doi: 10.11720/wtyht.2026.1407
李金付, 沈亚, 王世成, 等. 基于交叉注意力机制的智能化横波速度测井曲线预测方法[J]. 物探与化探, 2026, 50(2): 301-309. https://doi.org/10.11720/wtyht.2026.1407
Li J F, Shen Y, Wang S C, et al. An intelligent log-based method for predicting shear wave velocity based on a cross-attention mechanism[J]. Geophysical and Geochemical Exploration, 2026, 50(2): 301-309. https://doi.org/10.11720/wtyht.2026.1407

# 基于交叉注意力机制的智能化横波速度测井曲线预测方法

李金付[1], 沈亚[1], 王世成[1], 王宇航[1], 陈大宏[1], 张广智[2], 陈腾飞[2]
(1. 东方地球物理勘探有限责任公司研究院 长庆分院, 陕西 西安 710021; 2. 中国石油大学(华东) 地球科学与技术学院, 山东 青岛 266580)

**摘 要:** 横波速度是表征岩石弹性性质与流体敏感性的关键参数, 在地震波阻抗反演、地层识别及岩石物理建模等研究中具有重要意义。然而, 受采集成本及技术等问题, 常存在数据缺失或精度不足的问题。为此, 本文提出一种融合二维卷积神经网络、状态空间模型与交叉注意力机制的横波速度智能预测方法。该方法通过二维卷积神经网络和状态空间模型分别捕捉局部空间特征和纵向时序依赖关系, 并利用交叉注意力机制实现空间与时间特征的深度融合, 从而提升网络对关键地质信息的感知能力。此外, 为增强网络的可解释性, 本文引入基于 Shapley additive explanations 的解释性分析方法, 量化不同测井参数对横波速度预测的贡献度。实验结果表明, 本文所提方法在预测精度与泛化能力方面均优于传统单一神经网络, 且能有效揭示横波速度与常规测井参数之间的物理关联, 为复杂储层条件下横波速度的快速、可靠预测提供了新的思路与技术支撑。

**关键词:** 横波速度; 状态空间模型; 交叉注意力机制; SHAP 可解释性; 深度学习; 神经网络
**中图分类号:** P631.4; P31 **文献标识码:** A **文章编号:** 1000-8918(2026)02-0301-09

## 0 引言

横波速度 $V_s$ 是表征岩石弹性性质与流体敏感性的关键参数之一, 在地层识别及岩石物理建模等研究中具有重要作用[1-3]。然而, 与纵波速度 $V_p$ 和密度 $\rho$ 等常规测井参数相比, 横波速度测量成本高、可获取性差, 尤其在老井或低成本开发区块中, 常存在横波速度资料缺失或精度不足的问题。这一现状严重限制了地震资料的定量反演与储层特征识别精度。

传统的横波速度估算方法主要包括经验公式法和岩石物理模型法[4-7]。经验公式法虽然计算简便, 但其参数依赖于特定地质条件, 泛化能力较差; 岩石物理模型法能够反映岩石组分与孔隙结构的物理关系, 但模型假设往往过于理想化且部分参数往往难以准确获取, 从而限制岩石物理模型的应用。

近年来, 随着人工智能与深度学习技术的发展, 神经网络在地球物理领域中的应用逐渐深入[8-11], 其强大的特征学习和非线性拟合能力为横波速度的智能预测提供了新的思路。基于神经网络的曲线重构能够从大量测井数据中自动学习复杂的非线性关系, 避免了传统方法中对显式物理方程和参数假设的依赖, 从而在不同地质条件下具有更好的泛化能力。目前, 国内外学者已尝试利用卷积神经网络(convolutional neural network, CNN)及循环神经网络(rerrent neural network, RNN)开展应用[12,13], 并取得了良好的效果。马乔雨等[14] 通过一维卷积神经网络提取常规测井数据的空间特征, 从而与横波速度之间建立映射关系。此外, 孙宇航等[15] 通过门控循环单元(gate recurrent unit, GRU)捕捉测井数据随深度变化的序列相关性, 进而进行横波速度预测。Chen 等[16] 通过多层长短记忆网络(long short term memory, LSTM)建立孔隙度的预测模型, 从而提高孔隙度的预测精度。然而, 上述方法仅从空间特征或时序特

**收稿日期:** 2025-11-28; **修回日期:** 2026-01-28
**基金项目:** 中国石油集团东方地球物理勘探有限责任公司重大专项项目(25BFWTSG008)
**第一作者:** 李金付(1970-), 男, 高级工程师, 勘察地球物理专业, 主要从事储层预测与地震资料综合解释工作。Email: 15309283918@163.com

征角度进行特征提取，未能充分融合两者的信息，导致神经网络在关联测井数据时空特征方面存在困难。为此，部分学者采用神经网络融合或者加入注意力机制的方式进一步提高神经网络对时空特征的捕捉能力[17-20]。Chen 等[21] 将二维卷积神经网络和门控循环单元融合分别提取测井数据的空间特征和时序特征进行横波速度预测。李艳辉等[22] 将注意力机制与时空网络融合，从而为不同的时空特征分配不同的权重系数，进而提高网络对重要时空特征的敏感度。翟晓岩等[23] 将空间注意力机制与二维卷积神经网络融合，强化深度学习网络捕捉测井曲线自相关和互相关特征信息的能力。

针对横波速度预测中时空特征耦合不足及长序列特征提取时存在记忆丢失等问题，本文提出一种融合二维卷积神经网络(CNN)、状态空间模型(Mamba)与交叉注意力机制的智能预测方法(convolutional neural network-Mamba-cross attention, CMCA)。该方法利用 CNN 提取局部空间特征，Mamba 捕捉纵向时序依赖关系，并通过交叉注意力实现空间与时间特征的深度融合，从而显著提升横波速度预测的准确性与泛化能力。此外，为增强神经网络的可解释性，本文通过 SHAP 可解释性方法揭示了不同测井参数在横波速度预测中的关键影响因素，使模型不仅具备较强的预测性能，同时在结果解释性方面具有更高的可信度与实用价值。

