

文章编号:1009-9603(2022)01-0080-10

DOI:10.13673/j.cnki.cn37-1359/te.2022.01.010

基于深度前馈神经网络方法的横波速度预测

王树华,杨国杰,穆 星

(中国石化胜利油田分公司 勘探开发研究院,山东 东营 257015)

摘要:针对横波速度预测问题,在分析经验公式法和岩石物理建模法优缺点的基础上,结合横波速度预测原理,提出基于深度前馈神经网络方法(DFNN)进行横波速度的预测。研究从纵、横波速度关系入手,详细阐述了DFNN方法应用于横波速度预测的可行性,并介绍了该深度学习方法的原理;选择声波时差、密度、中子孔隙度、泥质含量、孔隙度5个储层参数与横波速度进行深度神经网络训练,建立可靠的横波速度预测模型。将该模型应用于不同研究区的横波速度预测,结果表明基于DFNN方法预测横波速度能够有效提高预测的精度和效率,适用范围广,可以为叠前AVO分析、叠前反演提供可靠的横波数据,具有较高的实际应用价值和推广意义。

关键词:横波速度预测;深度前馈神经网络方法;深度学习;储层参数;预测模型

中图分类号:TE319

文献标识码:A

S-wave velocity prediction based on deep feedforward neural network

WANG Shuhua, YANG Guojie, MU Xing

(Exploration and Development Research Institute, Shengli Oilfield Company,
SINOPEC, Dongying City, Shandong Province, 257015, China)

Abstract: Given the shear wave (S-wave) velocity prediction problem, the advantages and disadvantages of the empirical formula method and petrophysical modeling were analyzed, and the principle of s-wave velocity prediction was discussed. On this basis, this paper proposed a deep feedforward neural network (DFNN) for S-wave velocity prediction. Starting with the relationship between compressional wave (P-wave) and S-wave velocities, this study expounded the feasibility of applying the DFNN to S-wave velocity prediction and explained the principle of this deep learning method. Five reservoir parameters (acoustic time difference, density, neutron porosity, shale content, and porosity) were chosen for deep neural network training with S-wave velocity, and a reliable S-wave prediction model was thereby built. The model was applied to S-wave velocity prediction in different research areas, and the results show that DFNN-based S-wave velocity prediction achieves effectively improved prediction accuracy and efficiency and has a wide application range. It can provide reliable S-wave data for pre-stack amplitude-versus-offset (AVO) analysis and pre-stack inversion, so it is worth practical application and promotion.

Key words: S-wave velocity prediction; DFNN; deep learning; reservoir parameter; prediction model

具备横波速度测井资料是利用叠前AVO分析技术、叠前反演技术进行储层及储层流体预测的一个基本前提^[1-2]。但是在油田实际勘探开发生产过程中,由于成本问题等多方面因素很少采集横波测

井数据。这就导致了在开展基于叠前地震数据的地球物理技术应用时,因为受到横波测井资料的制约而面临很大困难。在这种情况下,利用常规测井资料进行横波速度的预测成为研究的热点,众多学

收稿日期:2021-11-11。

作者简介:王树华(1973—),男,山东济宁人,高级工程师,博士,从事储层地球物理和大数据及人工智能技术研究。E-mail:wangshuhua061.slyt@sinopec.com。

基金项目:中国石化科技攻关项目“基于大数据技术的油藏精细表征方法研究”(P20071-1)。

者开展了横波速度预测方法的研究^[3-5]。目前,横波速度预测方法主要有2种:经验公式法和岩石物理建模法。经验公式法简单易用,但是估算精度不高,且受区域限制;而岩石物理建模法虽然估算精度较高,但是流程复杂、参数繁多,操作难度大,实际应用效率不高。近年来,人工智能技术发展迅速,也正在被逐渐引入石油行业,特别是神经网络方法在测井解释^[6-7]、油气藏开发^[8-11]等方面都取得了不错的应用效果。为此,笔者从现有横波速度预测的方法和原理出发,通过分析经验公式和岩石物理建模2种方法的优缺点,讨论了横波速度预测的原理,在此基础上引入人工智能领域的深度学习方法,提出基于DFNN方法预测横波速度,并通过实例研究,认为该方法可以提高横波速度估算的精度和效率,具有较高的推广应用价值。

1 传统横波速度预测方法原理及优缺点

1.1 经验公式法

经验公式法是在通过实验室数据研究岩石的纵波速度和横波速度变化规律的过程中,建立两者之间的拟合关系式。例如CASTAGNA等利用实验室测量的水饱和砂岩和页岩的纵波速度和横波速度,拟合出二者的线性方程^[12-14];HAN等根据实验室超声波数据拟合出描述纵波速度和横波速度的关系式^[15]。利用这些公式,可以快速地计算出一个工区内的横波速度,因为几乎所有的井都会测量纵波速度曲线。但需要注意的是,这些经验公式都是在特定区域内通过对实验室测量数据的统计分析建立起来的,简单直接引用可能会产生较大误差^[16]。

