基于深度混合神经网络的横波速度反演预测方法

王俊^{1,2}, 曹俊兴^{1,2*}, 赵爽³, 漆乔木^{1,2}

1. 成都理工大学油气藏地质及开发工程国家重点实验室, 成都 610059;

2. 成都理工大学地球勘探与信息技术教育部重点实验室, 成都 610059;

3. 中国石化西南油气分公司勘探开发研究院, 成都 610041

* 通讯作者, E-mail: caojx@cdut.edu.cn

收稿日期: 2021-05-14; 收修改稿日期: 2021-10-26; 接受日期: 2021-11-18; 网络版发表日期: 2022-01-05

国家自然科学基金项目(批准号: 42030812、42042046、41974160)和中国石化科技部项目(编号: P20055-6)资助

摘要 横波速度是最重要的岩石物理参数之一, 在油藏描述、地震叠前反演和地质力学分析中至关重要, 但实测获得不易. 在无实测横波数据可用时, 岩石物理建模计算预测被认为是精度最高的横波速度预测方法. 但因地下地质结构的复杂性与岩石矿物组成的多样性等因素, 岩石物理建模预测结果易受建模者认知、经验等多种因素的影响. 因此, 研究发展新的更稳健简便的横波速度反演预测方法具有重要意义. 受集成学习思想的启发, 文章基于储层地质沉积规律及其在测井响应上的特点, 将深度学习中经典的卷积神经网络(CNN)与长短期记忆网络(LSTM)相结合, 发展了一种基于深度混合神经网络(DHNN)的横波速度反演预测方法. 该方法以常规的声波与密度等常规测井数据为输入, 利用CNN建立输入数据与横波速度的非线性映射关系, 利用LSTM融入地层垂向变化趋势信息, 实现数据驱动的横波速度智能反演预测. 实际数据应用结果表明, 文章发展的方法使用单井数据集进行训练即能获得与岩石物理建模计算相当的预测结果, 且具有较强的泛化适用性. 该方法的实施为横波速度的稳健简便预测提供了新的方法技术, 具有重要的学术价值与很好的应用前景.

关键词 深度学习, 卷积神经网络, 长短期记忆网络, 混合神经网络, 沉积约束, 岩石物理反演, 横波速度预测

1 引言

横波速度是最重要的岩石物理参数之一(Buland和Omre, 2003). 岩石的横波速度可以通过室内岩石物理实验测量或偶极声波测井实测获得, 但前者费时费力, 后者因成本较高而用得也较少, 导致在实际勘探中常缺横波资料(Rezaee等, 2007; Tan等, 2015; Xu等, 2017; Sohail和Hawkes, 2020), 尤其是老井基本都没有实测横波速度数据(李维新等, 2009), 使得叠前地震反

演等工作无法开展(Russell等, 2003). 横波速度预测是地震勘探基础理论方法研究的重要内容之一.

前人已经开展了大量的横波速度预测研究, 发展了许多横波速度预测方法. 这些方法大体可分为经验关系式法(Castagna等, 1985; Han等, 1986; Eskandari等, 2004)和岩石物理模型法(Krief等, 1990; Greenberg和Castagna, 1992; Xu和White, 1996; Jørstad等, 1999; Xu和Payne, 2009)两类. 经验关系式法以统计分析为基础, 是简单易行的横波速度估计方法, 但其应用具有一

中文引用格式: 王俊, 曹俊兴, 赵爽, 漆乔木. 2022. 基于深度混合神经网络的横波速度反演预测方法. 中国科学: 地球科学, 52(6): 1151–1169, doi: 10.1360/SSTe-2021-0128

英文引用格式: Wang J, Cao J, Zhao S, Qi Q. 2022. S-wave velocity inversion and prediction using a deep hybrid neural network. Science China Earth Sciences, 65(4): 724–741, <https://doi.org/10.1007/s11430-021-9870-8>