## 1　关键技术思路及方法原理

针对长序列测井曲线空间变化与纵向层序之间往往具有强耦合关系，传统方法或普通深度网络难以同时捕获不同的时空信息，从而导致横波速度曲线预测精度低等问题，本文提出了一种基于交叉注意力机制的 CNN–Mamba 融合网络(图 1)。该方法以常规测井曲线为输入，通过二维卷积神经网络提取测井曲线的空间特征，同时利用 Mamba 网络提取测井曲线的时序依赖信息，随后通过交叉注意力机制实现空间特征与时序特征的动态耦合，最后在全连接层的作用下进行非线性拟合，从而实现对横波速度曲线的高精度预测。横波速度训练和预测流程可分为以下步骤(图 2)。

1)相关性分析。通过相关系数，分析各测井曲线与横波速度之间的相关性，筛选出与横波速度高度相关的输入特征，以减少冗余输入，提高模型训练效率。

2)数据处理。对优选出来的常规测井数据进行标准化处理，从而消除不同类型测井数据量纲之间的差异。随后，将处理后的数据按一定比例划分为训练集和测试集，从而验证网络的性能。

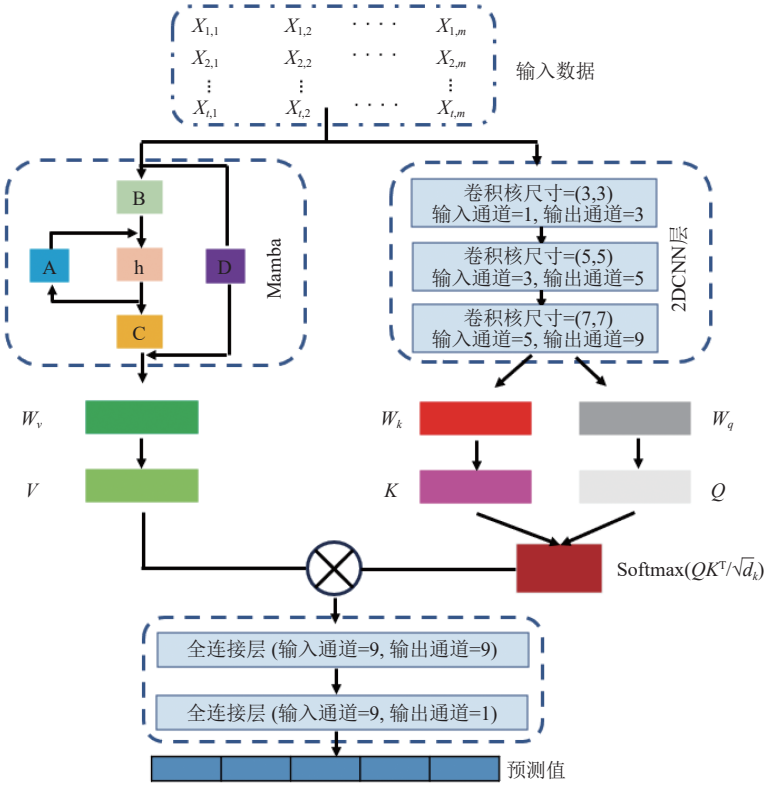



**图 1　CMCA 的网络结构**

**Fig. 1　The structure of the CMCA network**

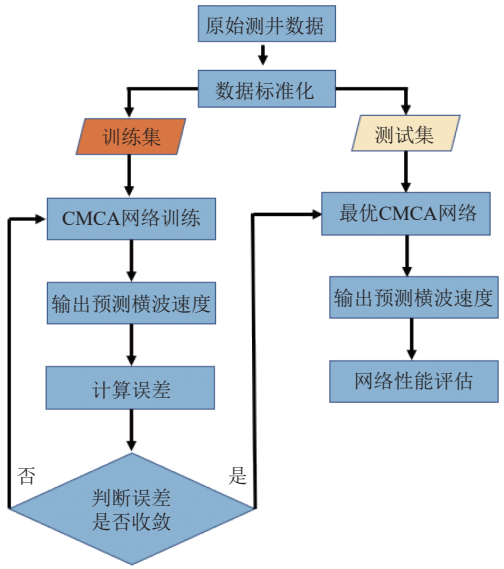



**图 2　CMCA 融合网络的训练和预测流程**

**Fig. 2　The training and prediction process of the CMCA fusion network**

3)网络训练。将选取的常规测井数据输入到融合网络中, 采用均方误差 *MSE* 作为损失函数, 通过 Adam 优化器迭代更新网络参数, 直至模型收敛。

4)网络评估。利用测试集对训练完成的网络进行评估, 采用相关系数 $R^2$、平均绝对误差 *MAE* 指标衡量网络的性能。

$$R^2 = 1 - \frac{\sum_{i=1}^{m}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{m}(y_i - \bar{y})^2}, \tag{1}$$

$$MAE = \frac{1}{m}\sum_{i=1}^{m}|y_i - \hat{y}_i|, \tag{2}$$

式中: $y_i$表示真实值; $\bar{y}$表示真实值的均值; $\hat{y}_i$表示预测值; $m$ 是样本数量。

### 1.1　卷积神经网络

卷积神经网络是经典神经网络之一, 其核心思想是通过局部感受野、权重共享和下采样机制, 从输入数据中自动提取层次化特征, 从而捕捉局部和全局信息。

$$Y(i,j) = f\left(\sum_{p=1}^{P}\sum_{q=1}^{Q}\boldsymbol{W}(\boldsymbol{p},\boldsymbol{q})\cdot X(i+p-1, j+q-1)+b\right), \tag{3}$$