1.2 岩石物理建模法

岩石的纵波速度和横波速度等物理性质是由岩石的组成部分、各组成部分之间的结构即岩石内部结构以及岩石所处的温度和压力环境所决定的。对于实际的地下岩石来说,其组成部分包括矿物、孔隙度、胶结物等均非常复杂;岩石的内部结构包括矿物颗粒的大小、形状、排列方式等也是非常复杂的,难以准确求解其物理性质。

岩石物理建模法是通过一定的假设条件将实际地下岩石等效为理想介质,从而使用物理学原理计算其物理性质^[17]。前人在开展岩石物理研究过程中,提出了多种岩石物理模型,包括Voigt-Reuss-Hill模型^[18-20]、Hashin-Shtrikman模型^[21]、DEM模

型^[22]、Wyllie方程^[23]、Gassmann方程^[24]和Xu-White模型^[25]等。其中,Xu-White模型是一种广泛应用的经典岩石物理模型,该模型将岩石等效为岩石基质、岩石骨架、孔隙充填物及饱和岩石4个部分。岩石基质为组成岩石的矿物混合物,岩石骨架是指岩石中去除孔隙内流体之后的部分,饱和岩石即为岩石骨架孔隙中充满油、气、水等流体或固体充填物,也就是地下岩石实际的存在状态。使用Xu-White模型开展岩石物理建模并估算横波速度的过程就是选择合适的理论模型分别求解4个部分的弹性模量,然后利用岩石物理理论公式将饱和岩石的弹性模量转换为横波速度。许多地球物理工作者在开展叠前反演时都选择使用Xu-White模型进行横波速度的估算^[26-27]。使用Xu-White模型开展岩石物理建模进行横波速度预测的关键在于准确给出岩石的矿物种类(如石英、长石、高岭石等)及其含量、孔隙度、孔隙结构(一般用孔隙纵横比表示)、孔隙流体类型及其占比、原油密度、地层水矿化度、地层温度、地层压力等参数^[28]。

由此可见,利用岩石物理建模法进行横波速度预测涉及岩石物理学、沉积岩石学、测井地质学等多种学科的知识以及岩心分析化验、地层测试、油气生产数据等多方面的信息。其优势在于该方法有严格的理论基础和准确的物理意义,但其缺点也十分明显,即对研究人员的多学科、多专业的掌握程度及综合运用能力要求很高,且由于参数多、流程复杂导致效率较低。此外,由于涉及因素和环节较多,不可避免地会产生误差,可能会由于误差累积而使得最终计算结果不理想。

2 基于DFNN方法预测横波速度的提出

前人在利用实验室测量数据研究岩石的纵波速度和横波速度变化规律时,发现二者存在较好的相关性。利用一元一次方程的线性公式往往可以较好地拟合二者之间的关系。HAN利用经验公式对不同黏土含量、不同孔隙度的样品进行了纵、横波速度关系的拟合,取得了较好的效果^[15]。

在实际应用中,岩石物理建模法预测的横波速度与实测横波速度往往存在较大误差。学者们也逐渐意识到纵波速度与横波速度之间的简单线性拟合并不能准确建立二者之间的关系,因此不断寻求合适的方法提高二者之间关系描述的精度。1992年,李庆忠建立了纵波速度与横波速度之间的

抛物线公式^[29]。2014年,李文成等提出利用多元拟合的方法,通过加入自然伽马、密度等测井曲线进一步强化纵、横波速度之间的相关性,从而提高横波速度的预测精度^[30]。岩石物理建模法虽然从更加微观的角度考虑岩石的组分和结构并建立等效模型,进而用物理学的方法推导出岩石的纵、横波速度,但对于岩石组分(矿物类型和含量)和结构(主要是孔隙纵横比)来说,虽然可以通过岩心分析化验获得比较精确的结果,但是全井段的分析数据仍需通过对测井曲线的解释来获取。例如利用自然伽马(*GR*)、自然电位(*SP*)、补偿中子(*CNL*)、密度(*DEN*)等测井曲线解释获得泥质含量曲线,利用声波时差(*AC*),*CNL*,*DEN*等测井曲线解释获得孔隙度曲线,利用孔隙度曲线确定全井段孔隙纵横比^[31]等。因此,岩石物理建模法最终还是间接使用测井曲线对横波速度进行预测。

由此可见,无论是经验公式法还是岩石物理建模法,其本质都是直接或间接建立测井曲线(储层参数)与横波速度之间的关系,从而实现横波速度的预测。如果能有一种更好的方法用于建立测井曲线(储层参数)与横波速度之间的关系,那么必将提高横波速度预测精度,从而提高叠前AVO技术及叠前反演技术的实际应用效果。

近年来,大数据及人工智能技术飞速发展,已经在图像识别、语音识别等多个领域成功应用并获得重大突破^[32]。以卷积神经网络(CNN)、循环神经网络(RNN)和DFNN为代表的深度学习方法可以深度挖掘数据之间的联系,实现对目标数据的精准预测。这恰恰为我们建立储层参数与横波速度之间

的关系提供了一种新的思路和解决方案。

3 基于DFNN方法预测横波速度的原理

深度学习是指使用深层神经网络实现数据拟合的一种机器学习方法^[33]。相对于浅层学习而言,通常是具有多层结构(多个隐含层的)神经网络。深度学习的本质是模拟人脑的分层结构,对外部输入的各种类型的数据(包括声音、图像、文本等)进行从低级到高级的特征提取,实现对外部数据的预测和识别^[34-35]。

