

文章编号: 1001-1749(2023)03-0289-10

# 基于遗传算法优化深层神经网络的测井横波速度预测

刘涛<sup>1</sup>, 田仁飞<sup>1</sup>, 张伟<sup>2</sup>

(1. 成都理工大学 地球物理学院, 成都 610059;

2. 中国电建集团 贵阳勘测设计研究院有限公司, 贵阳 550081)

**摘要:** 实际生产中的测井横波资料通常很少或缺失, 在地震资料解释与处理中需进行要人工补足缺失的测井横波资料, 常规的线性回归方法得到的结果无法解释各种属性之间复杂的对应关系。随着机器学习的发展并被应用到地震数据处理等领域, 通过神经网络的非线性映射的能力可以弥补线性拟合横波速度上的不足, 并利用其优势进行横波预测, 但机器学习中仍存在过拟合或拟合能力不足问题。针对该问题选择遗传算法与高斯过程回归共同优化后的神经网络进行训练。实践表明: 与多元拟合和支持向量机回归相比, 结果的精度相对误差有所降低, 并用岩石物理测试获得的横波速度进行对比, 验证了该方法的可靠性。

**关键词:** 横波速度预测; 深度学习; 遗传算法

**中图分类号:** P 631.4 **文献标志码:** A **DOI:** 10.3969/j.issn.1001-1749.2023.03.02

## 0 引言

实际生产中, 由于测井资料的横波测量成本较高, 经常只测量部分井或部分井段的横波信息, 造成横波信息不完整, 然而横波信息是叠前地震反演<sup>[1]</sup>, AVO分析的重要条件<sup>[2]</sup>。对于缺失的信息需要人工进行重构, 目前重构的方法主要有: 经验公式拟合, 如 Castagna 和 Han 等<sup>[3-4]</sup>给出的砂岩储层 S 波速度经验公式, 以及 Pickeet, Milholland 等<sup>[5-6]</sup>给出的碳酸盐岩储层 P 波和 S 波速度的经验公式; 岩石物理拟合, 如 Xu-White<sup>[7-8]</sup>提出的砂岩储层 S 波预测模型和 Xu-Payne<sup>[9]</sup>提出的碳酸盐岩储层预测模型; 机器学习, 如神经网络<sup>[10]</sup>、支持向量机回归等<sup>[11]</sup>。基于经验公式拟合的数据很难从一个工区映射到另一个工区<sup>[12]</sup>, 基于岩石物理模型体现的是岩石本身的微观特征与岩石速度之间的联系, 但

建模所用参数难以确定, 使得预测具有多解性<sup>[13]</sup>。基于机器学习方法简单, 但是传统的机器学习没有考虑到测井曲线的时间序列特征, 不能真实反映储层的岩性和岩石的微观特征<sup>[14]</sup>, 而在机器学习的基础上发展而来的深度学习逐渐在各个领域成为热门研究对象, 各种神经网络也是层出不穷, 如卷积神经网络(CNN)、循环神经网络(RNN)、长短期记忆网络(LSTM)等。目前, 勘探地球物理领域, 诸多学者将神经网络应用到了不同方向, 如储层预测<sup>[15]</sup>、断层检测<sup>[16]</sup>等, 这些成功的应用案例, 为在神经网络的基础之上对横波速度进行预测提供了可借鉴的方案。因此, 这里重点研究了基于遗传算法优化后的深层神经网络, 并应用于横波速度预测中, 从神经网络结构的理论、工作流程、在神经网络中加入遗传算法与高斯过程回归的基础上, 结合实际测井资料进行了试算, 并与几种常用的横波速度预测方法进行对比, 认为基于遗传算法优化的深层神经网络在测

收稿日期: 2022-03-13

基金项目: 国家自然科学基金项目(41304080); 贵州省科技计划项目([2018]2814)