式中: $Y(i,j)$表示在$(i,j)$位置处提取的空间特征; $\boldsymbol{W}(\boldsymbol{p},\boldsymbol{q})$是二维卷积核; $X(i+p-1, j+q-1)$ 表示输入数据; "$b$" 是偏置。

### 1.2　状态空间模型

Mamba 是一种新型的状态空间模型(state space model, SSM)架构, 旨在高效提取长序列数据的特征。其核心思想是结合经典状态空间模型、循环神经网络和卷积神经网络的优势, 并引入输入依赖的选择机制, 使模型能够动态关注相关输入, 忽略无关信息。

$$\boldsymbol{h}'(\boldsymbol{t}) = \boldsymbol{A}\boldsymbol{h}(\boldsymbol{t}) + \boldsymbol{B}\boldsymbol{x}(\boldsymbol{t}), \tag{4}$$

$$\boldsymbol{y}(\boldsymbol{t}) = \boldsymbol{C}\boldsymbol{h}(\boldsymbol{t}) + \boldsymbol{D}\boldsymbol{x}(\boldsymbol{t}), \tag{5}$$

式中: $\boldsymbol{h}(\boldsymbol{t})$是上一时刻的输入; $\boldsymbol{h}'(\boldsymbol{t})$是当前时刻的隐藏层状态; $\boldsymbol{x}(\boldsymbol{t})$是当前时刻的输入; $\boldsymbol{A}$是状态转移矩阵, 用于描述系统状态随时间的变化规律; $\boldsymbol{B}$是输入矩阵, 用于描述控制输入对状态变化的影响; $\boldsymbol{C}$是输出矩阵, 用于根据当前状态生成输出; $\boldsymbol{D}$是指令系数, 用于描述输入对输出的直接影响, 一般情况下可以忽略。

原始的状态空间模型是连续的。为了满足深度学习任务中离散输入的需求, 原始的连续状态空间模型需要被离散化。

$$\boldsymbol{h}'(\boldsymbol{t}) = \overline{\boldsymbol{A}_t}\boldsymbol{h}(\boldsymbol{t}) + \overline{\boldsymbol{B}_t}\boldsymbol{x}(\boldsymbol{t}), \tag{6}$$

$$\boldsymbol{y}(\boldsymbol{t}) = \overline{\boldsymbol{C}_t}\boldsymbol{h}(\boldsymbol{t}), \tag{7}$$

式中: $\overline{\boldsymbol{A}_t}$、$\overline{\boldsymbol{B}_t}$和$\overline{\boldsymbol{C}_t}$是动态参数矩阵, 它们使模型能够动态地选择注意力信息并忽略无关输入, 从而提高对重要时序特征的敏感性(即注意力机制)。

### 1.3　交叉注意力机制

横波速度与常规测井数据的不同时空特征之间的相关性存在差异。因此, 将交叉注意力机制与 CNN、Mamba 模块融合, 用于对不同的时空特征分配自适应权重。具体来说, CNN 提取的不同空间特征被用作查询向量 $\boldsymbol{Q}$ 和键向量 $\boldsymbol{K}$, 而 Mamba 提取的时序特征被用作值向量 $\boldsymbol{V}$。交叉注意力通过计算 $\boldsymbol{Q}$ 与 $\boldsymbol{K}$ 之间的注意力权重并与 $\boldsymbol{V}$ 相乘, 从而实现空间特征与时间特征之间的信息交互与动态融合。

$$\boldsymbol{Q} = Softmax(\boldsymbol{W}_q\boldsymbol{X}_t + b_q), \tag{8}$$

$$\boldsymbol{K} = Softmax(\boldsymbol{W}_k\boldsymbol{X}_t + b_k), \tag{9}$$

$$\boldsymbol{V} = Softmax(\boldsymbol{W}_v\boldsymbol{H}_t + b_v), \tag{10}$$

$$\boldsymbol{X}_t' = Softmax\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}}\right)\boldsymbol{V}, \tag{11}$$

式中: $\boldsymbol{X}_t$和$\boldsymbol{H}_t$分别是卷积神经网络和 Mamba 网络提取的空间特征和时序特征; $\boldsymbol{W}_q$, $\boldsymbol{W}_k$, $\boldsymbol{W}_v$和$b_q$, $b_k$, $b_v$是权重矩阵和偏置; $d_k$ 是时空特征的长度; $Softmax$ 是激活函数, 可以将数据映射到 [0,1] 范围内; $\boldsymbol{X}_t'$是加权后的结果。

### 1.4　SHAP 原理

SHAP(Shapley additive explanations)是一种基于合作博弈论的模型可解释性方法, 其核心思想是通过计算特征在所有可能特征组合中的边际贡献来量化每个输入特征对模型输出的影响程度。SHAP 以

Shapley 值为理论基础，实现了对深度神经网络的全局与局部解释。给定任意特征子集$S$，神经网络的预测结果可以表示为$f(S)$。当某一特征$i$加入子集后，其边际贡献可定义为：

$$\Delta_i(S)=f(S\cup\{i\})-f(S), \tag{12}$$

Shapley 值则是在所有可能特征排列中，对该边际贡献的加权平均，即：

$$\varphi_i=\sum_{S\subseteq N\setminus\{i\}}\frac{|S|!(|N|-|S|-1)!}{|N|!}[f(S\cup\{i\})-f(S)], \tag{13}$$

式中：$\varphi_i$表示特征$i$对神经网络预测的平均贡献度，数值为正，说明该特征使预测值增大；数值为负，则说明使预测值减小。$S\subseteq N\setminus\{i\}$表示不包含特征$i$的特征子集。