定的局限性(Lee, 1990; Akhundi等, 2014; Anemangely等, 2017), 常难以满足储层精细描述的需求. 岩石物理建模法主要是结合实际地质情况对各种岩石物理模型进行研究(印兴耀等, 2015; Qi等, 2017), 通过计算得到岩石的等效弹性参数, 进而计算岩石的纵横波速度. 许多学者以岩石物理分析为基础, 发展了多种适用于不同地质条件的横波预测模型(Krief等, 1990; Xu和White, 1996; Xu和Payne, 2009; 白俊雨等, 2012; 张广智等, 2013; Pan等, 2015; 罗水亮等, 2016; Qi等, 2019; Azadpour等, 2020; Zhang B等, 2020), 得到了比经验公式法更准确的结果. 岩石物理建模法以严谨的力学分析为基础, 理论上能准确预测岩石的横波速度, 因而受到了广泛的重视. 但在实践上, 在岩石物理建模过程中, 需要准确确定岩石的骨架矿物组成及其结构、岩石的孔隙结构及其连通性以及岩石的孔隙流体等各种影响因素, 并针对不同的实际情况选择恰当的岩石物理模型才能实现预期目标. 这使得岩石物理建模预测横波速度方法的推广使用受到了一定的限制, 如在复杂油气藏勘探中采用岩石物理建模方法预测横波速度就很难获得满意的结果. 因此, 针对复杂油气藏勘探这类情况, 需要循新的思路研究发展新的横波速度预测方法.

随着人工智能机器学习技术的快速发展及计算水平的提升, 基于机器学习的智能化技术在油气勘探领域受到了广泛关注(Rajabi等, 2010; Asoodeh和Bagheripour, 2012; Anemangely等, 2017; Wang和Peng, 2019; Olayiwola和Sanuade, 2021; 李宁等, 2021). 机器学习是利用计算机从数据中自动分析获得规律, 并利用获得的规律对未知数据进行预测的算法. 深度学习是当前机器学习领域的研究热点之一(Langer等, 2009; Mousavi等, 2016; Xing等, 2017; Zhang等, 2018; Bergen等, 2019; Saad和Chen, 2020; Lin等, 2021), 在许多科学与工程领域都取得了突破性的进展. 深度学习通过构建深网络结构能够提取蕴含在数据中的深层次特征, 挖掘数据的本质信息(Hinton等, 2006; LeCun等, 2015; Goodfellow等, 2016). 深度学习具有很多网络结构, 经典的如卷积神经网络(Convolutional neural networks, CNN)(Nebauer, 1998)和长短期记忆网络(Long short-term memory network, LSTM)(Hochreiter和Schmidhuber, 1997)等. 近年来, 深度学习正在逐步革新传统的油气资源勘探开发相关科学研究(Cao等, 2016; 曹俊兴,

2017; Cao和Wu, 2017; Yu等, 2019; 赵明等, 2019; Wu等, 2020; 汪凯翔等, 2020; 奚先和黄江清, 2020; Gao等, 2021; 匡立春等, 2021; 孙歧峰等, 2021; 田亚军等, 2021; 张逸伦等, 2021; Yu和Ma, 2021). 许多学者已成功将深度学习方法应用于地震储层预测(曹俊兴, 2017; 林年添等, 2018)、油气检测(Cao等, 2016; Cao和Wu, 2017; Zhu等, 2020)、储层孔隙度预测(Chen等, 2020; Feng, 2020)、岩相预测(Zhang等, 2018)、测井数据重构和解释(张东晓等, 2018; Wang等, 2020; Zhang Y等, 2020; Chen和Zhang, 2020; Pham等, 2020)、油藏自动试井解释(李道伦等, 2020)、全波形反演(奚先和黄江清, 2020)等. 深度学习的本质是构建一个被称之为深网络的嵌套映射矩阵, 功用和数理解析模型中的变量映射关系相当(郭庆华等, 2020). 在变量关系无法确定的复杂问题中, 深度学习可能是现阶段构建其映射关系模型的最佳手段. 我们现在面临的问题亦是如此: 横波速度与其他测井数据之间的关系相当复杂, 受固体骨架弹性模量、孔隙结构、孔隙大小、孔隙连通性、孔隙流体组成等多种因素的影响, 表现出很强的非线性特征. 在这种情况下, 使用深度学习构建常规测井数据与横波速度之间的深网络映射模型可能是最佳选择. 虽然基于深度学习的横波速度预测已经成为学术界研究的热点问题(Wang和Peng, 2019; Wang等, 2020; Zhang B等, 2020; Cui等, 2021), 但目前尚未被充分研究, 存在如模型泛化能力不足等诸多难点问题亟待解决.