基于DFNN方法预测横波速度,具体步骤如下:首先利用DFNN方法建立多条测井曲线与实测横波速度的训练模型;然后利用该模型对横波速度进行预测,并对比预测横波速度与实测横波速度的吻合度,在此过程中通过调整DFNN模型的隐藏层个数、神经元数量等参数优化训练模型,直至预测横波速度与实测横波速度的吻合度较高且稳定,即为最终的深度学习横波速度预测模型。

3.1 DFNN方法的原理

以具有2个隐藏层和1个输出层的三层DFNN模型为例(图1)。输入层为训练样本的特征空间,即用于预测横波速度的储层参数,如果选择使用2个储层参数,则可以用1个二维列向量 $[x_1, x_2]^T$ 表示。在实际应用中,输入层的储层参数越多,其维度越高。

利用DFNN方法进行横波速度模型训练时,针对每个输入数据以及经过神经元后输出的结果,研

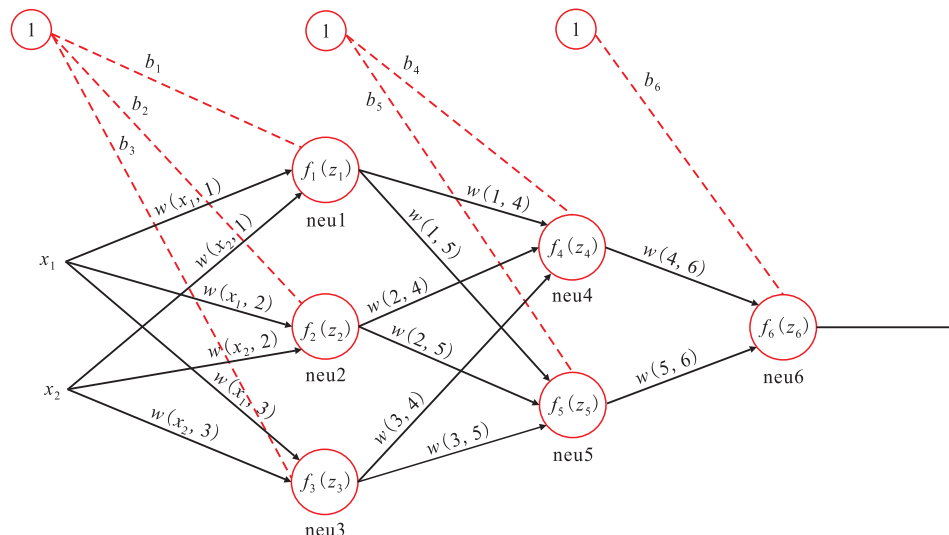


图1 DFNN方法原理示意
Fig.1 Principle of DFNN

究采用 Xavier 初始化方法^[36],随机产生对应的权重系数 w 和偏置项 b (图 1)。每个神经元激活函数选择使用 Sigmoid 函数,其表达式为:

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

向前传播的过程中,所有输入层数据以加权平均的形式输入到第 1 个隐藏层中的每个神经元,则第 1 个隐藏层中 3 个神经元 neu1, neu2 和 neu3 的输入数据分别表示为:

$$z_1 = w(x_{1,1})x_1 + w(x_{2,1})x_2 + b_1 \quad (2)$$

$$z_2 = w(x_{1,2})x_1 + w(x_{2,2})x_2 + b_2 \quad (3)$$

$$z_3 = w(x_{1,3})x_1 + w(x_{2,3})x_2 + b_3 \quad (4)$$

经过逻辑函数非线性转换处理后,第 1 个隐藏层中 3 个神经元的输出结果分别为 $f_1(z_1), f_2(z_2), f_3(z_3)$, 其加权平均的结果作为下 1 个隐藏层中神经元的输入数据。因此,第 2 个隐藏层中 2 个神经元的输入数据分别为:

$$z_4 = w_{(1,4)}f_1(z_1) + w_{(2,4)}f_2(z_2) + w_{(3,4)}f_3(z_3) + b_4 \quad (5)$$

$$z_5 = w_{(1,5)}f_1(z_1) + w_{(2,5)}f_2(z_2) + w_{(3,5)}f_3(z_3) + b_5 \quad (6)$$

同理,第 2 个隐藏层中 2 个神经元的输出结果分别为 $f_4(z_4)$ 和 $f_5(z_5)$, 其加权平均之和作为输出层神经元 neu6 的输入数据,即:

$$z_6 = w_{(4,6)}f_4(z_4) + w_{(5,6)}f_5(z_5) + b_6 \quad (7)$$

经过输出层之后,即可得到最终的预测结果 $f_6(z_6)$ 。

3.2 目标函数的构建

上述神经网络输出的最终结果是基于真实初始化的 w 和 b 所得到的,为使最终的输出结果与真实数据之间达到最小二乘误差,需要构建一个以 w 和 b 为自变量的函数,使预测数据与真实数据之间的误差的平方和最小:

$$\text{Min } g(b, w) = \sum_{i=1}^n (y_i - x_i)^2 \quad (8)$$

对该函数进行求解,通常采用的数值优化方法主要有基于一阶泰勒级数展开的梯度下降法(最速下降法)、基于二阶泰勒级数展开的牛顿法,以及介于二者之间的共轭梯度法。

梯度下降法(最速下降法)利用的是一阶泰勒展开式,基本思路为从初始点出发,采用一阶线性逼近,沿着负梯度方向移动一段距离,然后跳回到原函数,如此反复,直至收敛。其中,将每次下降的步长称为学习率。最速下降法越接近目标值时,学