## 2　实际应用

### 2.1　数据集介绍

本文选取中国东部 X 工区中的 S1、S2、S3、S4 和 S5 井为研究对象，该工区属于典型的致密砂岩储层，埋藏较深、孔隙度低、渗透率差，具有明显的非均质性和复杂的岩石物理特征。地层以细粒长石砂岩为主，夹有薄层泥岩及粉砂质泥岩，具有强烈的层间变化和非均质结构特征。通过相关性分析，优选出与横波速度相关的测井曲线（图 3），其中包括纵波速度 $V_p$、密度 $\rho$、自然伽马 *GR*、孔隙度 *CNL*、泥质含量 *SH* 和含水饱和度 *SW*，相关系数 $R^2$ 依次为 0.59、0.04、0.21、0.39、0.23 和 0.12。此外，由于沉积地层是渐变的，测井数据在深度方向上具有相关性，因此，采用自相关函数 *ACF* 分析常规测井数据的自相关性（图 4），可以看出，随着滞后距的不断增大，测井数据的自相关性逐渐降低。上述分析表明，常规测井数据与横波速度之间存在不同程度的相关性和自相关性。此外，本文将 S1、S2 和 S4 井作为训练，将 S3 和 S5 井作为测试样本，用于评估网络的泛化性能。

### 2.2　不同方法对比

为了验证本文所提方法的有效性，将 CMCA 融合网络的预测结果分别与 2DCNN、GRU 网络和岩石物理模型方法的预测结果进行对比。为了确保对比结果的公平性，所有网络均使用自适应矩估计作为优化器，以均方误差 *MSE* 作为损失函数，并保持一致的超参数配置（如学习率、批大小和训练轮数等）。图 5 为不同方法在 S2 井上的预测结果，可以看出，尽管不同方法都能较好地建立常规测井数据与横波速度之间的映射关系，但是 CMCA 融合网络的预测效果要优于其他方法的预测结果，其相关系数比 2DCNN、GRU 网络和岩石物理模型的高 0.022 0、

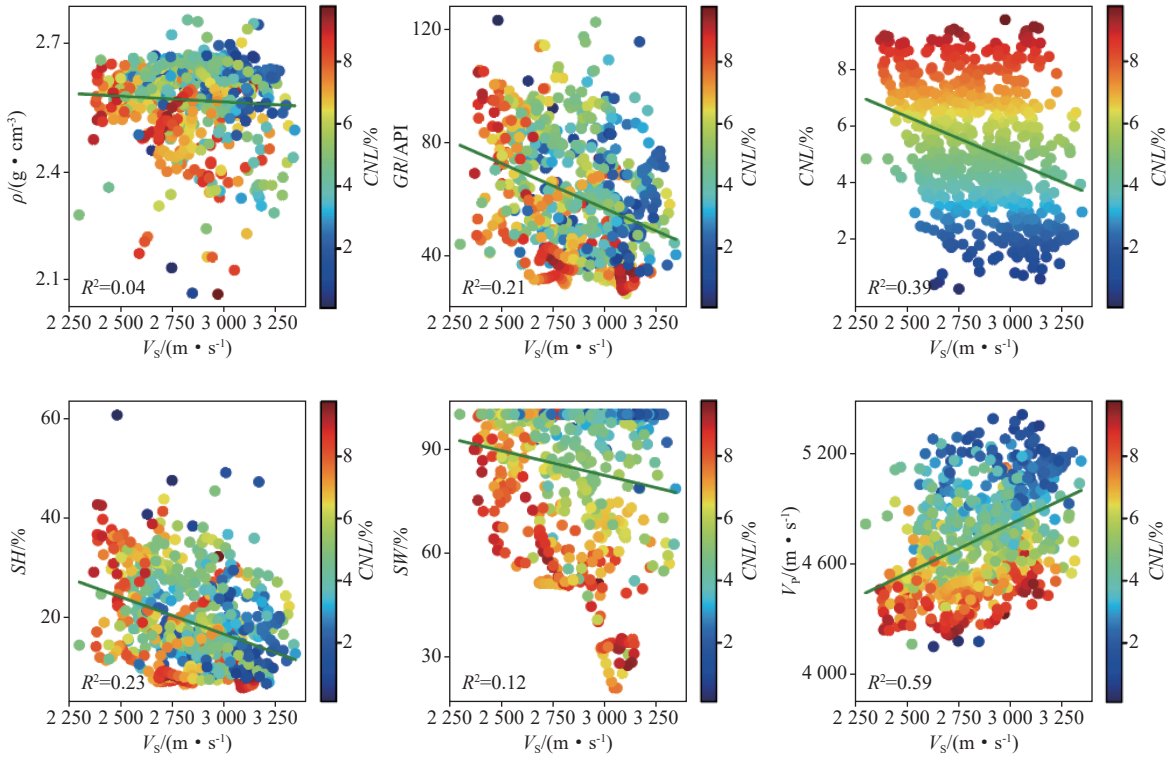



**图 3　横波速度与其他常规测井曲线交会**

**Fig. 3　Crossplot of shear wave velocity and other conventional logging curves**

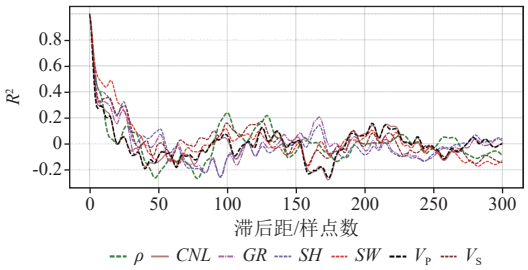



**图 4　常规测井曲线的自相关系数**

**Fig. 4　Autocorrelation coefficient of conventional logging curve**

0.023 3 和 0.039 9, 表明 CMCA 融合网络能够更充分地提取常规测井数据的空间特征与时间序列特征, 从而与横波速度之间建立映射关系。

为了更好地验证本文所提方法的泛化性, 将测试集 S3 井和 S5 井的预测结果进行对比(图 6)。可以看出, 在 S3 井的 3 801~3 845 m 和 3 980~3 990 m 以及 S5 井的 3 805~3 860 m 和 3 895~3 920 m 处 (图中黑框所示), CMCA 融合网络的预测效果优于其他方法。主要原因是 CMCA 融合网络通过 2DCNN 和 Mamba 网络充分提取常规测井数据的时空特征, 并通过交叉注意力机制实现时空特征的自适应融合与权重分配, 从而在细节刻画和局部异常识别方面表现更优。表 1 为不同方法的定量评估结果, 可以看出, CMCA 融合网络在 S3 井和 S5 井的 $R^2$ 最高且 *MAE* 最低, 其中, CMCA 融合网络的 $R^2$ 分别比 2DCNN、GRU 和岩石物理模型的高 0.096 6、0.085 4, 0.104 8、0.097 0 和 0.120 0、0.125 1。从而表明, CMCA 融合网络具有更高的预测精度和更强的泛化能力。