第一作者: 刘涛(1997-), 男, 硕士, 主要从事油气储层预测方面的研究, E-mail: lt2020020454@163.com。

通信作者: 田仁飞(1983-)男, 副教授, 主要从事地球物理信号处理、油气储层预测等方面的研究, E-mail: tianrenfei08@cdut.cn。

井横波速度预测上具有较好的效果,预测结果可靠。

## 1 方法原理

### 1.1 深层神经网络

深层神经网络的基本框架如图 1 所示,由输入层、隐含层、输出层组成,节点与节点的关系如图 2 所示, $x_1, x_2, x_3$  代表输出, $w$  代表权重表示可能性大小, $b$  代表偏置可以正确的分类样本, $f(x)$  代表激活函数,可以将输出结果限制在一定范围内,并对将输入与输出的关系转化为非线性映射的关系,常用的激活函数主要有 sigmoid, tanh, ReLU 公式为:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

$$f(x) = \max(0, x) \begin{cases} 0, x \leq 0 \\ x, x > 0 \end{cases} \quad (3)$$

式(1)、式(2)、式(3)中: $f(x)$ 为输入数据经过激活函数得到的输出; $x$ 为输出数据,如图 3 所示。这里选择的激活函数为 sigmoid,它的优点是可以将输出映射到(0, 1)之间,并且在计算反向传播时更加简单。神经网络第一个隐含层的节点与输入层的解析式表达为式(4)。

$$z_j^1 = f\left(\sum_{i=1}^{N_x} \omega_{i,j,1} x_i + b_{j,1}\right) \quad (4)$$

式中: $z_j^1$ 为隐含层网络结构上首层网络的第  $j$  个神经元, $j = 1, 2, 3, \dots, n$ ;  $N_x = 3$ ;  $x_i$ 为输入层网络的第  $i$  个神经元, $\omega_{i,j,1}$ 为输入层网络第  $i$  个神经元与首个隐含层网络上第  $j$  个神经元之间的权重大小。向后继续传播时,以  $z_j^1$ 作为下一层输入,对式(4)递归得其余隐含层的公式为式(5)。

$$z_j^k = f\left(\sum_{i=1}^{N_x} \omega_{i,j,k} x_i + b_{i,j,m}\right) \quad (5)$$

式中: $z_j^k$ 为第  $k(k > 1)$ 层,第  $j$  个神经元为隐含层网络中第  $k-1$ 层上包含的神经元总数; $\omega_{i,j,k}$ 为隐含层网络上  $k-1$ 层上的第  $i$  个神经元与第  $k$ 层上第  $j$  个神经元之间的权重大小。由式(5)进一步得到隐含层到输出层的公式为式(6)。

$$y_j = f\left[\sum_{i=1}^{N_z} \omega_{i,j,m} z_i^m + b_{i,j,m}\right] \quad (6)$$

式中: $y_j$ 为输出层网络第  $j$  个神经元; $m$ 为隐含层网络的总层数。结合式(4)~式(6)建立多层神经网络。

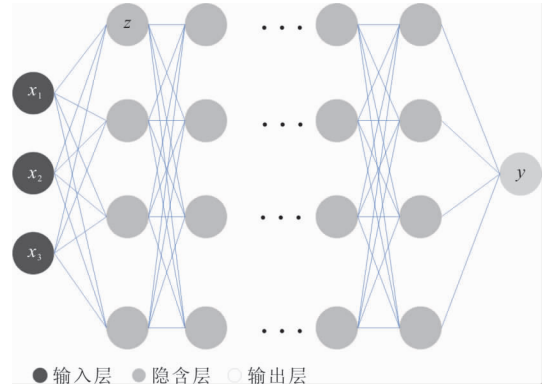


图 1 神经网络结构图

Fig. 1 The structure of neural networks




图 2 节点关系图

Fig. 2 Relationship of nodes

模型。

## 2 优化算法

### 2.1 网络结构优化

深层神经网络在用来预测时,网络内部的隐含层数与隐含层节点数都是未知的。一般来说,可以应用经验法与试错法进行调整,但是会花去大量的时间。对于小型网络,可以选择网格搜索法来确定最优的参数,但是随着网络层数与节点数的增加,网格搜索法工作量会急剧增加,并且由于步长的选择也是随机的,大步长选择会减少运算时间,但会容易漏掉最优结果;小步长则会增加巨量的工作,并且容易陷入局部最小,无法找到全局最优解。这里选择随机搜索法加高斯过程回归,对随机搜索得到的结果通过高斯过程回归确定趋势模型,在将所有的超参数组合输入模型找出最优解,可以避免随机搜索是被漏掉的最优解,以及缩短传统网格搜的时间。如图 4 所示为随机搜索原理示意图。如图 5 所示,对参数空间进行随机搜索,可以看出随机搜索得到




