。因此，通过构建数据驱动与物理约束相结合的整体架构，实现正反演联合模型，有助于提升预测结果的准确性与地质可靠性。

## 2 应用实例

### 2.1 数据准备与模型配置

#### (1) 数据来源与预处理

为验证方法的适用性，本研究将其应用于吐哈盆地南部鲁克沁油田某砂岩工区三叠系克拉玛依组二段。研究区位于吐哈盆地南缘，属三角洲沉积体系，储层主要为细粒砂岩和砂砾岩，孔隙度的主值分布范围为13%~33%，孔隙类型以剩余粒间孔和原生粒间孔为主，储层表现出较好的储集性与渗流性。然而如图2所示，井间孔隙度分布存在差异，且岩性对孔隙度的控制作用较弱，因此传统经验拟合方法即使分岩性处理也难以兼顾井间差异，泛化能力受限。

实验数据包括三口取心井的自然电位、自然伽马、电阻率、声波时差、密度和中子等六条常规测井曲线，以及压汞实验获得的部分深度孔隙度数据。图3展示了孔隙度与测井数据的相关性分布，其中声波时差与孔隙度的相关性相对较高，表明声波时差对孔隙度具有较强的敏感性，从而为正演模块中基于岩石物理模型的理论声波时差模拟提供了理论依据。

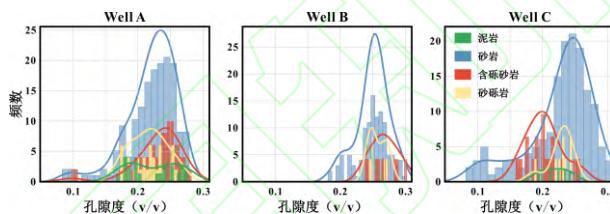


图2 岩性约束下的孔隙度分布直方图

Fig.2 Porosity distribution under different lithology

反演模型以经过标准化处理的6条测井曲线作为输入，以压汞实验测试得到的孔隙度数据作为标签。为充分利用测井数据的时序信息，采用滑动窗口采样方法生成样本，具体为：测井曲线采样间隔为0.125m，窗口长度设置为5个深度点，步长为1个深度点，每个样本的标签取自滑动窗口中心深度点的孔隙度数据。

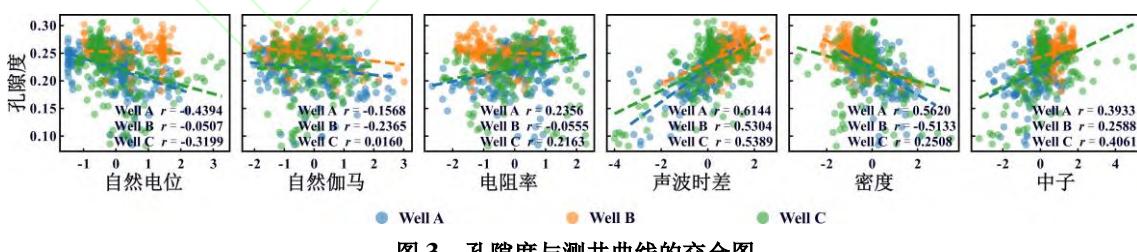


图3 孔隙度与测井曲线的交会图

Fig.3 Crossplot of porosity and well logs

#### (2) 模型的参数配置与优化

在模型训练之前，采用网格搜索法对反演模型中双向门控循环神经网络层数、学习率、L2正则化系数及随机失活概率等关键参数进行调优。通过在验证集上计算平均绝对误差作为评估指标，以确定最优参数组合。具体搜索范围和最优参数如表3所示。

表 3 超参数网格搜索范围与最优参数值

Table 3 Hyperparameter grid search ranges and optimal values

超参数	网格搜索范围	最优参数值
学习率	[0.0005, 0.001, 0.002, 0.005, 0.01]	0.002
L2 正则化	[0, $10^{-6}$ , $10^{-5}$ , $10^{-4}$ , $10^{-3}$ , $10^{-2}$ ]	$10^{-3}$
随机失活概率	[0.1, 0.2, 0.3, 0.4]	0.1

表 4 留一井交叉验证数据集划分方案

Table 4 Dataset partition strategy for leave-one-well-out cross-validation

交叉验证轮次	训练集		验证集		测试集	
	井	样本数 (70%)	井	样本数 (30%)	盲测井	样本数
第一轮	井 B、井 C	961	井 B、井 C	413	井 A	541
第二轮	井 A、井 C	867	井 A、井 C	372	井 B	676
第三轮	井 A、井 B	851	井 A、井 B	366	井 C	698

为评估模型在未知井上的预测性能,研究采用“留一井交叉验证”方法对模型进行训练与测试。每次选取两口井的数据,随机划分70%为训练集、30%为验证集,剩余一口井的数据作为独立盲测井构成测试集(表4)。通过三次交叉验证,能够全面评估模型在未见数据上的泛化能力,同时避免模型因过拟合而失去预测可靠性。

## 2.2 数据量与数据质量敏感性分析

为评估正反演联合模型与纯数据驱动的神经网络反演模型在数据量不足或数据质量下降情况下的预测性能,本研究在全量训练数据的基础上,通过添加20%的噪声以及随机抽取30%和50%的训练数据,构建对比实验,并利用三轮盲测进行验证。图4展示了在不同数据条件下,相对于全量数据的相关系数下降率和平均绝对误差上升率。结果表明,在加入噪声和训练数据量减少至50%的条件下,正反演联合模型的性能变化较小。在数据量减少至30%时,两种模型均出现明显的性能退化,但正反演联合模型仍略优于神经网络反演模型。