习率越小,前进越慢。

牛顿法与梯度下降法相同,也是在每一步利用逼近来降低函数值。尽管牛顿法也是利用泰勒级数展开,但采用的是二次逼近,其从初始点出发,通过重复构造函数的二次逼近,移动至这个二次方程的驻点并跳回到原函数来进行优化。因为牛顿法的每一步都使用二次逼近,而二次方程可以更好地模拟相关函数,所以牛顿法比梯度下降法收敛更快。但牛顿法每次迭代都需计算和存储 Hessian 矩阵,因此计算量较大。

共轭梯度法是介于最速下降法与牛顿法之间的一种方法,它仅需利用一阶导数信息,克服了最速下降法收敛慢的缺点,避免了牛顿法需要存储和计算 Hessian 矩阵并求逆的缺点,共轭梯度法的每一个搜索方向是互相共轭的。在各种优化算法中,共轭梯度法收敛快、稳定性高,且不需要任何外来参数。

综上所述,研究采用共轭梯度法进行数值优化,当迭代次数达到设定的次数时,停止迭代。

4 应用效果分析

4.1 数据准备

收集渤海湾盆地济阳拗陷多个油田共 10 口井的实测横波速度测井数据(编号为 E1—E10),同时收集了这 10 口井的常规测井曲线(包括 GR, SP, AC, CNL 等)及解释的储层参数曲线(孔隙度和泥质含量)。本次研究主要针对碎屑岩地层,这 10 口井钻遇的碎屑岩地层具有实测横波速度测井数据的深度从 500 ~ 1 000 m 不等。选用 10 口井累积长度为 5 000 m 的实测横波速度测井数据作为样本数据(共计 40 000 个实测样本点)。

4.2 关键参数设置

横波速度预测模型建立的第 1 个关键在于输入层的设置,即选择使用哪些测井曲线建立与横波速度的关系,这关系到样本的合理性和可靠性。CASTAGNA 等提出,在已知岩性的条件下,对于高黏土含量的砂岩和较纯的砂岩,可以对经验关系式进行微调以使其分别对这 2 种类型的砂岩更好地拟合^[6]。HAN 对 70 个饱含水含泥砂岩的超声波实验室数据进行统计分析,发现将这些数据按照黏土含量进行分类(大于 25% 和小于 25%)和按照孔隙度进行分类(大于 15% 和小于 15%)时,所拟合出的纵、横波速度经验公式是不同的^[9]。这表明纵波速度与横波速度的关系是随着黏土含量、孔隙度的变

化而发生变化的。因此,在建立测井曲线与实测横波速度的关系时,除了选择纵波速度之外,考虑黏土含量和孔隙度,可以更加准确地预测横波速度。*GR*和*SP*测井曲线等虽然能够反映岩石的黏土含量,但受放射性矿物及泥浆的影响,不同地区具有较大的差异,不适合用来构建样本。而*DEN*和*CNL*测井曲线也可以反映岩石的孔隙度和黏土含量,且不受放射性矿物和泥浆环境影响。因此,最终确定利用 V_p , *DEN*, *CNL*, 测井解释泥质含量(*SH*)和测井解释孔隙度(*POR*)共5条曲线构建与实测横波速度的DFNN训练模型。

此外,在构建基于DFNN方法的横波速度预测模型时,对隐藏层个数、神经元个数、迭代次数等主要参数进行了大量测试。通过对比计算效率和预测结果的精度,最终选择使用3个隐藏层、6个神经元、迭代200次的DFNN训练模型参数。

4.3 预测精度分析对比

在研究过程中采用不同的模型训练方法,包括采用全部10口井训练并预测,以及采用多数井训练、少数井验证的方法。以选择9口井进行训练、1口井(E2)验证的方法为例,分析基于DFNN方法的

横波速度预测结果的精度,并与经验公式法、岩石物理建模法和多元回归方法的横波速度预测结果进行对比。结果(图2—图5)表明,经验公式法最不稳定,E2和E4井的预测横波速度与实测横波速度吻合较好,而E1和E3井的预测横波速度与实测横波速度吻合较差,这是因为经验公式法依赖于经验公式的系数,不同地区的系数存在差异。岩石物理建模法预测的结果稍好,但是该方法通常仅针对某一目的层段,超出目的层段的部分由于岩石物理参数不同,会导致预测的横波速度误差较大(如E2井的2380~2880 m)。多元回归方法以及基于DFNN方法的横波速度预测结果与实测横波速度吻合的程度都非常高,但是对未参与回归模型建立和训练的E2井,基于DFNN方法的横波速度预测结果比多元回归方法获得的结果更可靠。