图 3 激活函数图

Fig. 3 Activation

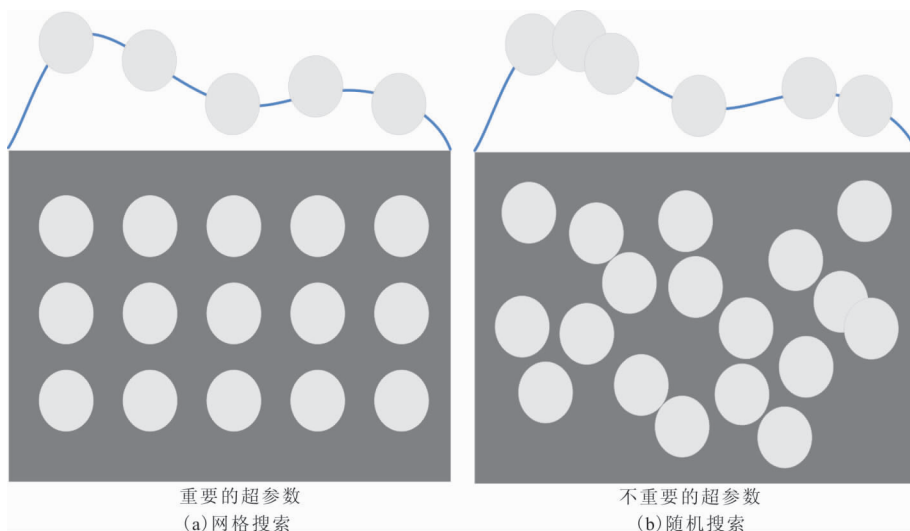


图 4 超参数搜索示意图

Fig. 4 The hyper-parameter search strategy




图 5 超参数随机搜索结果

Fig. 5 The hidden layers and nodes are determined by random hyperparameter search




图 6 高斯过程回归预测结果

Fig. 6 Gaussian process regression prediction results

的结果一致性不强,层内节点数与均方根误差的关系不够明确,层数的增加与均方根误差的关系同样不明显,所以本文搜索结果进行高斯过程回归确定关系(图 6)。可以看出,随着网络层数的增加均方根误差在初见减少,并且层内神经网络的节点数与均方根