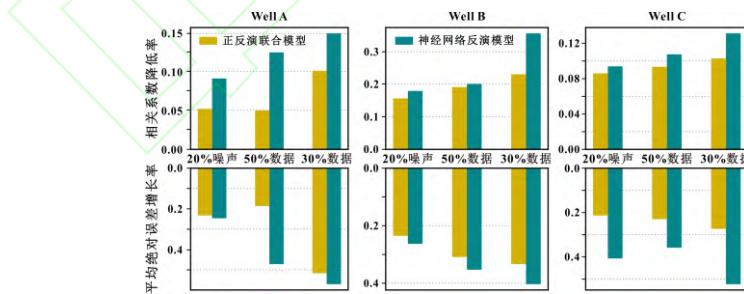


图 4 数据量与数据质量对模型性能的影响分析

Fig.4 Impact of data availability on model performance

图5展示了盲测井A全井段的孔隙度预测结果。500次独立预测的平均曲线表明,正反演联合模型在数据量或数据质量受限时,整体趋势保持一致,显示出较高的鲁棒性。尽管在局部细节上存在差异,例如在2795~2805m井段预测曲线趋于平直,以及在2825~2835m井段,当数据量减少至30%时局部细节捕捉能力下降,但整体而言,该模型能较好反映孔隙度的变化。相比之下,神经网络反演模型在相同条件下表现出明显的不稳定性,其预测曲线在不同数据条件下的差异较大,且在数据量减少至30%时呈现“粗化”

趋势，局部变化刻画不足。

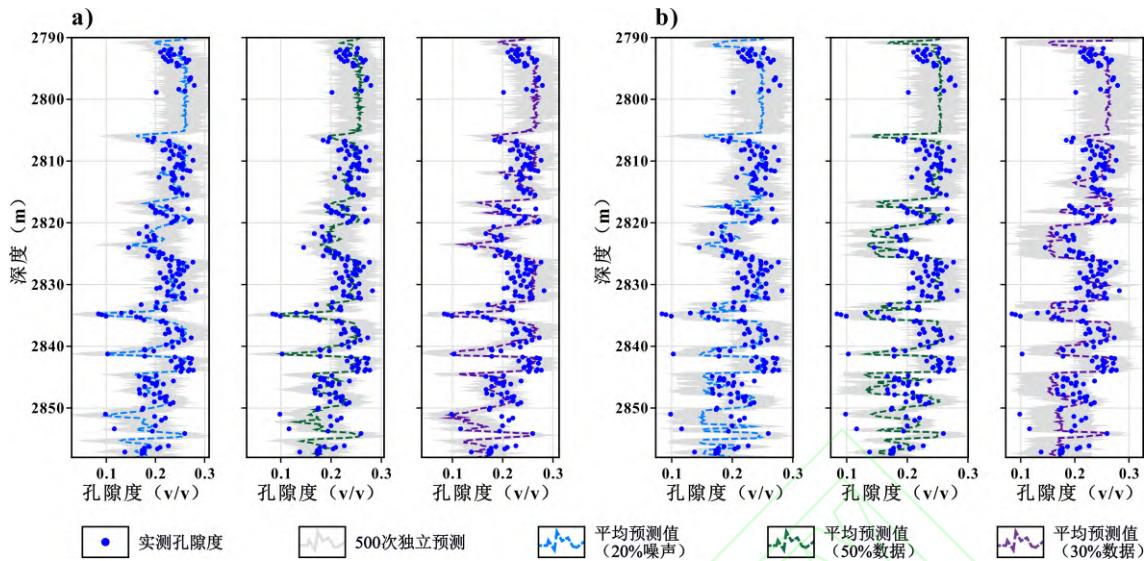


图 5 不同数据条件下井 A 的孔隙度预测结果对比

Fig.5 Comparison of porosity predictions of Well A under different data conditions

(a) 基于概率与岩石物理信息神经网络模型预测的孔隙度; (b) 神经网络反演模型预测的孔隙度

因此，正反演联合模型通过嵌入岩石物理约束，能够在数据条件受限时保持较高的稳定性。而纯数据驱动模型对数据条件变化更为敏感。该分析验证了岩石物理正演约束对提升模型鲁棒性的重要作用。

### 2.3 岩石物理参数敏感性分析

为分析岩石物理正演模型中临界孔隙度、配位数和含水饱和度等参数对声波时差与孔隙度关系的影响，进一步绘制了声波时差与孔隙度的岩石物理量版。

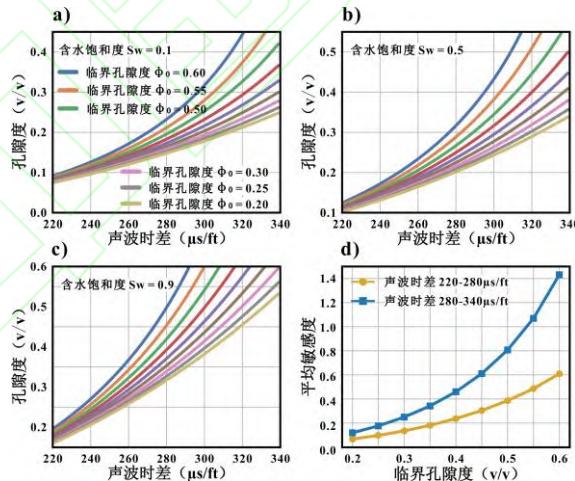


图 6 临界孔隙度的敏感性分析

Fig.6 Sensitivity analysis of critical porosity

(a) 含水饱和度设置为 0.1; (b) 含水饱和度设置为 0.5; (c) 含水饱和度设置为 0.9; (d) 临界孔隙度对声波时差敏感度的变化趋势

图 6 展示了不同含水饱和度条件下，临界孔隙度对孔隙度随声波时差变化的影响。结果表明，含水饱和度越高，孔隙度越大。临界孔隙度与孔隙度呈正相关，且临界孔隙度越高，孔隙度变化幅度越大。图 7 展示了配位数的影响。结果表明，配位数与孔隙度呈负相关，且配位数越高，孔隙度变化幅度越大。