对不同方法的预测结果进行量化分析,结果(表1)表明,基于DFNN方法的横波速度预测结果的精度最高,平均相对误差约为5.1%。

4.4 泛化能力分析

为了进一步验证基于DFNN方法预测横波速度的适用性,也就是横波预测模型的泛化能力,将基




图2 E1井横波速度预测结果

Fig.2 Results of S-wave velocity prediction in Well E1




图3 E2井横波速度预测结果

Fig.3 Results of S-wave velocity prediction in Well E2

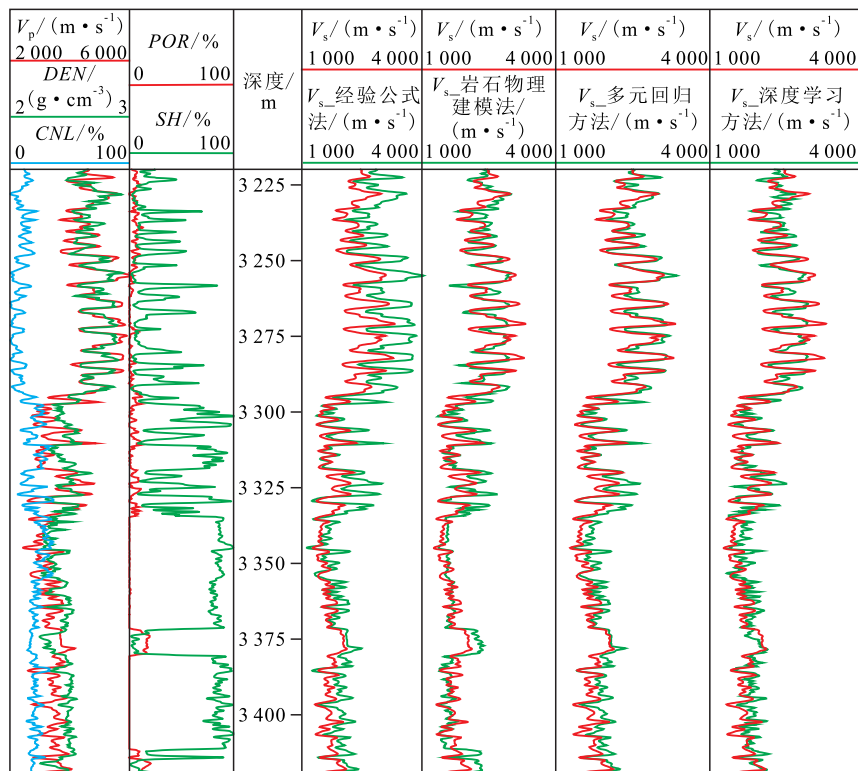


图4 E3井横波速度预测结果

Fig.4 Results of S-wave velocity prediction in Well E3

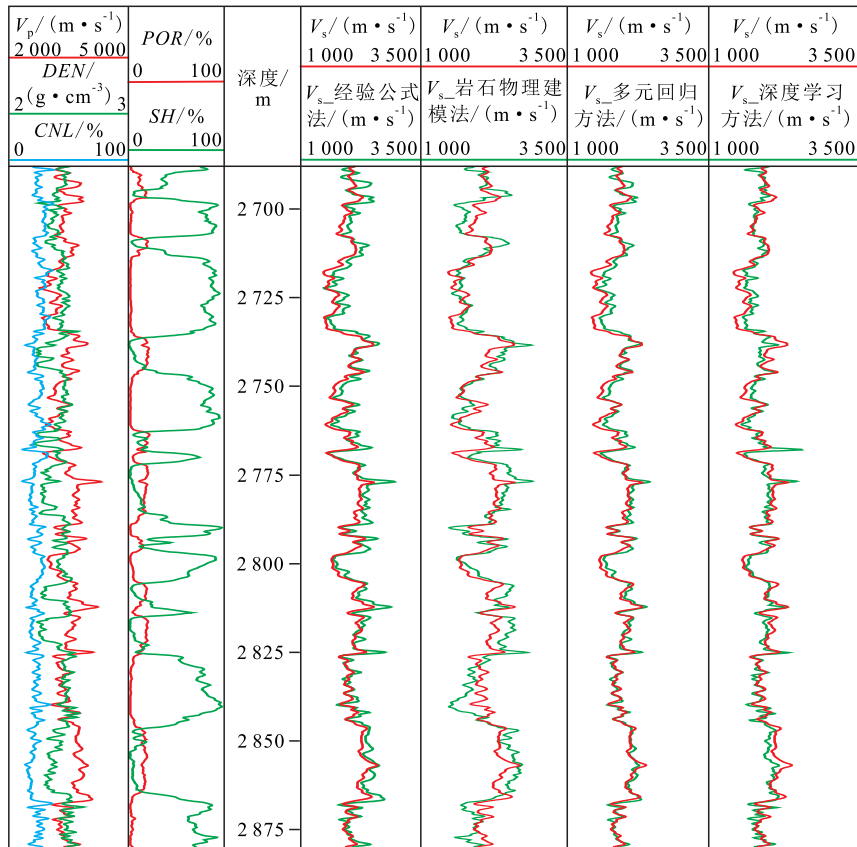


图5 E4井横波速度预测结果

Fig.5 Results of S-wave velocity prediction in Well E4

表1 不同方法预测横波速度的相对误差对比
 Table1 Comparison of relative errors in S-wave velocity prediction by different methods %