误差的关系为先减小后增大,所以选择的网络层数为 3 层,每层 14 个节点。

### 2.2 遗传算法

神经网络内部除了隐含层数与节点数还需待解决的就是权重与偏置,经典的 BP 算法(Back Propagation),正向运算之后,真实值与预测值进行比较

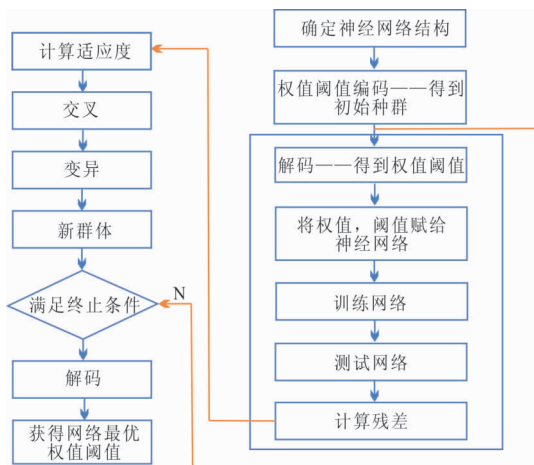


图 7 遗传算法示意图

Fig. 7 Genetic algorithm

后进行反向传播修正权值与偏置,称之为反向传播算法,但是该算法训练时间较长,容易陷入局部极小值,以及学习新样本容易遗忘旧样本的趋势等显而易见的不足之处,这里采用遗传算法对权值与偏置进行优化,从而避免了 BP 网络在优化权值和阈值时陷入局部最优的缺点。遗传算法(Genetic Algorithms)是对自然界中的物种进化规律模拟形成的一种寻优算法。它把自然界物种进化方式引入,将待优化的参数定义为种群,种群通过不停的繁衍,并通过适应度函数对种群中适应度好的个体进行保留,这样循环往复,种群中的个体在不断被优化,直到满足我们所需要的停止条件(图 7)。将权值与偏置编码通过遗传算法进行,在满足条件后将优化好的权值与偏置赋值于神经网络之上,从而避免传统神经网络的缺点。

### 3 应用实例

以重庆合川地区测井横波预测为研究对象,目标层段为震旦系灯影组灯四段。震旦系灯影组的地层以碳酸盐岩为主,储集空间以缝洞型为主<sup>[17]</sup>。碳酸盐岩储层组成的主要成分为白云岩,其上的盖层为石灰岩,白云岩储层发育时阻抗会大大降低,且储集类型主要为裂隙—孔洞型,储层孔隙度小,因此使得含气层与其围岩的差异并不明显,并且地震相应较弱,储层含气性评价困难<sup>[18]</sup>。

#### 3.1 灯影组测井地球物理特征

灯影组埋深 5 080 m~5 920 m。自下而上分为四个层段,如图 9 所示。

1)灯一段厚度为 20 m~100 m,主要的岩性特

征为粉晶白云岩,含藻纹层云岩,少量膏岩。物性特征:伽马高值,下部有大齿状;电阻率曲线呈低平或齿状。

2)灯二段厚度为 180 m~480 m,主要的岩性特征为微晶白云岩,含少量藻类,泥粉晶白云岩,富含藻类。物性特征:伽马值低平,夹有小齿状;电阻率特征为高值,曲线多小齿状,少有大齿状。

3)灯三段厚度为 20 m~60 m,主要的岩性特征为深色泥页岩,夹杂有白云岩。物性特征:伽马高值,曲线呈大齿状;电阻率低值,曲线呈小齿状。

4)合川地区灯四段碳酸盐岩非均质性强。横向变化快,灯四段厚度为 260 m~350 m,主要岩性特征为台内丘滩微相白云石,方解石含量较高,台内泻湖微相白云岩表现较高的石英、泥质及硬石膏含量。物性特征:伽马低值,曲线特征以平直为主,其中偶有小齿状;电阻率高值,曲线呈大小齿间互,密度均值为  $2.38 \text{ g} \cdot \text{cm}^{-3}$ ,X4 井目标层段纵横波速度受矿物组分影响明显,岩芯样品中石英,方解石,黏土含量增加时纵波速度有明显的降低,高硅质,泥质含量的云岩形成低速带,且目标层段速度受孔隙影响明显,从岩芯取样来看储层段对应裂隙—孔隙储层,纵波速度均值为  $5\,932 \text{ m} \cdot \text{s}^{-1}$ ,孔隙度均值为 5.98%。

这里选择合川地区 X1 井、X2 井、X3 井作为训练数据训练神经网络模型,并选择 X4 井作为预测井验证模型的可靠性。训练井数据如图 8 所示,测试井数据如图 10 所示。

#### 3.2 数据处理

不同的测井数据之间的量纲是不统一的,不同的量纲在进入神经网络训练会影响神经网络对各种属性的权重分配,因此需要对测井数据进行无量纲化处理。通常的数据处理方式有标准化与归一化处理,其表达式为式(7)、式(8)。

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

$$x^* = \frac{x - \mu}{\sigma} \quad (8)$$

式(7)中: $x^*$ 为归一化处理后的数据; $x$ 为未处理数据, $x_{\max}$ 为未处理数据最大值; $x_{\min}$ 为未处理数据最小值。

式(8)中: $\mu$ 为所有样本数据的均值; $\sigma$ 为所有样本数据的标准差。标准化处理是将一系列数据缩放到均值为“0”,标准差为“1”,归一化则是将一系列数据的数值特征缩放到某个区间,通常为(0,1)之间。这里所采用的数据预处理的方式归一化前后的数据(图 11)。