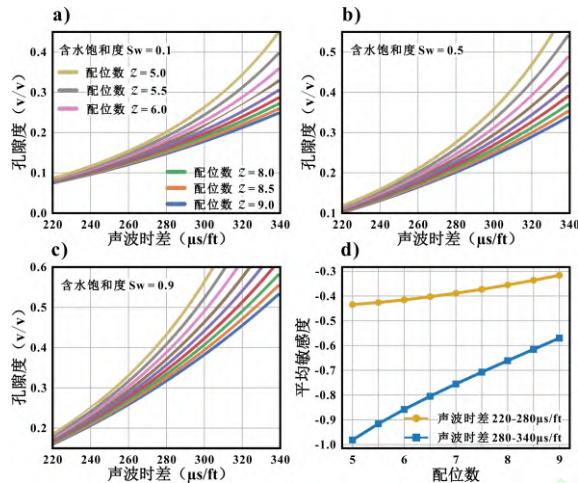


图 7 配位数的敏感性分析

Fig.7 Sensitivity analysis of coordination number

(a) 含水饱和度设置为 0.1; (b) 含水饱和度设置为 0.5; (c) 含水饱和度设置为 0.9; (d) 配位数对声波时差敏感度的变化趋势

图 6 (d) 和图 7 (d) 进一步展示了临界孔隙度和配位数的平均敏感度随声波时差变化的趋势。正敏感度表示临界孔隙度与孔隙度呈正相关，而负敏感度则表明配位数与孔隙度呈负相关。高声波时差条件下，无论是临界孔隙度还是配位数，敏感度均明显增加，表明在这一条件下，这些参数对孔隙度的影响更加显著。这些结果表明临界孔隙度、配位数和含水饱和度对岩石物理模型的影响机制较为复杂，且在高声波时差条件下，表现出更强的敏感性。该分析验证了岩石物理模型的合理性，并为正反演联合模型中的物理约束提供了理论支持。

## 2.4 反演结果与分析

### 2.4.1 储层物性参数预测与评估

为了评估本研究提出的基于概率与岩石物理信息神经网络的测井多参数反演方法在物性参数预测中的性能，比较了 3 种不同的模型：基于概率与岩石物理信息神经网络的正反演联合模型、仅使用反演模块的神经网络反演模型，以及仅使用岩石物理正演模块的岩石物理模型。正反演联合模型既利用了神经网络在捕捉测井数据时序信息和非线性映射方面的优势，又结合了岩石物理正演模块对物理规律进行约束，实现了孔隙度、含水饱和度和声波时差等多参数联合预测。相较而言，神经网络反演模型仅依赖于数据驱动的反演模块，因缺少含水饱和度的实验数据作为标签，无法对全井段含水饱和度进行预测。此外，因缺少岩石物理正演过程，无法提供与预测孔隙度具有物理一致性的理论声波时差。另一方面，纯岩石物理模型则基于正演模块逐点计算孔隙度，虽然能够反映在不同含水饱和度条件下的孔隙度趋势，但忽略了测井数据的时序特征，且由于缺乏含水饱和度数据，难以在每个深度点提供精确的孔隙度预测，从而限制了其在复杂储层条件下的应用。

图 8 至图 10 展示了三种方法在三轮盲测中的全井段预测结果，其中灰色曲线表示模型在 500 次独立预测中的输出，用于评估预测的不确定性，而红色虚线则表示 500 次预测的平均值。对比各轮盲测结果可见，正反演联合模型 (a) 图的灰色区域在图 8、图 9 和图 10 中均明显窄于对应的神经网络反演模型 (b) 图，表明正反演联合模型在捕捉孔隙度变化时波动性较小，稳定性更高。

针对各轮盲测结果，在第一轮盲测 (图 8) 中，盲测井 A 在 2795~2805m 井段，神经网络反演模型显示出较大波动，灰色区域较宽且孔隙度曲线平直，未能充分捕捉局部孔隙度的变化；而正反演联合模型在保持神经网络非线性映射能力的基础上，通过引入岩石物理公式所体现的趋势，实现了更为准确的局部拟合，并明显降低了预测不确定性。第二轮盲测 (图 9) 中，盲测井 B 在 2920~2936m 井段，神经网络反演模型呈现跳跃且不稳定的预测结果，而正反演联合模型则保持了较窄、稳定的灰色区域，显示出较高的鲁

棒性。第三轮盲测(图10)中,盲测井C在2830~2845m井段,神经网络反演模型预测出三处孔隙度低值,而这些低值与声波时差的变化趋势不符;相比之下,正反演联合模型则通过物理约束有效矫正了偏差,使得预测结果更贴近实际物理规律。

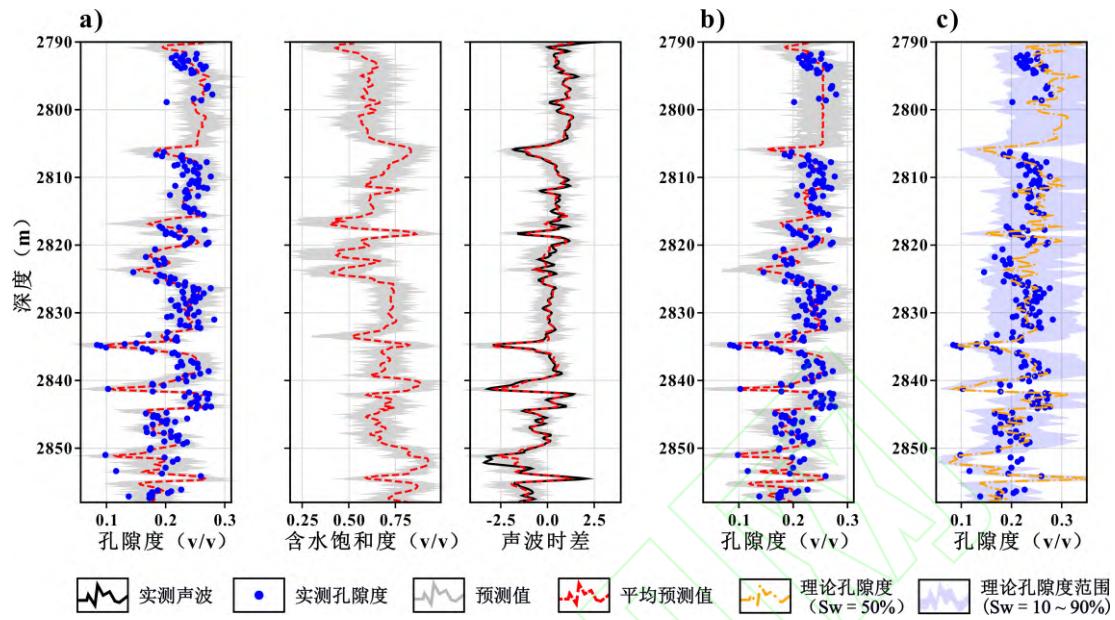


图8 井A预测结果对比

Fig.8 Comparison of prediction results for Well A

(a) 基于概率与岩石物理信息神经网络模型预测的孔隙度、含水饱和度和声波时差; (b) 神经网络反演模型预测的孔隙度;