方法	相 对 误 差			
	E1井	E2井	E3井	E4井
经验公式法	12.75	4.58	15.97	5.68
岩石物理建模法	7.48	8.98	10.11	7.10
多元回归方法	5.81	5.34	8.59	4.11
DFNN方法	4.44	3.17	8.39	4.43

于东部油田测井数据建立的多元回归模型及深度学习模型直接应用于西部某油田多口井的横波速度预测。以W1和W2井为例,通过对比预测横波速度与实测横波速度的相关性,可以看出2口井的深度学习模型预测横波速度与实测横波速度的相似度均很高,但是W1井的多元回归模型预测横波速度与实测横波速度吻合较好,而W2井的预测横波速度与实测横波速度吻合较差(图6,图7),证明基于DFNN方法预测横波速度具有较高的泛化能力,稳定性最好。

5 结论

基于DFNN方法预测横波速度,通过建立纵波

速度、密度、孔隙度、泥质含量、中子孔隙度5个储层参数与横波速度的深度学习模型,对横波速度进行预测,并与传统方法进行对比。结果表明,基于DFNN方法的横波速度预测结果精度最高,与实测横波速度的误差最小。将该模型直接应用于西部某油田,取得了较好的效果,表明基于DFNN方法预测横波速度具有较强的泛化能力和稳定性,能够为碎屑岩地层的横波速度预测提供一定的指导和借鉴意义,进而为储层及储层流体预测提供可靠的基础数据,同时提高效率。需要指出的是,仍需不断对模型加入新的实测横波速度进行训练,以进一步提高其预测能力和适用性。

符号解释

- b ——偏置项;
- b_1, b_2, b_3 ——第1个隐藏层中3个神经元 neu1, neu2, neu3对应的偏置项;
- b_4, b_5 ——第2个隐藏层中2个神经元 neu4, neu5对应的偏置项;
- b_6 ——输出层神经元 neu6对应的偏置项;
- $g(b, w)$ ——真实数据与预测数据之间的误差的平方和;
- i ——数据的排序;

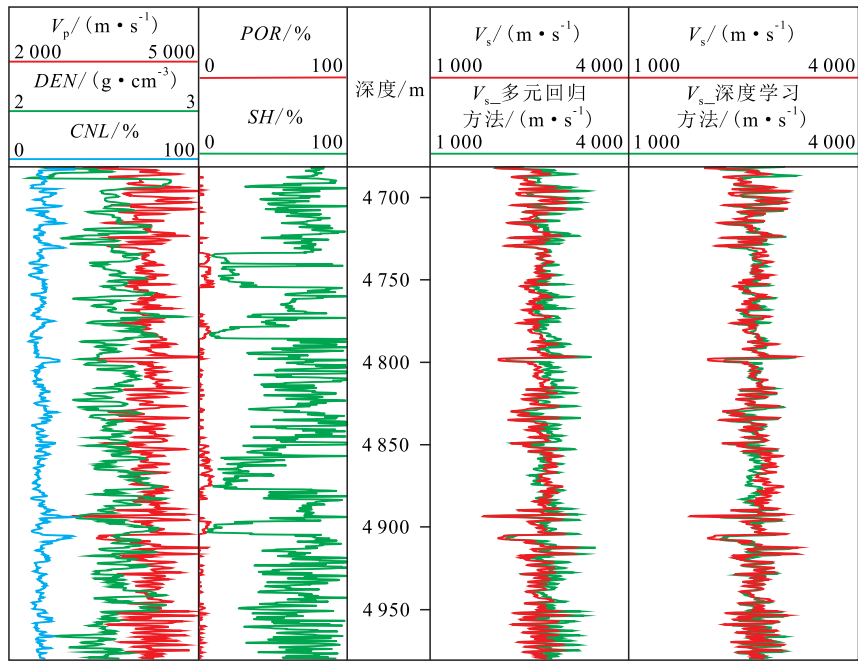


图6 W1井横波速度预测结果

Fig.6 Results of S-wave velocity prediction in Well W1




图7 W2井横波速度预测结果

Fig.7 Results of S-wave velocity prediction in Well W2

n ——数据的数量;
 w ——权重系数;
 x ——输入数据;
 x_1, x_2 ——第1个输入数据和第2个输入数据;
 x_i ——第 i 个预测数据;
 y_i ——第 i 个真实数据;
 z_1, z_2, z_3 ——第1个隐藏层中3个神经元 neu1, neu2, neu3 的输入数据;
 z_4, z_5 ——第2个隐藏层中2个神经元 neu4, neu5 的输入数据;
 z_6 ——输出层神经元 neu6 的输入数据。