图 8 训练井数据

Fig. 8 Data of training well



图 9 灯影组地层柱状图

Fig. 9 Stratigraphic column of Dengying formation

### 3.3 实验流程

实验流程如图 12 所示,首先是对测井数据的预处理,然后对神经网络进行迭代优化,最后将神经网络预测横波的结果与其他方法进行对比说明其优势。

### 3.4 结果评价

本次试验所选择的数据为重庆合川地区 X<sub>1</sub>、X<sub>2</sub>、X<sub>3</sub>、X<sub>4</sub>,由于测井数据中,包含众多属性,不同测井之间所含有的信息又不相同,所以选择四口井都包含的纵波、密度、伽马、孔隙度作为输入,横波作




图 10 横波预测结果(538 m~5 720 m)

Fig. 10 Shear wave prediction results of neural network optimized by genetic algorithm

为输出,选择训练的井为 X1、X2、X3 共 9 246 个样本点,以 X4 井作为预测样本,共 2 689 个样本点,预测深度为 5 384 m~5 720 m,另选取支持向量机回归(SVR) [11],多元回归预测[19]作为对比说明试验结果的可靠性。采用均方根误差(RMSE)、平均绝对百分比误差(MAPE)两个评价标准对模型的可靠性进行评价[20-21]。RMSE 是误差的平均值,MAPE 是绝对误差的范围为 0~1,越接近 1,预测体现预测值与真实值之间的偏差越接近 0 表示误差越小结果越好。具体公式如下:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (9)$$

$$MAPE = \frac{100\%}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (10)$$

式中: $\hat{y}_i$  为预测数据; $y_i$  为实测数据; $m$  为样本点数。

## 4 结果讨论

从图 10 中可以看出,所用方法的误差更小且拟合效果更好,并在主要含气层段 5 445 m~5 570 m 处开窗显示,如图 13 所示,并进行精度对比见表 1。从表 1 中的两项评价参数对比显示可以看出,在

全井段和含气段的均方根误差、相对误差均值结果所用方法的优势明显大于另外两种方法。

为了验证方法的可靠性,利用 X4 井的岩芯样品进行岩石物理测试,获得目标层段纵横波速度,将纵波速度与横波速度做交会图(图 14)。通过图 14 可以得到,纵横波速比的关系为:灯四段储层云岩横波速度为: $V_s = 0.37V_p + 1 223$ ;泥质,灰质云岩横波速度为: $V_s = 0.65V_p - 696.3$ ;硅质云岩的横波速度为: $V_s = 0.21V_p + 2 286$ 。如图 15 所示,在 5 445 m~5 458 m 由于岩性发生变化导致拟合的相关性有所下降,在 5 458 m~5 580 m 处本文方法得到的横波速度与岩石物理得到的横波速度基本重合,总体相关系数为 0.93,证明本文所用方法的精度较高。

表 1 多种方法横波预测精度对比

Tab. 1 Comparison of shear wave prediction accuracy of these methods

指标	层段	支持向量机	多元回归	神经网络
RMSE	全井段	129.59	128.17	116.78
	含气段	89.22	93.19	89.33
MAPE/%	全井段	2.80	2.86	2.27
	含气段	2.12	2.16	2.08