(c) 岩石物理模型在不同含水饱和度条件下的理论孔隙度

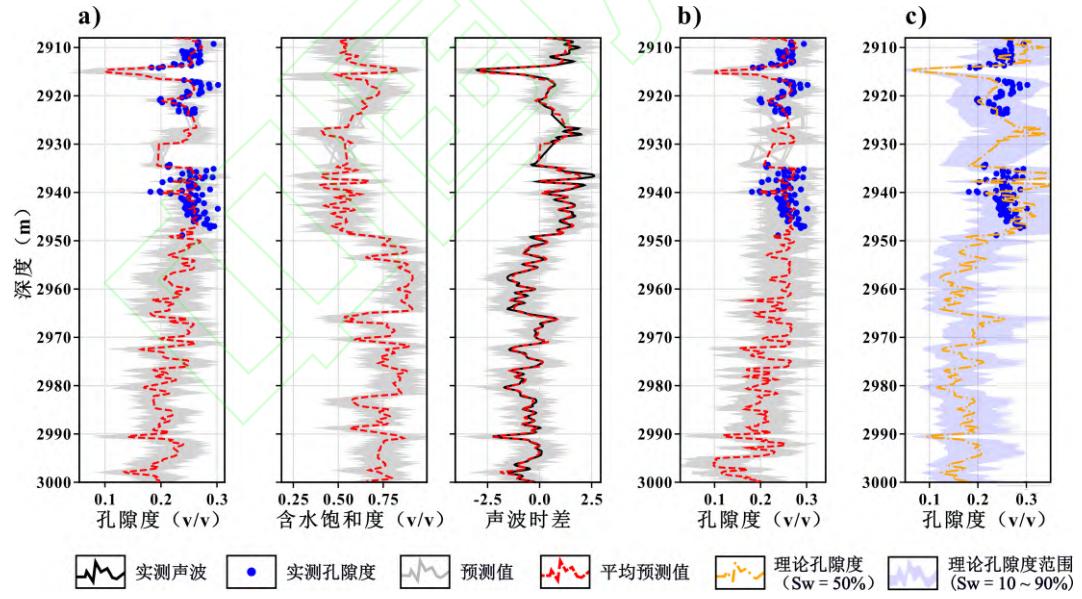


图9 井B预测结果对比

Fig.9 Comparison of prediction results for Well B

(a) 基于概率与岩石物理信息神经网络模型预测的孔隙度、含水饱和度和声波时差; (b) 神经网络反演模型预测的孔隙度;

(c) 岩石物理模型在不同含水饱和度条件下的理论孔隙度

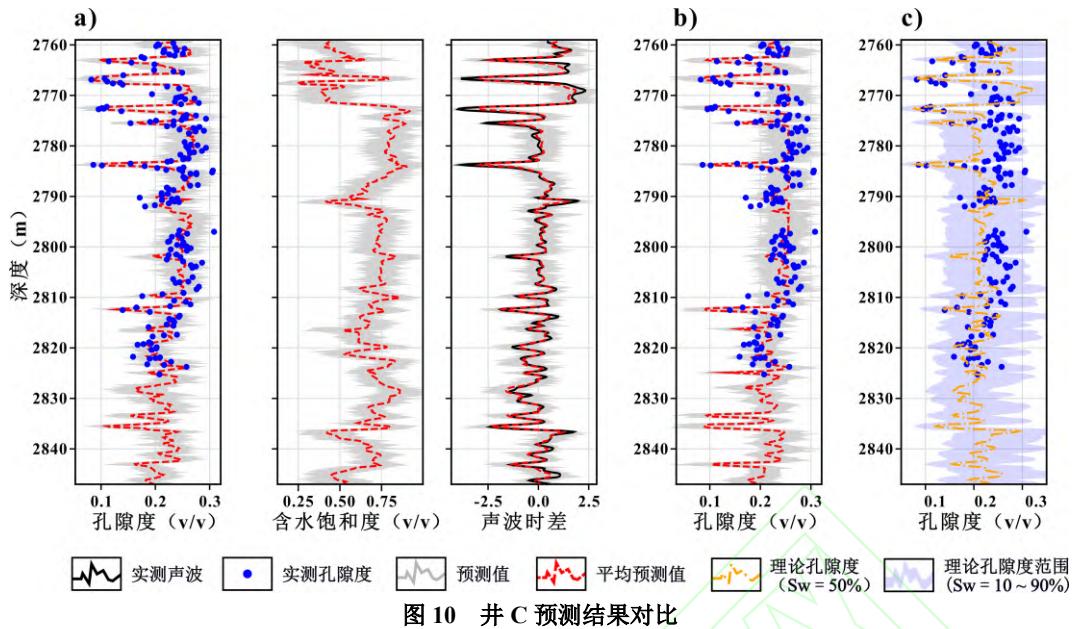


图 10 井 C 预测结果对比

Fig.10 Comparison of prediction results for Well C

(a) 基于概率与岩石物理信息神经网络模型预测的孔隙度、含水饱和度和声波时差; (b) 神经网络反演模型预测的孔隙度;  
(c) 岩石物理模型在不同含水饱和度条件下的理论孔隙度

此外，在含水饱和度预测方面，图 8 至图 10 (a) 中的红色虚线所示的含水饱和度平均预测值与孔隙度和声波时差呈现出相似的变化趋势，但并不重合，反映出含水饱和度的变化不仅受到孔隙度影响，还受到其他因素调控。正反演联合模型能够合理地反映这一复杂的物理关系。在理论声波时差的重构上，图 8 至图 10 (a) 中的理论声波时差与实测值显示出高度一致性，进一步验证了正反演联合模型在捕捉测井数据多维特征及遵循岩石物理规律方面的有效性。

同时，图 8 至图 10 (c) 中的蓝色阴影区域代表在不同含水饱和度 (10%~90%) 条件下，根据岩石物理公式计算得到的理论孔隙度范围，该范围能够较好地覆盖实测孔隙度数据，说明在合理岩石物理超参数设定下，纯岩石物理公式能够为该地区提供较可靠的孔隙度预测。但蓝色阴影区域反映的是预测区间，而黄色虚线对应 50% 含水饱和度条件下的孔隙度变化趋势，仅可作为趋势参考，难以每个深度点提供准确的孔隙度预测值。这表明，当缺乏合理的含水饱和度和岩石物理超参数等实验数据时，仅依赖岩石物理公的方法在实际应用中仍存在一定局限性。