### 2.3　基于 SHAP 的全局解释

为进一步探究神经网络的决策依据与各测井参数对预测结果的整体影响, 本研究采用了基于 SHAP 的可解释性分析方法。SHAP 通过计算各输入特征对预测结果的平均贡献度, 能够量化不同测井参数在模型整体预测中的重要性, 从而揭示模型内部的特征响应机制。图 7 为全局 SHAP 值分布, 从上到下按照对预测横波速度的重要性排序, 其中纵波速度贡献度最高, 密度贡献度最低, 这与图 5 中常规测井数据与横波速度之间的相关性规律是一致的。其中, 纵波速度和孔隙度对横波速度的贡献最大, 说明神经网络主要依赖纵波速度和孔隙结构进

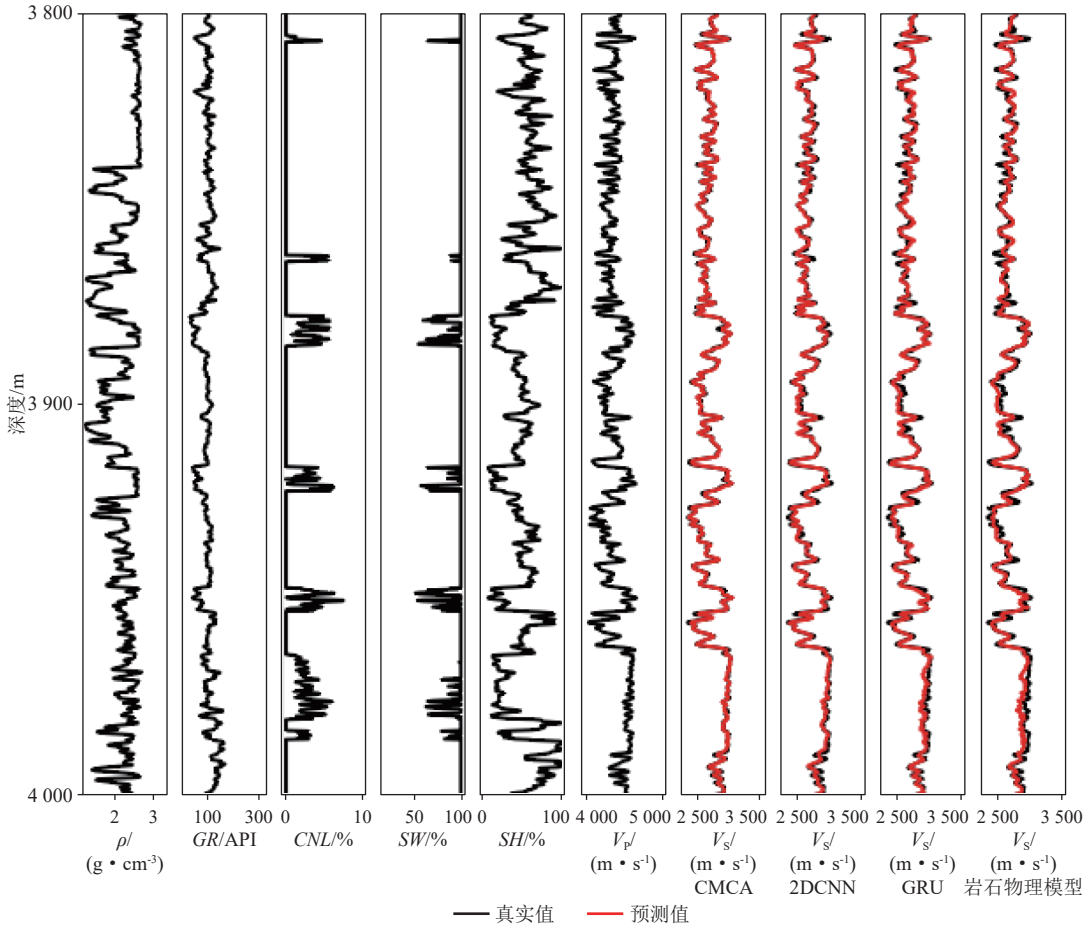



**图 5　S2 井中不同方法在训练集上横波速度预测结果**

**Fig. 5　The shear wave velocity prediction results of different methods on the training set in S2 well**

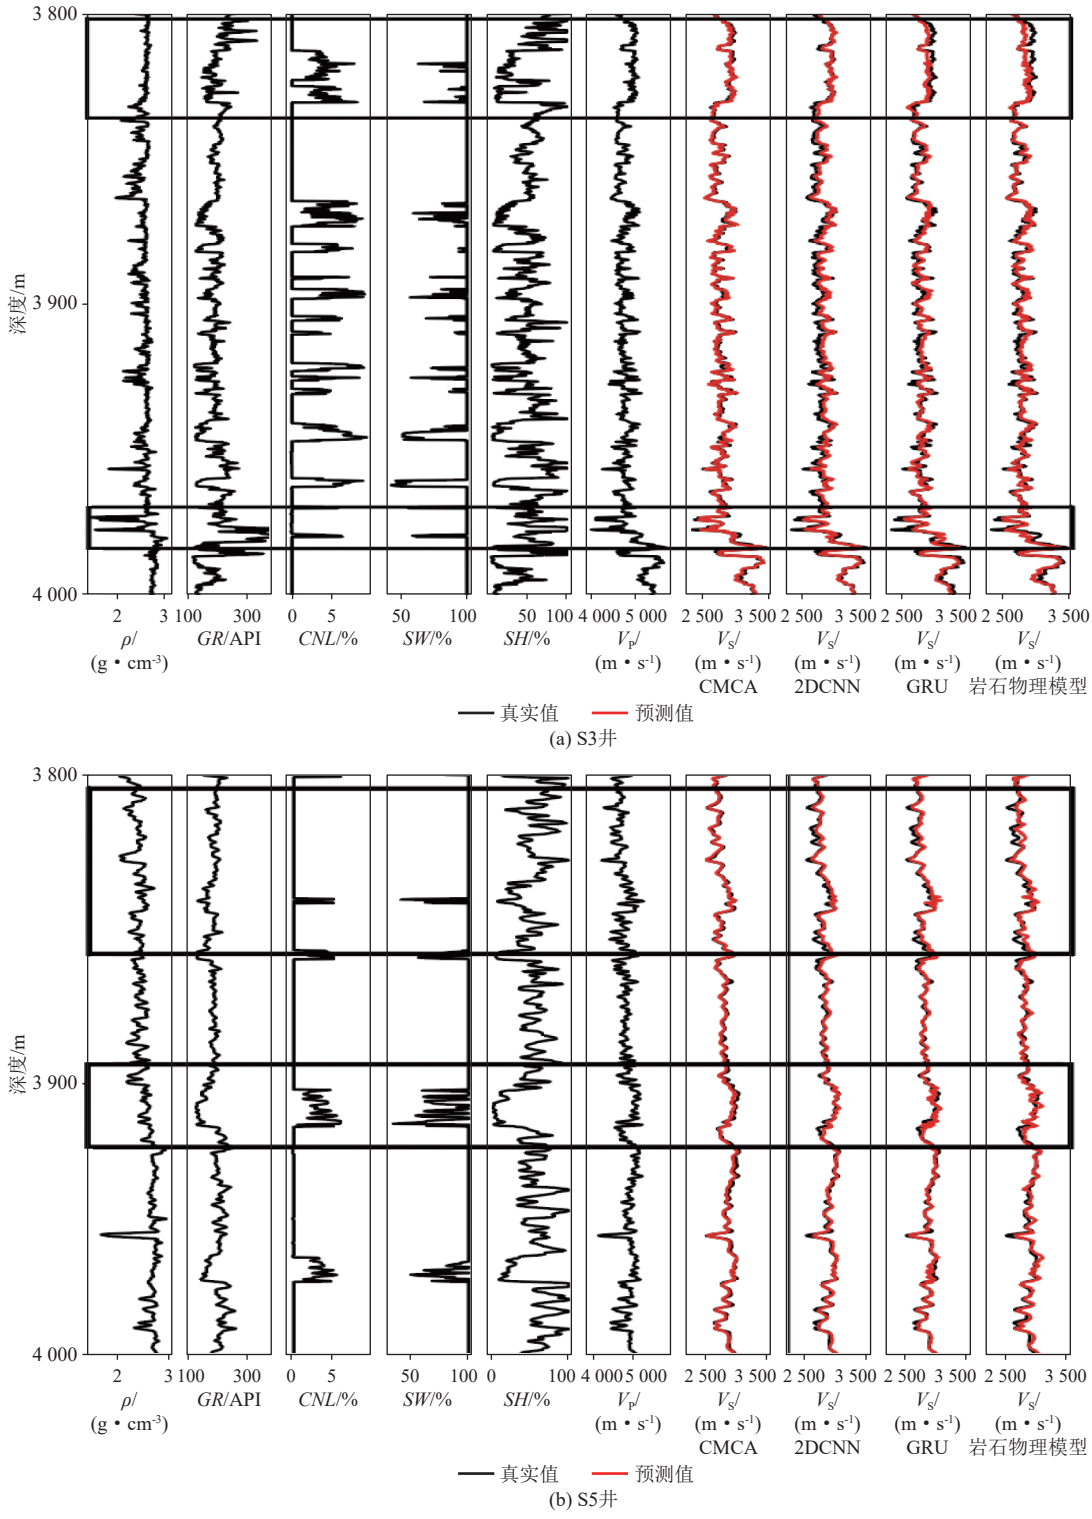



**图 6　不同方法在测试集上横波速度预测结果**

**Fig. 6　The shear wave velocity prediction results of different methods on the test set**

行预测。与此同时，伽马、含水饱和度、泥质含量和密度等参数在一定程度上也影响预测结果，表明地层岩性差异和流体特征对横波速度具有间接控制作用，进一步验证了网络的物理一致性和可靠性。