地层沉积物的岩性类别和相应的物性主要受其形成时期沉积环境的控制, 由于沉积环境在一段时期内保持相对稳定, 所以同一时期的沉积物比不同时期沉积的沉积物更为相似(Tian等, 2021). 相邻沉积物之间存在一定的相关性, 这在地质研究中非常重要, 当然这是在假设没有断层或其他沉积后地层重建的情况下. 测井数据潜在的包含了地层岩石的各种属性特征信息, 其每个记录值都是相邻沉积物测井响应的加权总和(Lindberg等, 2015), 相互之间也存在一定的关系. 因此, 在基于测井数据的横波速度反演预测中, 既要考虑横波速度与常规测井数据之间的非线性映射关系, 还要考虑地层垂向变化的趋势信息. 本研究受集成学习思想的启发, 将深度学习中常用的两种经典网络CNN和LSTM网络进行结合, 发展了一种基于深度混合神经网络(Deep hybrid neural network, DHNN)的横

波速度反演预测方法. 将不同测井数据看作纵向上联系且彼此相关的序列数据, 利用DHNN建立起横波速度与常规测井数据序列之间的映射模式, 并基于这些模式对横波速度进行反演预测. 实际数据测试结果表明, 相比于基准模型CNN和LSTM, DHNN不仅能充分利用井下对应深度测井数据的响应值, 又能兼顾测井数据随深度的变化, 最大程度地避免储层横向和纵向非均质性带来的影响, 能更有效地提取数据内禀特征, 具有更高的预测准确度; 相比于岩石物理模型, DHNN的预测结果与自相容近似建立岩石物理模型的结果相当, 且受主观因素的影响较少, 避免了复杂的岩石物理建模和参数调整过程, 具有较强的适用性与泛化能力.

2 方法技术

2.1 卷积神经网络

卷积神经网络(CNN)(Nebauer, 1998; 周飞燕等, 2017)是深度学习中的经典网络之一. CNN具有强大的特征提取与信息整合能力, 可将原始数据进行高维映射处理, 有效提取数据内在特征, 在区域局部特征提取和图像处理等方面具有独特的优势, 已在图像分类、自然语言处理等领域取得显著成效(Krizhevsky等, 2012). CNN通过神经元局部连接和卷积核权重共享方式大幅度减少训练过程中的参数数量, 提高了模型训练速度. 由于其在数据特征提取方面的独特优势, 受到了地球物理学家的关注. Araya-Polo等(2018)利用深度CNN基于合成地震记录重建地下速度模型. Imamverdiyev和Sukhostat(2019)应用CNN从测井资料中自动解释岩相.

本研究采用的CNN结构由卷积层和全连接层组成, 如图1所示. 利用卷积层对输入数据进行卷积操作, 其主要目的是通过卷积运算提取输入数据的特征, 并以一定的步长滑动卷积核, 这样提取的特征便保留了原始输入数据的顺序关系. 为最大程度地保留提取的有效特征, 我们舍弃了池化层.

2.2 长短期记忆神经网络

循环神经网络(Recurrent neural network, RNN)(Goltsev和Rachkovskij, 2001; Graves和Schmidhuber, 2005)结构将前一时刻记忆的信息应用于当前神经元计算, 从而使隐藏层节点之间建立连接, 如图2所示.

图1 CNN结构

RNN具有动态特征记忆功能, 是一种适合处理涉及时序序列问题的网络. 常规RNN能够有效地分析和处理较短的序列数据, 但其在处理一些具有长期相关性的序列预测问题上表现较差(Ma等, 2015). 此外, 多层RNN在分析和处理维度过长的序列数据时易产生“梯度消失”或“梯度爆炸”的问题(Bengio等, 1994).