图 11 至图 13 进一步展示了三轮盲测中，实测声波时差与预测声波时差、实测孔隙度与预测孔隙度的对比。结果表明，正反演联合模型在预测中表现出较高的准确性，其实测声波时差与预测声波时差之间具有较高的相关系数 (Correlation Coefficient,  $r$ ) 和决定系数 (Coefficient of Determination,  $R^2$ )。孔隙度预测存在局部偏差，但整体预测与实测数据的差异较小，并且 95% 置信度区间较窄，表明模型预测的不确定性较低。

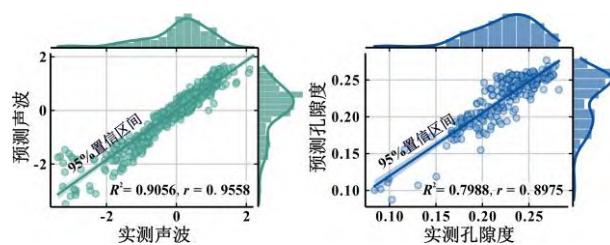


图 11 井 A 声波时差和孔隙度实测与预测的交会图

Fig.11 Crossplot of predictions and observations for Well A

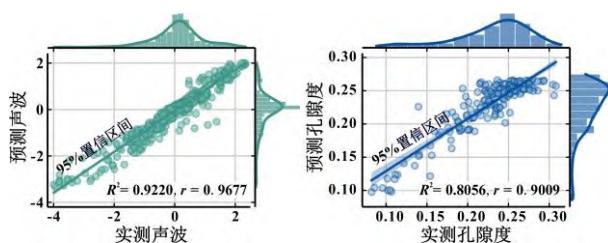


图 12 井 B 声波时差和孔隙度实测与预测的交会图

Fig.12 Crossplot of predictions and observations for Well B

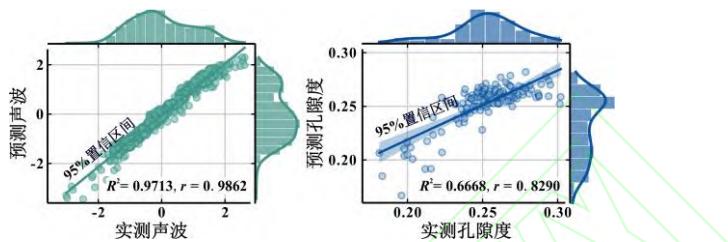


图 13 井 C 声波时差和孔隙度实测与预测的交会图

Fig.13 Crossplot of predictions and observations for Well C

表 5 汇总了三轮盲测中，正反演联合模型与神经网络反演模型在孔隙度预测中的评估指标，包括相关系数（ $r$ ）、决定系数（ $R^2$ ）和平均绝对误差（MAE）。相关系数衡量预测值与实测值的线性相关性，决定系数反映模型对数据变异的解释能力，而平均绝对误差表示预测值与实测值之间的平均偏差。结果表明，正反演联合模型在各项指标上均优于神经网络反演模型，在三轮盲测中展现出较高的相关性和拟合度。虽然两者在数值误差上的差异并不显著，但前者在降低预测不确定性、捕捉局部细节以及确保物理一致性方面具有明显优势。

表 5 孔隙度预测结果的模型评估指标

Table 5 Model performance metrics for porosity prediction on testing wells

盲测井	模型	$r$	$R^2$	MAE
井 A	正反演联合模型	0.8975	0.7988	0.0129
	神经网络反演模型	0.8800	0.7698	0.0142
井 B	正反演联合模型	0.8290	0.6668	0.0114
	神经网络反演模型	0.7824	0.6097	0.0119
井 C	正反演联合模型	0.9009	0.8056	0.0153
	神经网络反演模型	0.8605	0.7364	0.0183

在计算效率方面，本研究在配备 i9-11900H 处理器和 NVIDIA RTX3080 显卡的移动工作站上开展实验。神经网络反演模型在单个训练轮次中，每个样本的平均训练时间约为 1.2804 毫秒，而正反演联合模型每个样本的平均训练时间约为 2.8195 毫秒。训练完成后，对贝叶斯神经网络执行 1 次采样的耗时约为 0.1647 秒。

因此，正反演联合模型在发挥神经网络对非线性映射与时序信息捕捉优势的同时，通过引入岩石物理正演模块对预测结果进行物理约束，实现了多参数联合预测。然而贝叶斯神经网络中变分推断过程明显增加了模型的运行成本。

#### 2.4.2 岩石物理参数预测与评估

图 14 和图 15 展示了贝叶斯神经网络对岩石物理参数的预测结果在 500 次采样中的分布情况。图 14 中每个色块的颜色深浅反映了相应参数估计值的频率，红色五角星标记表示平均值。通过这些分布图，可以体现不同井中临界孔隙度和配位数的分布特征及其集中性，从而推断相关地质特征。图中显示，模型在三口井的预测结果存在一定程度的集中性，深色块的分布较为集中，表明贝叶斯神经网络能够有效捕捉超参数的实际变化。而不同井之间的预测结果存在一定差异，表明参数的估计受地质背景的影响，反映了井间地质特征的差异。