图 11 输入样本归一化

Fig. 11 Sample normalization

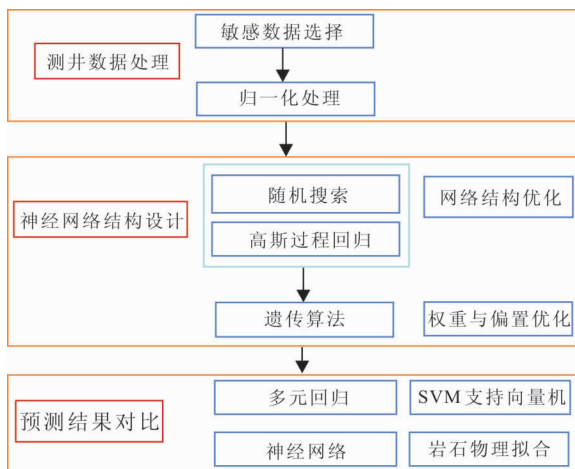


图 12 实验流程图

Fig. 12 Experimental flow chart

### 5 结论

笔者应用遗传算法优化的深层神经网络对横波速度进行预测,在预测过程中对网络结构应用高斯过程回归优化,权重与偏置应用遗传算法进行优化,使得整个网络拟合效果更好。随后对实际横波速度进行预测,并用支持向量机与多元回归进行对比实验,验证了本文所用方法取得更好的效果,并且与岩石物理测试拟合的横波速度在储层部分基本一致,因此本文建立了一种可行的测井横波速度预测方法。但是方法所用的模型为全连接网络模型,没有




图 13 三种横波预测方法效果对比深度 (5445 m~5570 m)  
 Fig. 13 The effects of three S-wave prediction methods(5445~5570)




图 14 纵横波交会图  
 Fig. 14 The Crossplot of P-wave and S-wave




图 15 与岩石物理测试对比(5 445 m~5 570 m)  
 Fig. 15 Compared with the shear wave velocity from petrophysical testing (5 445 m~5 570 m)

与其他的网络模型进行对比,在后续的工作中会不断完善这部分的工作。

参考文献:

[1] 杨建礼,高利君,李俊,等.基于横波分裂思想的横波速度方位各向异性反演[J].石油物探,2021,60(02):261-271.  
 YANG J L, GAO L J, LI J, et al. Inversion of shear-wave velocity azimuthal anisotropy based on shear-wave splitting[J]. Geophysical Prospecting for Petroleum, 2021,60(2):261-271. (In Chinese)

[2] 邓勇,刘仕友,李洋森,等.莺歌海盆地东方区纵横波速度变化对 AVO 类型的影响[J].天然气地球科学,2019,30(09):1378-1385.  
 DENG Y, LIU SY, LI Y S, et al. Analysis of the influence of P-S wave velocity variation on AVO type in the Dongfang area, Yinggehai basin[J]. Natural Gas Geoscience, 2019,30(09):1378-1385. (In Chinese)

[3] 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.