为了克服这些问题, Hochreiter和Schmidhuber (1997)提出了长短期记忆网络(LSTM), LSTM是RNN的一种特殊表现形式, 将传统RNN隐藏层的普通神经元替换为LSTM单元, 改善了常规RNN不能很好处理较长序列数据的问题. LSTM网络既能有效解决RNN存在的梯度消失和爆炸问题, 又能记住长期有效的相关信息, 可以处理任意长度的序列数据. LSTM的结构如图3所示, 其中图3a为LSTM的图模型, 图3b为LSTM单元结构. 通过门结构和记忆单元状态的设计, 使得LSTM可以对序列中的关键信息进行有效的更新和传递. LSTM单元中输入、输出、遗忘门及记忆细胞状态如图3b所示(Graves等, 2013).

2.3 深度混合神经网络模型

为充分利用CNN和LSTM两种网络的优势, 建立横波速度和常规测井数据之间的复杂映射关系, 本文发展了结合两者优势的深度混合神经网络(DHNN)模型. 首先, 作为一种经典网络模型, CNN可以较好地学习数据的内在特征, 且不会因为对数据深层次特征的提取而导致大量特征信息损失; 其次, 从储层沉积连续性角度, 考虑测井数据可以看作纵向上具有联系的序列数据, 时序特征也是进行横波速度预测的关键信息. 因此, 本文利用CNN进行测井数据特征提取, 将CNN提取的特征信息作为LSTM的输入, 利用LSTM挖

图2 RNN序列连接

图3 LSTM网络结构

(a) LSTM的图模型; (b) LSTM单元结构

掘测井数据沿深度方向的趋势信息。

本文设计的DHNN模型由CNN、LSTM和全连接层组成, 模型结构如图4所示。基于DHNN的预测方法主要包括数据标准化、模型建立和预测、分析与评价三个部分, (1) 数据标准化: 采用均值-方差归一化方法对输入数据进行标准化处理, 以确保各参数处于合理的分布范围内, 使网络更容易学习到数据间的内在关系; (2) 模型建立和预测: 该部分为模型的核心模块, 主要包括网络构建和数据预测, 通过训练数据集训练

图4 DHNN模型框架

神经网络建立输入和输出之间的映射关系, 建立反演预测模型, 实现利用常规测井数据直接预测横波速度的目标; (3) 分析与评价: 根据不同的评价指标, 评价模型预测结果的准确性。

3 实例应用

为测试本文发展方法的预测性能, 选择两个勘探区的实际数据进行三组对比实验。在实验一中, 使用澳大利亚西北大陆架北卡那封盆地某区域(以下简称A区域)的测井数据进行测试, 将预测结果与基准模型

CNN和LSTM的预测结果进行比较. 在实验二中, 使用在A区域训练好的模型对四川盆地川西坳陷中段东部斜坡中江气田某区域(以下简称B区域)的横波速度进行预测, 并与CNN和LSTM以及商业软件GeoScope的预测结果进行比较. 在实验三中, 利用B区域的实际数据进行测试, 将预测结果与采用自相容近似建立岩石物理模型的预测结果进行对比. 实验的主要目的是: (1) 验证本文发展的方法相对于基准模型的准确性和先进性; (2) 测试本文发展的方法的适用性和泛化能力; (3) 对比分析本文发展的方法相较于岩石物理建模预测方法的优缺点. 文中所有深度学习模型均使用Python3.7程序设计语言在TensorFlow框架下编程实现, 运行环境为: Windows 10操作系统, CPU配置为intel(R)Core(TM)i7-9750M, 主频为2.6GHz, 内存为128GB.

3.1 研究区地质背景

3.1.1 A研究区域

该区域位于西澳大利亚近海的北卡那封盆地, 共两口钻井, Satyr-5和Callirhoe-1井, 井位置如图5所示. Satyr-5和Callirhoe-1两口井的测井资料分别包括自然伽马(GR)、中子孔隙度(NPHI)、密度(RHOB)和纵波速度(V_p)数据. 钻井是为了对三叠统Mungaroo组浅部、深部以及早白垩世下巴罗群的油气勘探潜力进行评价. 北卡那封盆地是澳大利亚最主要的产油气盆地, 也是世界上主要的富气盆地之一, 其三叠系沉积由粉砂岩和黏土岩组成, 有少量石灰岩和砂岩互层, 在薄层厚度超过100m的块状地层时岩性变化强烈(Jeong等, 2021).