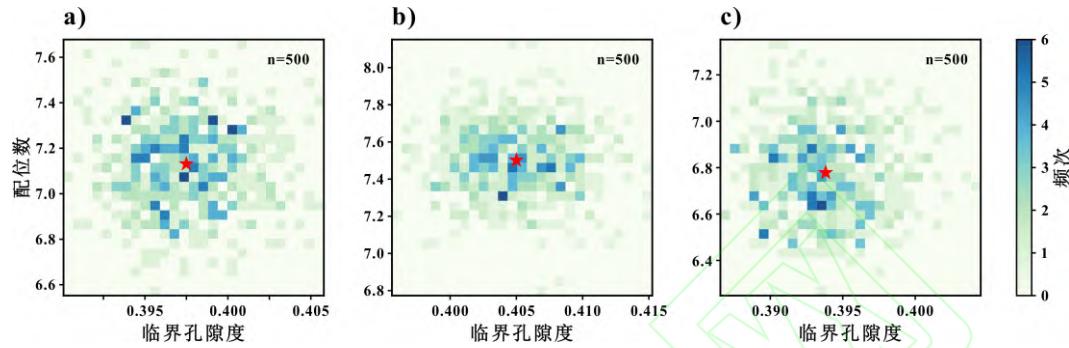


图 14 贝叶斯神经网络预测的临界孔隙度和配位数的概率分布

Fig.14 Probability distribution of critical porosity and coordination number

(a) 井 A 的 500 次采样结果分布；(b) 井 B 的 500 次采样结果分布；(c) 井 C 的 500 次采样结果分布

图 15 进一步展示了贝叶斯神经网络预测的临界孔隙度和配位数在井间的差异。图 15 (a) 显示，井 A 和井 C 的临界孔隙度预测结果分布相对集中，表明这两口井所在区域的孔隙结构相对均一，沉积环境较为稳定。从测井曲线特征来看，井 A 和井 C 的声波时差、密度和中子曲线分布相似，且声波时差波动较小（图 8, 图 10），进一步说明两者具有相似的地质特征和较为稳定的孔隙结构。相比之下，井 B 的临界孔隙度预测值分布范围较宽且数值偏高，反映井 B 所在区域孔隙发育较好、孔隙空间较大，但孔隙结构更为复杂，说明井 B 可能位于沉积环境更复杂的区域。井 B 测井曲线的分布与井 A 和井 C 存在差异，声波时差的波动相对较大（图 9），同样说明井 B 具有较复杂的沉积特征。图 15 (b) 展示了配位数的预测结果，井 B 的配位数较高，表明其孔隙结构较为致密，孔隙之间的连接性较强。而井 A 和井 C 的配位数相对较低，表明这两口井所在的区域孔隙之间的连接性较差，可能与较松散或不均匀的沉积环境相关。

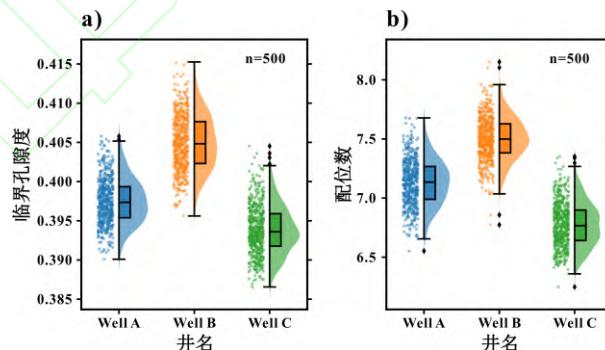


图 15 临界孔隙度和配位数的井间分布

Fig.15 Distribution of critical porosity and coordination number across wells

(a) 临界孔隙度在三口井的分布；(b) 配位数在三口井的分布

#### 2.4.3 多参数物理一致性评估

图 16 展示了联合预测的孔隙度、含水饱和度及声波时差的三维分布，并与基于岩石物理模型计算的理论声波时差曲面进行对比。在大部分区域，预测值密集分布在理论曲面附近，反映了参数间相互关系基本符合物理

预期。然而，在局部区域，尤其是声波时差较高的区域，预测数据点与理论曲面之间存在明显偏离。这与岩石物理参数敏感性分析结果一致：在高声波时差条件下，参数敏感性增强，导致局部预测波动增大。此外，高参数值区间的训练样本相对稀疏，可能使得模型对该区域特征分布的学习不足，从而增加了局部预测的偏差。因此，尽管正反演联合模型在整体上能够保持多参数预测的物理一致性，但在参数空间边缘区域仍有进一步优化的潜力。

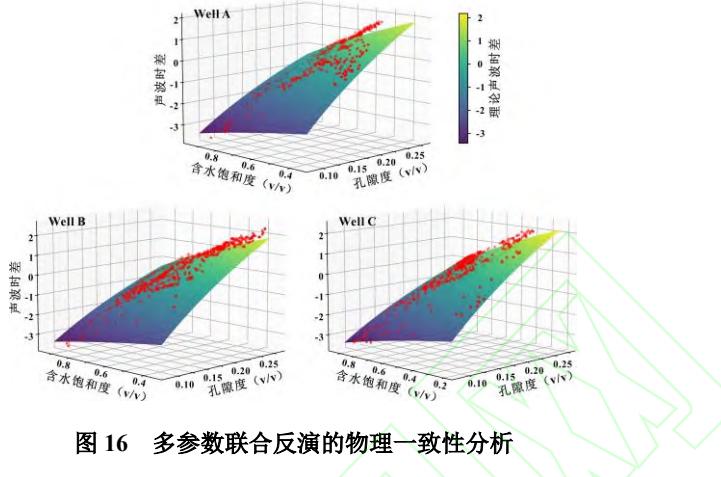


图 16 多参数联合反演的物理一致性分析

Fig.16 Rock physics consistency validation of multi-parameter joint inversion

### 3 总结与讨论

本文提出了一种基于概率与岩石物理信息神经网络的测井多参数反演方法，通过结合深度神经网络与岩石物理模型，为复杂地质条件下的多参数预测提供了一种有效的解决方案。主要认识和结论如下：

(1) 传统神经网络反演模型通常缺乏物理约束，可能导致预测结果与实际地质特征不一致。通过引入岩石物理正演过程，正反演联合模型有效缓解了纯数据驱动方法可能产生的物理不合理性，提供符合岩石物理规律的孔隙度和声波时差预测结果。同时，模型在物理约束下进行优化，有效减少了误差的累积效应，提高了预测结果的稳定性与可靠性。该方法的优势在于其正反演联合架构，使得已知或部分已知的岩石物理关系能够嵌入深度学习过程中，从而增强了对储层参数联合预测的物理解释能力，并易于扩展到不同地质任务中。针对其他可能存在的不确定参数，模型可通过贝叶斯不确定性量化实现超参数的估计，同时对预测结果的不确定性进行量化，为不同地质背景下的多参数反演提供了有效途径。