此外，每个点对应的横坐标值为神经网络的 SHAP 值，颜色从蓝到红表示贡献度逐渐变大，从特征重要性分布可以看出，神经网络并未过度依赖单一测井参数，而是综合考虑了多种岩石物理因素的协同作用，体现了 CMCA 融合网络在复杂地质条件下的稳健性与泛化能力。

### 2.4　基于 SHAP 的局部解释

为了深入理解 CMCA 融合网络在具体样本上的

**表 1　不同方法的评估结果**

**Table 1　Evaluation results of different methods**

| 井名 | 方法 | *MAE* | $R^2$ |
|---|---|---|---|
| S2 | 岩石物理模型 | 0.071 | 0.942 6 |
| | 2DCNN | 0.048 | 0.960 5 |
| | GRU | 0.058 | 0.959 2 |
| | CMCA | 0.019 | 0.982 5 |
| S3 | 岩石物理模型 | 0.132 | 0.831 9 |
| | 2DCNN | 0.125 | 0.855 3 |
| | GRU | 0.129 | 0.847 1 |
| | CMCA | 0.065 | 0.951 9 |
| S5 | 岩石物理模型 | 0.139 | 0.822 9 |
| | 2DCNN | 0.116 | 0.862 6 |
| | GRU | 0.125 | 0.851 0 |
| | CMCA | 0.070 | 0.948 0 |