- [4] HAN D, NUR A, MORGAN D. Effects of Porosity and clay content on wave velocities in Sandstones[J]. *Geophysics*, 1986, 51(11):2093-2107.
- [5] PICKETT, G. R. Acoustic character logs and their applications in formation evaluation[J]. *Journal of Petroleum Technology*, 1963, 15(06):659-667.
- [6] MILHOLLAND P, MANGHNANI M H, SCHLANGER S O, et al. Geoacoustic modeling of deep-sea carbonate sediments[J]. *Journal of the Acoustical Society of America*, 1980, 68(5):1351-1360.
- [7] XU S Y, R. E. WHITE. A new velocity model for clay-sand mixtures[J]. *Geophysical Prospecting*, 1995, 43(1):91-118.
- [8] XU S Y, R. E. WHITE. A physical model for shear-wave velocity prediction[J]. *Geophysical Prospecting*, 1996, 44(4):687-717.
- [9] XU S Y, MICHAEL A, PAYNE. Modeling elastic properties in carbonate rocks[J]. *Geophysics: the Leading Edge of Exploration*, 2009, 28(1):66-74.
- [10] WANG J, CAO J, YUAN S. Shear wave velocity prediction based on adaptive particle swarm optimization optimized recurrent neural network[J]. *Journal of Petroleum Science and Engineering*, 2020, 194(5):1-16.
- [11] BAGHERIPOUR P, GHOLAMI A, ASOODEHM, et al. Support vector regression based determination of shear wave velocity[J]. *Journal of Petroleum Science and Engineering*, 2015(125):95-99.
- [12] ZHANG B, JIN S G, LIU C, et al. Prediction of shear wave velocity based on a statistical rock-physics model and bayesian theory[J]. *Journal of Petroleum Science and Engineering*, 2020, 195(1):1-14.
- [13] QIN R D, PAN H P, ZHAO P Q, et al. Petrophysical parameters prediction and uncertainty analysis in tight sandstone reservoirs using Bayesian inversion method[J]. *Journal of Natural Gas Science and Engineering*, 2018(55):431-443.
- [14] ZHANG Y, ZHONG H R, WU Z Y, et al. Improvement of petrophysical workflow for shear wave velocity prediction based on machine learning methods for complex carbonate reservoirs[J]. *Journal of Petroleum Science and Engineering*, 2020, 192(5):1-14.
- [15] 姜振海. 基于分频智能反演的储层预测研究—以大庆黑鱼泡南部探区为例[J]. *地质科学*, 2021, 56(04):1052-1061.
- JIANG Z H. Research on reservoir prediction based on frequency-divided intelligent inversion: A case study from southern exploration area of Heiyupao in Daqing[J]. *Chinese Journal of Geology*, 2021, 56(04):1052-1061. (In Chinese)
- [16] 杨午阳, 杨佳润, 陈双全, 等. 基于 U-Net 深度神经网络的地震数据断层检测[J]. *石油地球物理勘探*, 2021, 56(04):688-697.
- YANG W Y, YANG J R, CHEN S Q, et al. Seismic data fault detection based on U-Net deep learning network[J]. *Oil Geophysical Prospecting*, 2021, 56(04):688-697. (In Chinese)
- [17] 文菁菁. 川中合川—广安地区震旦系灯影组含油气评价[D]. 成都:西南石油大学, 2015.
- WEN J J. Petroleum evaluation of sinian dengying formation in hechuan-guang'an area, central sichuan[D]. Chengdu: Southwest Petroleum University, 2015. (In Chinese)
- [18] 曹俊兴, 薛雅娟, 田仁飞, 等. 深层碳酸盐岩储层含气性检测方法技术研究[J]. *石油物探*, 2019, 58(01):9-16.
- CAO J X, XUE Y J, TIAN R F, et al. Advances in hydrocarbon detection in deep carbonate reservoirs[J]. *Geophysical Prospecting for Petroleum*, 2019, 58(1):9-16. (In Chinese)
- [19] HABIB A, MOHAMMAD G, GHOLAM-REZA L. Prediction of shear wave velocity using artificial neural network technique, multiple regression and petrophysical data: a case study in Asmari reservoir (SW Iran)[J]. *Open Journal of Geology*, 2014, 4(7):303-313.
- [20] DANIAL B, KAVEH A, RAHIM M S. Modeling of

shear wave velocity in limestone by soft computing methods[J]. International Journal of Mining Science and Technology, 2017, 27(03): 423-430.

shear-wave velocity prediction for sedimentary rocks [J]. Journal of Natural Gas Science and Engineering, 2020, 76(C): 1, 3084-103084.

[21] OLALERE OLORUNTOBI, STEPHEN BUTT. The

## Shear wave velocity prediction based on deep neural network optimized by genetic algorithm

LIU Tao<sup>1</sup>, TIAN Renfei<sup>1</sup>, ZHANG Wei<sup>2</sup>

(1. College of Geophysics, Chengdu University of Technology, Chengdu 610059, China;

2. Power China Guiyang Engineering Corporation Ltd., Guiyang 550081, China)

**Abstract:** The logging s-wave data are usually few or missing in production. In seismic data interpretation and processing, it is necessary to supplement the missing logging shear wave data manually. The results of conventional linear regression methods can not explain the complex correspondence among various attributes. However, with the development of machine learning and its application in seismic data processing and other fields, the ability of nonlinear mapping of neural networks can make up for the deficiency of linear fitting of shear wave velocity and make use of its advantages to predict shear wave. However, machine learning algorithm has the problem of over-fitting or insufficient fitting ability for fitting problems. This paper selects the neural network optimized by genetic algorithm and Gaussian process regression for training. The practice shows that compared with multivariate fitting and support vector machine regression, the accuracy relative error of the results used in this paper is reduced and compared with the shear wave velocity from petrophysical testing, which confirms the practical value of this method.

**Keywords:** shear wave prediction; deep learning; genetic algorithm