(2) 岩石物理参数敏感性分析表明，临界孔隙度、配位数和含水饱和度等参数对声波时差和孔隙度的变化存在综合影响。贝叶斯神经网络能够为岩石物理参数提供概率分布，并通过多次采样量化预测的不确定性。因此，该方法不仅能捕捉测井数据反映的地质特征变化，还能量化井间差异，从而提高了模型在复杂地质条件下的适应性和泛化能力。值得注意的是，尽管在本研究采用的小样本数据集下，运行复杂度处于可控范围，但在大规模数据处理环境中，贝叶斯模块引入的时间复杂度可能显著增加，成为性能瓶颈。本研究提出的方法具有较高的可扩展性，未来研究可探讨采用轻量化的贝叶斯近似方法，以进一步优化模型在大规模数据应用中的性能。

(3) 正反演联合模型能够同时预测储层物性参数和岩石物理参数，具备处理多任务问题的能力（如声波时差曲线重构）。即使在缺少部分实验数据（如含水饱和度）的情况下，模型仍能通过物理约束有效训练，并提供具有内在关联和物理一致性的多参数预测结果，展现出较强的灵活性和适应性。然而实验结果显示，局部区域的预测结果仍存在一定偏差。未来研究可探讨引入分层贝叶斯网络架构，在不同声波时差范围内建立子网络，以更精细地适应局部参数变化的敏感性，从而提升模型保持物理一致性的能力。

## 参考文献 (References)

- [1] SCHON J H. Physical properties of rocks: Fundamentals and principles of petrophysics[M]. Amsterdam: Elsevier, 2015.
- [2] PASSEY Q R, BOHACS K M, ESCH W L, et al. From oil-prone source rock to gas-producing shale reservoir-geologic and petrophysical characterization of unconventional shale-gas reservoirs[C]//SPE International Oil and Gas Conference and Exhibition in China. Beijing: SPE, 2010: SPE-131350-MS.
- [3] MAVKO G, MUKERJI T, DVORKIN J. The Rock Physics Handbook[M]. Cambridge: Cambridge University Press, 2020.
- [4] ARCHIE G E. The electrical resistivity log as an aid in determining some reservoir characteristics[J]. Transactions of the AIME, 1942, 146(1): 54-62.
- [5] GASSMANN F. Elastic waves through a packing of spheres[J]. Geophysics, 1951, 16(4): 673-685.
- [6] WYLLIE M R J, GREGORY A R, GARDNER L W. Elastic wave velocities in heterogeneous and porous media[J]. Geophysics, 1956, 21(1): 41-70.
- [7] XU S, WHITE R E. A new velocity model for clay-sand mixtures 1[J]. Geophysical Prospecting, 1995, 43(1): 91-118.
- [8] NUR A, SIMMONS G. The effect of saturation on velocity in low porosity rocks[J]. Earth and Planetary Science Letters, 1969, 7(2): 183-193.
- [9] DVORKIN J, NUR A. Elasticity of high-porosity sandstones: Theory for two North Sea data sets[J]. Geophysics, 1996, 61(5): 1363-1370.
- [10] 叶端南, 印兴耀, 王璞, 等. 砂泥岩储层岩石物理交会模板构建[J]. 地球物理学进展, 2015, 30(2): 758-768.  
YE D N, YIN X Y, WANG P, et al. The build of rock physics cross plot template for sand shale reservoir[J]. Progress in Geophysics, 2015, 30(2): 758-768.
- [11] 黄伟传, 杨长春, 范桃园, 等. 岩石物理分析技术在储层预测中的应用[J]. 地球物理学进展, 2007, 22(6): 1791-1795.  
HUANG W C, YANG C C, FAN T Y, et al. The application of petrophysical analysis in reservoir prediction[J]. Progress in Geophysics, 2007, 22(6): 1791-1795.
- [12] 李燕, 刘浩杰, 王玉梅. Gassmann 模型机理分析及其应用[J]. 勘探地球物理进展, 2010, 33(1): 16-20+80.  
LI Y, LIU H J, WANG Y M. Mechanism analysis of Gassmann model and its application[J]. Progress in Exploration Geophysics, 2010, 33(1): 16-20+80.
- [13] 张佳佳, 印兴耀, 张广智, 等. 基于线性化岩石物理反演的物性参数预测方法[J]. 石油勘探与开发, 2020, 47(1): 57-64.  
ZHANG J J, YIN X Y, ZHANG G Z, et al. Prediction method of physical parameters based on linearized rock physics inversion[J]. Petroleum Exploration and Development, 2020, 47(1): 57-64.
- [14] TIMUR A. Velocity of compressional waves in porous media at permafrost temperatures[J]. Geophysics, 1968, 33(4): 584-595.
- [15] 柴愈坤, 冯沙沙, 王华. 致密砂岩储层物性参数建模方法探讨[J]. 中外能源, 2017, 22(5): 39-43.  
CHAI Y K, FENG S S, WANG H. Discussion on the physical parameter modeling method for tight sandstone reservoir[J]. Sino-Global Energy, 2017, 22(5): 39-43.
- [16] 宛利红, 刘波涛, 王新海, 等. 致密油藏多元回归产能预测方法研究与应用[J]. 油气井测试, 2015, 24(1): 17-19+26+75-76.  
WAN L H, LIU B T, WANG X H, et al. Study on multiple regression analysis in prediction of tight oil reservoir and its application[J]. Well Testing, 2015, 24(1): 17-19+26+75-76.
- [17] 肖曦, 王志红, 叶云飞, 等. 致密砂岩储层孔隙度预测方法研究[J]. 地球物理学进展, 2024, 39(4): 1597-1606.  
XIAO X, WANG Z H, YE Y F, et al. Novel porosity prediction method for tight sandstone reservoirs: A case study of member of He8, Ordos Basin, Northern China[J]. Progress in Geophysics, 2024, 39(4): 1597-1606.
- [18] 袁伟, 张占松, 张泽宇, 等. 基于储层分类的支持向量机渗透率预测[J]. 测井技术, 2015, 39(4): 450-454.  
YUAN W, ZHANG Z S, ZHANG Z Y, et al. Permeability prediction using support vector machine based on reservoir classification[J]. Well Logging Technology, 2015, 39(4): 450-454.
- [19] 魏佳明, 韩家新. 随机森林在储层孔隙度预测中的应用[J]. 智能计算机与应用, 2018, 8(5): 79-82.  
WEI J M, HAN J X. Application of random forest in reservoir porosity prediction[J]. Intelligent Computer and Applications, 2018,

8(5): 79-82.