决策机制, 进一步对测试集单个样本进行了局部可解释性分析。以第 3 个样本为例(图 8), 纵波速度和

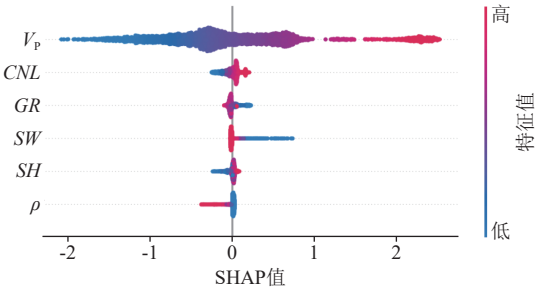



**图 7　特征参数的 SHAP 值分布**

**Fig. 7　SHAP value distribution of characteristic parameters**

密度对该段横波速度的正向贡献最大, 而孔隙度、自然伽马和泥质含量在一定程度上起负向调节作用, 含水饱和度对局部预测结果的贡献相对较小。这说明 CMCA 网络能够根据特定井段的地质条件, 自适应地调节各测井参数的权重, 动态捕捉局部时空特征, 从而实现对横波速度的精细预测。

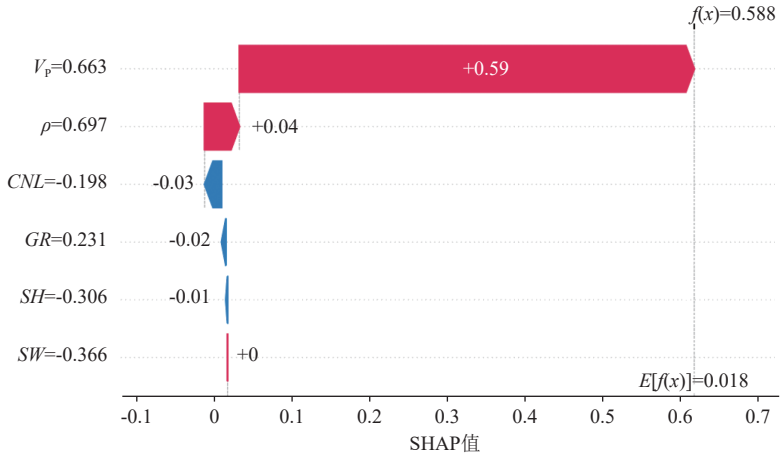



**图 8　样本 3 的局部解释**

**Fig. 8　Local explanation of sample 3**

## 3　结论

针对传统方法横波速度测井曲线预测过程中存在时空特征耦合不足、长序列测井曲线提取时记忆丢失等问题, 提出了一种基于交叉注意力机制的智能化横波速度测井曲线预测新方法。测试结果表明, 该方法不仅能够充分刻画常规测井曲线的空间纹理特征与垂向层序变化关系, 而且在砂岩段、泥岩段、薄互层等复杂层序条件下均表现出更高的预测精度与模型稳定性。在 S3 井和 S5 井, CMCA 融合网络的 $R^2$ 比 2DCNN、GRU 和岩石物理模型分别提高了 0.096 6、0.085 4、0.104 8、0.097 0 和 0.120 0、0.125 1, 从而验证本文所提方法具有更高的预测精度和泛化性。此外, 基于 SHAP 可解释性框架, 分析常规测井曲线对横波速度的贡献度, 结果表明, 纵波速度仍是主要影响因素, 这与岩石物理规律一致, 即横波速度主要受岩石弹性性质控制, 进一步验证了 CMCA 融合网络不仅具有高精度预测能力, 也能够反映物理机制。

**参考文献(References):**

[1] Saltzer R, Finn C, Burtz O. Predicting VShale and porosity using cascaded seismic and rock physics inversion[J]. The Leading Edge, 2005, 24(7): 732−736.

[2] Spikes K, Mukerji T, Dvorkin J, et al. Probabilistic seismic inversion based on rock-physics models[J]. Geophysics, 2007, 72(5): R87−R97.

[3] Sharma R K, Chopra S. Determination of lithology and brittleness of rocks with a new attribute[J]. The Leading Edge, 2015, 34(5): 554−564.

[4] Castagna J P, Batzle M L, Eastwood R L. Relationships between compressional-wave and shear-wave velocities in clastic silicate rocks[J]. Geophysics, 1985, 50(4): 571−581.

[5] Greenberg M L, Castagna J P. Shear-wave velocity estimation in porous rocks: Theoretical formulation, preliminary verification and applications[J]. Geophysical Prospecting, 1992, 40(2): 195−209.

[6] Kuster G T, Toksoz M N. Velocity and attenuation of seismic waves in two-phase media:Part I, Theoretical formulations[J]. Geophysics, 1974, 39(5): 587−606.

[7] Xu S Y, White R E. A new velocity model for clay-sand mixtures [J]. Geophysical Prospecting, 1995, 43(1): 91−118.

[8] Chen T F, Gao G, Wang P, et al. Prediction of shear wave velocity based on a hybrid network of two-dimensional convolutional neural network and gated recurrent unit[J]. Geofluids, 2022, 2022(1): 9974157.

[9] 葛大明. 基于深度学习的二维斜率层析反演模型误差校正方法 [J]. 物探与化探, 2025, 49(2): 385−393.
Ge D M. A deep learning-based method for error correction of 2D slope tomography-based inversion models[J]. Geophysical and Geochemical Exploration, 2025, 49(2): 385−393.

[10] 李国豪, 吕玉增, 董一凡, 等. 基于正演约束的高密度电法半监督学习反演 [J]. 物探与化探, 2025, 49(3): 661−669.
Li G H, Lyu Y Z, Dong Y F, et al. Semi-supervised learning inversion of data derived from high-resolution electrical resistivity tomography based on forward modeling constraints[J]. Geophysical and Geochemical Exploration, 2025, 49(3): 661−669.