3.1.2 B研究区域

该区域位于四川盆地川西坳陷中段东部斜坡中江气田, 共三口钻井, 将其分别命名为A、B和C井, 其中A井为唯一拥有横波实测数据的井, A、B和C井均包含自然伽马(GR)、密度(RHOB)和纵波速度(V_p)数据. 川西坳陷构造单元划分、气田分布及相关研究井位置如图6所示(修改自叶素娟等, 2017). 中江沙溪庙气藏是以断层为主要运移通道的远源次生气藏, 隐蔽性强. 储层主要为非均质性强、低孔、低渗、致密、多期次多条叠置的三角洲平原及三角洲前缘分流河道砂体, 属致密砂岩储层.

图5 研究区域Satyr-5和Callirhoe-1井的位置
据Jeong等(2021)

3.2 模型参数设置

本文构建的DHNN模型由两层卷积层, 每层卷积核数目均为64, 为最大程度的保留CNN提取的特征信息, 我们在设计网络时舍弃了池化层; 两层LSTM层, 每层的神经元个数均为40; 一层全连接层, 神经元个数均为1; 为避免过拟合的产生, 在第二层LSTM后接一个Dropout层, 并设置其参数为0.2; 设置最大迭代次数为500. 同时为进一步确保模型能被训练好又不至于出现过拟合, 本文采用早停止技术, 并设定迭代次数为20, 也就是当参考的评价指标经过一定的迭代次数仍不能再改进时, 停止模型训练. 学习率是影响模型性能的重要超参数之一, 如果学习率设置过高, 则模型无法收敛到局部最小值, 如果学习率设置得过小, 虽然能保证不会跳过局部最小值, 但会花费较长的时间使模型收敛. 本文采用自适应学习率衰减, 并设定迭代次数为10, 也就是当参考的评价指标经过一定的迭代次数仍不能再改进时, 学习率按一定的比例下降. 此外, 本文选用Adam(Lambrecht等, 2018)优化算法进行模型优化训练. 在实际应用中, 可以调整这些超参数组合以获得更好的预测性能. 然而, 当我们在一个特定任务中比较相同类型的方法时, 很难选择足够公平的超参数组合. 公平的比较取决于许多因素, 包括算法的类型以及输入数据对模型的敏感性等. 因此, 为了

图6 川西坳陷构造单元划分、气田分布及相关井位置

修改自[10]素娟等(2017)

尽可能公平地比较实验中使用的深度学习模型, 本文固定了除网络类型之外的其他超参数。

3.3 实验和分析

3.3.1 实验一

为了评价本文发展的方法相较于基准模型方法的准确性和先进性, 本实验将A区域Satyr-5井的数据作为训练集训练模型, 将Callihoe-1井的数据作为测试集测试模型的预测性能, 并将DHNN的预测结果与CNN和LSTM的预测结果进行比较。本实验采用均方根误差(Root mean square error, RMSE)、平均绝对误差(Mean absolute error, MAE)和平均绝对百分比误差(Mean absolute percentage error, MAPE)作为评价指标, 此外, 还比较了模型的运行时间。DHNN、LSTM和CNN模型的训练误差曲线如图7所示。