- [20] 崔学慧, 刘长江, 薛亮, 等. 基于随机森林回归算法预测孔隙度的研究[J]. 西部探矿工程, 2019, 31(11): 99-102+105.
- CUI X H, LIU C J, XUE L, et al. Prediction of porosity based on random forest regression algorithm[J]. West-China Exploration Engineering, 2019, 31(11): 99-102+105.
- [21] 魏国华, 韩宏伟, 刘浩杰, 等. 基于半监督高斯混合模型与梯度提升树的砂岩储层相控孔隙度预测[J]. 石油地球物理勘探, 2023, 58(1): 46-55.
- WEI G H, HAN H W, LIU H J, et al. Facies-controlled porosity prediction of sandstone reservoirs based on semi-supervised Gaussian mixture model and gradient boosting tree[J]. Oil Geophysical Prospecting, 2023, 58(1): 46-55.
- [22] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [23] 魏杰, 杨斌, 刘锋, 等. 基于岩性识别的 BP 神经网络孔隙度预测[J]. 石油化工应用, 2020, 39(3): 105-110.
- WEI J, YANG B, LIU F, et al. Prediction of porosity by BP neural network based on lithology recognition[J]. Petrochemical Industry Application, 2020, 39(3): 105-110.
- [24] 李奎周, 王团, 赵海波, 等. 基于深度前馈神经网络的致密砂岩储层孔隙度预测[J]. 大庆石油地质与开发, 2023, 42(5): 140-146.
- LI K Z, WANG T, ZHAO H B, et al. Porosity prediction of tight sandstone reservoir based on deep feedforward neural network[J]. Petroleum Geology and Oilfield Development in Daqing, 2023, 42(5): 140-146.
- [25] 王俊, 曹俊兴, 周欣. 基于深度双向循环神经网络的储层孔隙度预测[J]. 地球物理学进展, 2022, 37(1): 267-274.
- WANG J, CAO J X, ZHOU X. Reservoir porosity prediction based on deep bidirectional recurrent neural network[J]. Progress in Geophysics, 2022, 37(1): 267-274.
- [26] 杨柳青, 陈伟, 查蓓. 利用卷积神经网络对储层孔隙度的预测研究与应用[J]. 地球物理学进展, 2019, 34(4): 1548-1555.
- YANG L Q, CHEN W, ZHA B. Prediction and application of reservoir porosity by convolutional neural network[J]. Progress in Geophysics, 2019, 34(4): 1548-1555.
- [27] 宋辉, 陈伟, 李谋杰, 等. 基于卷积门控循环单元网络的储层参数预测方法[J]. 油气地质与采收率, 2019, 26(5): 73-78.
- SONG H, CHEN W, LI M J, et al. A method to predict reservoir parameters based on convolutional neural network-gated recurrent unit (CNN-GRU)[J]. Petroleum Geology and Recovery Efficiency, 2019, 26(5): 73-78.
- [28] VASHISTH D, MUKERJI T. Direct estimation of porosity from seismic data using rock-and wave-physics-informed neural networks[J]. The Leading Edge, 2022, 41(12): 840-846.
- [29] LV A, CHENG L, AGHIGHI M A, et al. A novel workflow based on physics-informed machine learning to determine the permeability profile of fractured coal seams using downhole geophysical logs[J]. Marine and Petroleum Geology, 2021, 131: 105171.
- [30] DENG T, AMBIA J, TORRES-VERDIN C. Interpretation of well logs and core data via Bayesian inversion[J]. Geophysics, 2023, 88(2): D49-D67.
- [31] DVORKIN J, NUR A, CHAIKA C. Stress sensitivity of sandstones[J]. Geophysics, 1996, 61(2): 444-455.
- [32] MINDLIN R D. Compliance of elastic bodies in contact[J]. Journal of Applied Mechanics, 1949, 16(3): 259-268.
- [33] HASHIN Z, SHTRIKMAN S. A variational approach to the theory of the elastic behaviour of multiphase materials[J]. Journal of the Mechanics and Physics of Solids, 1963, 11(2): 127-140.
- [34] VASWANI A, SHAZER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30: 5998-6008.
- [35] GAO Y N, TIAN M, GRANA D, et al. Attention mechanism-assisted recurrent neural network for well log lithology classification[J]. Geophysical Prospecting, 2025, 73(2): 628-649.

# Probabilistic rock physics-informed neural network for multi-parameter well log inversion

GAO Yining<sup>1</sup>, XU Zhaohui<sup>1</sup>, TIAN Miao<sup>2</sup>, XU Huaimin<sup>1</sup>

(1. College of Geosciences, China University of Petroleum Beijing, Beijing, 102249, China;

2. State Key Laboratory of Shale Oil and Gas Enrichment Mechanisms and Effective Development, Beijing, 102206, China)

**Abstract:** Accurate prediction of reservoir petrophysical properties is essential for reservoir evaluation and production decision-making. Traditional rock physics models and statistical methods provide physical interpretability but are limited by the high cost and scarcity of experimental data. In comparison, deep learning techniques can effectively model complex nonlinear relationships but lack physical constraints. To address these challenges, we propose a probabilistic rock physics-informed neural network for well log inversion. This approach innovatively integrates knowledge-driven rock physics forward models with data-driven deep neural networks and incorporates a Bayesian neural network to estimate the probability distributions of rock physics hyperparameters. This framework enables the joint prediction of porosity, water saturation, and acoustic, while quantifying prediction uncertainty. Experimental results indicate that parameters such as critical porosity and coordination number exhibit complex influence mechanisms on rock physics models. Under high acoustic conditions, these parameters show heightened sensitivity and exert more pronounced impacts on the predictions. Compared to traditional deep learning methods, the proposed method enhances model robustness in scenarios with limited data quality or quantity by integrating rock physics constraints, provides multi-parameter predictions consistent with rock physics principles, and demonstrates improved accuracy in predicting petrophysical properties of sandstone reservoirs.

**Keywords:** Well log inversion; Bayesian neural networks; Deep learning; Rock physics models; Uncertainty quantification

**Foundation item:** The National Natural Science Foundation of China (Grant No.42302334)