参考文献

- [1] 冷雪梅, 杜启振, 孟宪军. 基于纵横波弹性阻抗联合反演的储层流体检测方法[J]. 断块油气田, 2019, 26(3): 319-323, 363. LENG Xuemei, DU Qizhen, MENG Xianjun. Reservoir fluid detection method based on joint PP-and PS-wave elastic impedance inversion[J]. Fault-Block Oil and Gas Field, 2019, 26(3): 319-323, 363.
- [2] 汤婕, 吴国忱, 邓小凡. 基于贝叶斯理论的裂缝性介质叠前地震同步反演方法[J]. 油气地质与采收率, 2018, 25(6): 45-50. TANG Jie, WU Guochen, DENG Xiaofan. Pre-stack seismic synchronous inversion method for fractured media based on Bayesian theory[J]. Petroleum Geology and Recovery Efficiency, 2018, 25(6): 45-50.
- [3] 孙福利, 杨长春, 麻三怀, 等. 横波速度预测方法[J]. 地球物理学进展, 2008, 23(2): 470-474. SUN Fuli, YANG Changchun, MA Sanhuai, et al. An S-wave velocity predicted method[J]. Progress in Geophysics, 2008, 23(2): 470-474.
- [4] 唐杰, 王浩, 姚振岸, 等. 基于岩石物理诊断的横波速度估算方法[J]. 石油地球物理勘探, 2016, 51(3): 537-543. TANG Jie, WANG Hao, YAO Zhen'an, et al. Shear wave velocity estimation based on rock physics diagnosis[J]. Oil Geophysical Prospecting, 2016, 51(3): 537-543.
- [5] 王维红, 包培楠, 陈国飞, 等. 基于最小平方的横波速度拟合及应用[J]. 地球物理学进展, 2019, 34(5): 1 924-1 929. WANG Weihong, BAO Peinan, CHEN Guofei, et al. S-wave prediction and its application based on least square algorithm[J]. Progress in Geophysics, 2019, 34(5): 1 924-1 929.
- [6] 石玉江, 刘国强, 钟吉彬, 等. 基于大数据的测井智能解释系统开发与应用[J]. 中国石油勘探, 2021, 26(2): 113-126. SHI Yujiang, LIU Guoqiang, ZHONG Jibin, et al. Development and application of intelligent logging interpretation system based on big data[J]. China Petroleum Exploration, 2021, 26(2): 113-126.
- [7] 李昌, 沈安江, 常少英, 等. 机器学习法在碳酸盐岩岩相测井识别中应用及对比——以四川盆地MX地区龙王庙组地层为例[J]. 油气藏评价与开发, 2021, 11(4): 586-596. LI Chang, SHEN Anjiang, CHANG Shaoying, et al. Application and contrast of machine learning in carbonate lithofacies log identification: A case study of Longwangmiao Formation of MX area in Sichuan Basin[J]. Reservoir Evaluation and Development, 2021, 11(4): 586-596.
- [8] 黄家宸, 张金川. 机器学习预测油气产量现状[J]. 油气藏评价与开发, 2021, 11(4): 613-620. HUANG Jiachen, ZHANG Jinchuan. Overview of oil and gas production forecasting by machine learning[J]. Reservoir Evaluation and Development, 2021, 11(4): 613-620.
- [9] 李伟, 唐放, 侯博恒, 等. 基于神经网络的南海东部砂岩油藏采收率预测方法[J]. 油气藏评价与开发, 2021, 11(5): 730-735, 743. LI Wei, TANG Fang, HOU Boheng, et al. A method for oil recovery prediction of sandstone reservoirs in the eastern South China Sea based on neural network[J]. Reservoir Evaluation and Development, 2021, 11(5): 730-735, 743.
- [10] 刘巍, 刘威, 谷建伟, 等. 利用卡尔曼滤波和人工神经网络相结合的油藏井间连通性研究[J]. 油气地质与采收率, 2020, 27(2): 118-124. LIU Wei, LIU Wei, GU Jianwei, et al. Research on interwell connectivity of oil reservoirs based on Kalman filter and artificial neural network[J]. Petroleum Geology and Recovery Efficiency, 2020, 27(2): 118-124.
- [11] 吴君达, 李治平, 孙妍, 等. 基于神经网络的剩余油分布预测及注采参数优化[J]. 油气地质与采收率, 2020, 27(4): 85-93. WU Junda, LI Zhiping, SUN Yan, et al. Neural network-based prediction of remaining oil distribution and optimization of injection-production parameters[J]. Petroleum Geology and Recovery Efficiency, 2020, 27(4): 85-93.
- [12] CASTAGNA J P, BACKUS M M. AVO analysis—Tutorial and review [C]//Offset-dependent reflectivity—Theory and practice of AVO analysis. Society of Exploration Geophysicists, 1993, 8: 3-36.
- [13] CASTAGNA J P, BATZLE M L, EASTWOOD R L. Relationships between compressional-wave and shear-wave velocities in elastic silicate rocks[J]. Geophysics, 1985, 50(4): 571-581.
- [14] THOMSEN Leon. Weak elastic anisotropy [J]. Geophysics, 1986, 51(10): 1 954-1 966.
- [15] HAN D H, NUR A, MORGAN D. Effects of porosity and clay content on wave velocities in sandstones [J]. Geophysics, 1986, 51(11): 2 093-2 107.
- [16] 王浩璠, 马劲风, 李琳, 等. 致密储层横波速度预测方法研究——以苏里格气田为例[J]. 地球物理学进展, 2019, 34(4): 1 521-1 529. WANG Haofan, MA Jinfeng, LI Lin, et al. Research on predicting S-wave velocity in tight reservoir: Sulige gas field for example[J]. Progress in Geophysics, 2019, 34(4): 1 521-1 529.
- [17] 马淑芳, 韩大匡, 甘利灯, 等. 地震岩石物理模型综述[J]. 地球物理学进展, 2010, 25(2): 460-471. MA Shufang, HAN Dakuang, GAN Lideng, et al. A review of seismic rock physics models [J]. Progress in Geophysics, 2010, 25(2): 460-471.
- [18] VOIGT W. Lehrbuch der kristallphysik [M]. Leipzig: Teubner, 1928: 739.
- [19] REUSS A. Calculation of the flow limits of mixed crystals on the basis of the plasticity of monocrystals [J]. Zeitschrift fur Ange-