图7表明三种深度学习模型均获得了较理想的训练误差曲线, 其中DHNN、LSTM和CNN分别在第

53、68和51次迭代结束后停止训练。由于CNN特殊的卷积运算和权值共享使其经历最少的迭代次数即被训练好; LSTM具有独特的门结构, 虽然使得其具有记忆能力, 但同时也增加了模型的复杂度, 使得模型经历更多的迭代次数才趋于稳定; DHNN结合了CNN和LSTM网络的特性, 模型达到稳定的迭代次数介于CNN和LSTM之间。CNN和LSTM趋于稳定的误差基本相当, 且明显高于DHNN, 表明在超参数组合和训练数据集相同的条件下, 虽然CNN和LSTM具有各自不同的优势, 在模型训练过程中能够学习到蕴含在训练数据中的不同特征, 但就本实验研究而言, 两者获得的拟合模型基本相同。相比于CNN和LSTM, DHNN由于结合了两者的优势, 能够更好地学习到输入输出数据之间的内禀特征, 获得了最佳的拟合模型。利用训练好的模型对测试数据集的横波速度进行预测, DHNN和CNN和LSTM的预测结果如图8所示, 误差指标和运行时间如表1所列。

图 7 不同模型的训练误差曲线

由图8可以看出,就整体趋势而言,DHNN整体要优于LSTM和CNN,预测结果更加接近实际值.这表明DHNN能更好地学习到横波速度与其他测井数据序列间的内在模式,并根据这些模式进行横波速度预测.相比DHNN,LSTM和CNN提取测井数据特征的能力稍弱,特别是在测井数据波动较大时,其预测结果存在较大的误差,如图8中3300~3360和3690~3760m深度范围内的预测结果.表明在本研究区域的横波速度预测中,仅依赖单一的LSTM和CNN确实难以挖掘蕴含在数据中的潜在复杂特征.尽管DHNN的预测结果不能在所有位置都优于基准模型LSTM和CNN,但是从本实验的整体预测效果来看,DHNN的预测结果确实更准确和稳定.

对比LSTM和CNN的预测结果,不难发现CNN的预测结果更好,结合模型和数据两方面所具有的特点,我们认为上述情况可能是由于以下原因造成.虽然具有记忆功能的LSTM可以很好地处理具有时序关系的数据,一定程度上能够弥补CNN无法考虑储层地质纵

向连续性的问题.但在预测横波速度与输入测井数据呈现很好一致性变化的层段,此时考虑测井数据的垂向变化则可能造成预测结果出现一定的偏差,预测准确度低于CNN.表明考虑测井数据的趋势信息学习到的非关键特征在一定程度上会降低模型的预测准确度,这也说明了循环网络的记忆能力在模型中具有重要作用.

进一步通过具体的预测误差指标分析,如表1所列,在RMSE、MAE和MAPE指标下,LSTM性能最差,CNN次之,DHNN最好.特别的,在RMSE、MAE、MAPE指标下,DHNN比LSTM减少了18.48%、24.05%、22.80%,比CNN减少了4.21%、8.64%、8.58%.综合图8和表1的结果得出本文发展的方法具有最优效果,表明DHNN既保留了CNN在复杂特征提取的优势也发挥了LSTM在时序特征提取的特性,使其在基于测井数据的横波速度预测方面的具有更大的优势.从表1所列不同模型的运行时间不难看出,CNN所用的时间较小,计算效率高,LSTM因模型较为复杂,运行时间较长.DHNN的运行时间介于CNN和LSTM之间,但其预测误差最小,具有更高的预测准确度.综合各模型的预测误差和运行时间分析,本文发展的方法具有较高的性价比,且预测优势明显.

3.3.2 实验二

为了测试本文发展方法的适用性和泛化能力.本实验利用在A区域训练好的模型对B区域A井的横波速度进行预测,并与CNN和LSTM以及商业软件GeoScope的估算结果进行比较.不同模型对A井的预测结果如图9所示,在RMSE、MAE和MAPE误差指标的计算结果如表2所列.

从图9可看出,就本实验所涉及的数据而言DHNN、LSTM和CNN的预测效果明显优于Geoscope软件估算结果,表明了利用深度学习技术预测横波速度的有效性和实用性.DHNN的预测结果整体较CNN

表 1 不同模型预测Callirhoe-1井的误差及运行时间对比

预测方法	评价指标			
	RMSE	MAE	MAPE	时间(s)
DHNN	0.1412	0.1058	5.8844	119.79
LSTM	0.1732	0.1393	7.6226	502.11
CNN	0.1474	0.1158	6.4367	76.92