[11] 单博, 邢宇鑫, 张繁昌, 等. 基于二次编解码网络的适应性叠前反演方法 [J]. 物探与化探, 2025, 49(1): 158−165.
Shan B, Xing Y X, Zhang F C, et al. Adaptive prestack inversion method based on quadratic encoder-decoder network[J]. Geophysical and Geochemical Exploration, 2025, 49(1): 158−165.

[12] LeCun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541−551.

[13] Schuster M, Paliwal K K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673−2681.

[14] 马乔雨, 张欣, 张春雷, 等. 基于一维卷积神经网络的横波速度预测 [J]. 岩性油气藏, 2021, 33(4): 111−120.
Ma Q Y, Zhang X, Zhang C L, et al. Shear wave velocity prediction based on one-dimensional convolutional neural network[J]. Lithologic Reservoirs, 2021, 33(4): 111−120.

[15] 孙宇航, 刘洋. 利用 GRU 神经网络预测横波速度 [J]. 石油地球物理勘探, 2020, 55(3): 484−492, 503, 467.
Sun Y H, Liu Y. Prediction of S-wave velocity based on GRU neural network[J]. Oil Geophysical Prospecting, 2020, 55(3): 484−492, 503, 467.

[16] Chen W, Yang L Q, Zha B, et al. Deep learning reservoir porosity prediction based on multilayer long short-term memory network[J]. Geophysics, 2020, 85(4): WA213−WA225.

[17] Liu Y Q, Gao C Q, Zhao B. Shear-wave velocity prediction based on the CNN-BiGRU integrated network with spatiotemporal attention mechanism[J]. Processes, 2024, 12(7): 1367.

[18] Chen T F, Gao G, Liu H J, et al. Rock brittleness index inversion method with constraints of seismic and well logs via a CNN-GRU fusion network based on the spatiotemporal attention mechanism[J]. Geoenergy Science and Engineering, 2023, 225: 211646.

[19] 黄闻露, 阎建国, 任立龙, 等. 模型反演和深度学习反演联合的地震波阻抗优化反演 [J]. 物探与化探, 2024, 48(4): 1076−1085.
Huang W L, Yan J G, Ren L L, et al. Seismic impedance optimization inversion combining model inversion with deep learning inversion[J]. Geophysical and Geochemical Exploration, 2024, 48(4): 1076−1085.

[20] 梁立锋, 刘秀娟, 张宏兵, 等. 超参数对 GRU-CNN 混合深度学习弹性阻抗反演影响研究 [J]. 物探与化探, 2021, 45(1): 133−139.
Liang L F, Liu X J, Zhang H B, et al. A study of the effect of hyperparameters GRU-CNN hybrid deep learning EI inversion[J]. Geophysical and Geochemical Exploration, 2021, 45(1): 133−139.

[21] Chen T F, Gao G, Li Y G, et al. Shear-wave velocity prediction method via a gate recurrent unit fusion network based on the spatiotemporal attention mechanism[J]. Lithosphere, 2022, 2022(12): 4701851.

[22] 李艳辉, 陶悦. 嵌入注意力机制的时空网络设计及孔隙度可靠性预测 [J]. 石油地球物理勘探, 2025, 60(3): 555−563.
Li Y H, Tao Y. Design of spatio-temporal network embedded with attention mechanism and prediction of porosity reliability[J]. Oil Geophysical Prospecting, 2025, 60(3): 555−563.

[23] 翟晓岩, 高刚, 李勇根, 等. 融合注意力机制的二维卷积神经网络测井曲线重构方法 [J]. 石油地球物理勘探, 2023, 58(5): 1031−1041.
Zhai X Y, Gao G, Li Y G, et al. Reconstruction method of logging curves by 2D convolutional neural network integrating attention mechanism[J]. Oil Geophysical Prospecting, 2023, 58(5): 1031−1041.

## An intelligent log-based method for predicting shear wave velocity based on a cross-attention mechanism

LI Jin-Fu[1], SHEN Ya[1], WANG Shi-Cheng[1], WANG Yu-Hang[1], CHEN Da-Hong[1], ZHANG Guang-Zhi[2], CHEN Teng-Fei[2]

(1. *Changqing Branch of Geophysical Research Institute,BGP Inc.,CNPC, Xi'an* 710021, *China*; 2. *School of Geoscience, China University of Petroleum (East China), Qingdao* 266580, *China*)

**Abstract:** Shear wave velocity serves as a key parameter for characterizing the elastic properties of rocks and their sensitivity to fluids, playing a significant role in seismic wave impedance inversion, stratigraphic identification, and rock physics modeling. However, the lim-

itations in acquisition costs and technologies often lead to data gaps or insufficient accuracy for shear wave velocity. Hence, this study proposed an intelligent method for predicting shear wave velocity by integrating the two-dimensional convolutional neural network (2DCNN), a state-space model, and a cross-attention mechanism. The 2DCNN and the state-space model can capture local spatial features and longitudinal temporal dependencies, respectively, while the cross-attention mechanism enables the deep fusion of spatial and temporal features, thereby enhancing the sensitivity of the network to key geological information. Additionally, to improve model explainability, an explanatory analysis method based on Shapley additive explanations (SHAP) was employed to quantify the contributions of different log parameters to the shear wave velocity prediction. Experimental results demonstrate that the proposed method outperformed traditional individual neural networks in both prediction accuracy and generalization capability. Moreover, it effectively revealed the physical relationships between shear wave velocity and conventional log parameters. Therefore, the proposed method provides a novel approach and technical support for rapidly and reliably predicting shear wave velocity under complex reservoir conditions.

**Key words:** shear wave velocity; state-space model; cross-attention mechanism; Shapley additive explanations(SHAP)-based explainability; deep learning; neural network

（本文编辑: 叶佩）