- wandte Mathematik, 1929, (9):49-58.
- [20] HILL R. The elastic behavior of a crystalline aggregate [J]. *Proceeding of the Physical Society*, 1952, 65(5):349-353.
- [21] HASHIN Z, SHTRIKMAN S. A variational approach to the theory of the elastic behavior of multiphase materials [J]. *Journal of Mechanics and Physics of Solids*, 1963, 11(2):127-140.
- [22] BERRYMAN J G. Single-scattering approximations for coefficients in Biot's equations of poroelasticity [J]. *Journal of the Acoustical Society of America*, 1992, 91(2):551-571.
- [23] WYLLIE M R, GREGORY A R, GARDNER G H. An experimental investigation of factors affecting elastic wave velocities in porous media [J]. *Geophysics*, 1958, 23(3):459-493.
- [24] GASSMANN F. Elastic waves through a packing of spheres [J]. *Geophysics*, 1951, 16(4):673-685.
- [25] XU S, WHITE R E. A new velocity model for claysand mixtures [J]. *Geophysical prospecting*, 1995, 43(1):91-118.
- [26] 杨亚华, 高刚, 魏红梅, 等. 叠前同时反演在灰质发育区识别储层及流体的应用研究 [J]. *地球物理学进展*, 2017, 32(1):332-338.
YANG Yahua, GAO Gang, WEI Hongmei, et al. Application of pre-stack simultaneous inversion in reservoir and fluid identification of the calcareous development zone [J]. *Progress in Geophysics*, 2017, 32(1):332-338.
- [27] 段南. 叠前地震波形指示反演在薄互层储层预测中的应用 [J]. *地球物理学进展*, 2019, 34(2):523-528.
DUAN Nan. Application of prestack seismic waveform indicates inversion in thin reservoir prediction [J]. *Progress in Geophysics*, 2019, 34(2):523-528.
- [28] 马光克, 李洋森, 黄玉, 等. 基于岩石物理正演分析的低渗储层叠前反演方法研究 [J]. *地球物理学进展*, 2019, 34(1):347-353.
MA Guangke, LI Yangsen, HUANG Yu, et al. Application of rock physics analysis in pre-stack seismic reservoir prediction: a case study of low porosity and permeability reservoir in WC J/S area [J]. *Progress in Geophysics*, 2019, 34(1):347-353.
- [29] 李庆忠. 岩石的纵、横波速度规律 [J]. *石油地球物理勘探*, 1992, 27(1):1-12, 154.
LI Qingzhong. Velocity regularities of P and S-waves in formations [J]. *Oil Geophysical Prospecting*, 1992, 27(1):1-12, 154.
- [30] 李文成, 彭嫦姿, 杨鸿飞. 横波预测技术在YB地区的应用 [J]. *地球物理学进展*, 2014, 29(4):1695-1700.
LI Wencheng, PENG Changzi, YANG Hongfei. The application of S-wave prediction technology in YB area [J]. *Progress in Geophysics*, 2014, 29(4):1695-1700.
- [31] SAM M S, ANDREA M. The effect of clay distribution on the elastic properties of sandstones [J]. *Geophysical Prospecting*, 2001, 49(1):128-150.
- [32] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天 [J]. *计算机研究与进展*, 2013, 50(9):1799-1804.
YU Kai, JIA Lei, CHEN Yuqiang, et al. Deep learning: yesterday, today, and Tomorrow [J]. *Journal of Computer Research and Development*, 2013, 50(9):1799-1804.
- [33] SCHMIDHUBER J. Deep learning in neural networks: an overview [J]. *Neural Networks*, 2014, 61:85-117.
- [34] 郭丽丽, 丁世飞. 深度学习研究进展 [J]. *计算机科学*, 2015, 42(5):28-33.
GUO Lili, DING Shifei. Research progress on deep learning [J]. *Computer Science*, 2015, 42(5):28-33.
- [35] 孙志远, 鲁成祥, 史忠植, 等. 深度学习研究与进展 [J]. *计算机科学*, 2016, 43(2):1-8.
SUN Zhiyuan, LU Chengxiang, SHI Zhongzhi, et al. Research and advances on deep learning [J]. *Computer Science*, 2016, 43(2):1-8.
- [36] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [J]. *Journal of Machine Learning Research*, 2010, 9:249-256.

编辑 邹滢滢