图 8 DHNN、LSTM和CNN模型对Callirhoe-1井的预测结果

和LSTM更佳, 预测结果与实际值更接近. 在图中2605~2615m范围内, 三种方法的预测结果均出现了较大的误差. 经过初步分析, 笔者认为原因可能有以下三点: (1) 本实验采用的训练数据和测试数据位于不同的勘探区域, 澳大利亚西北大陆架北卡那封盆地和四川

盆地川西坳陷中段东部斜坡中江气田, 训练数据和测试数据具有一定的差异, 以至于测试数据中输入与输出数据之间的潜在关系在训练数据中没有得到较好的体现, 甚至在某些局部区域, 由于地层差异使得训练数据和测试数据的输入和输出之间存在完全不同的两种

图 9 DHNN、LSTM、CNN模型和Geoscope软件对A井的预测结果

模式; (2) 本实验的训练数据量很小, 所包含的地层信息非常有限, 以至于被训练的模型泛化能力有限; (3) 由于2605~2615m范围内Geoscope软件的估算结果也出现了很大的偏差, 因此有可能在此范围内存在流体异常. 当然也可能是其他的原因, 需要我们进一步结

合实际地质情况, 从模型和数据两方面入手进行对比研究和分析. 单方面从图中预测值和实际值重合程度同样可以看出, 虽然DHNN模型的预测结果不能在所有位置都优LSTM和CNN, 但是从预测结果的整体拟合程度来看, DHNN仍然最佳.

表 2 不同模型预测A井的误差对比

预测方法	评价指标		
	RMSE	MAE	MAPE
DHNN	0.1843	0.1415	2.1113
LSTM	0.2177	0.162	2.4247
CNN	0.2065	0.1532	2.2819
Geoscope	0.463	0.3941	5.9141

图 10 孔隙结构模型

(a) 高孔高渗储层; (b) 低孔低渗储层. 据王璞和吴国忱(2015), 已获得《地球物理学进展》使用许可

从表2可以看出, 就本实验所涉及的数据而言, DHNN模型预测结果的误差明显小于LSTM、CNN和Geoscope软件的预测结果, 其中RMSE、MAE、MAPE分别比LSTM降低了15.34%、12.65%、12.93%, 比CNN降低了10.75%、7.64%、7.48%, 比Geoscope软件降低了60.19%、64.10%、64.30%, 进一步证明了本文发展的方法具有较强的泛化适用性.

3.3.3 实验三

为了对比分析本文发展方法相较于岩石物理建模预测方法的优缺点. 本实验利用B区域唯一拥有实测横波数据的A井训练模型, 对B井和C井的横波速度进行预测, 并将预测结果与采用自相容近似岩石物理模型的预测结果进行对比. 该区域致密储层具有不同于常规砂泥岩储层, 具有低孔、低渗等特征. 常规砂泥岩储层和低孔低渗储层可等效为图10所示模型, 图中淡蓝色区域表示岩石的孔隙结构, 分为孔隙纵横比较大的孔隙和孔隙纵横比较小的裂缝. 其中图10a为常规砂泥岩储层对应的孔隙特征, 表现为高孔隙度, 高连通性; 图10b为低孔低渗储层对应的孔隙特征, 表现为低孔隙度, 低连通性, 甚至不连通.

为了综合考虑孔隙的影响, 我们将孔隙分为硬孔隙(孔隙纵横比接近1)和软孔隙(孔隙纵横比为0.01, 用

以描述裂隙), 这种组合可以很好地反映致密储层的孔隙特征. 另外为了分析基质固体颗粒的影响, 我们将颗粒分为硬颗粒(纵横比较大、近似为球状)和软颗粒(纵横比较小、近似为盘状). 同时考虑固体颗粒形状和孔隙形状的影响, 饱和岩石被等效为四部分组成(如图11). 为了分析固体颗粒形状和孔隙形状对致密储层速度的影响, 我们采用自相容近似建立岩石物理模型. 自相容近似模型包含物之间的弹性互动是通过用暂时尚未知的等效基质替换背景介质的方法来近似, 可以同时考虑固体颗粒形状和孔隙形状的影响. 由于自相容近似岩石物理模型为领域熟知的内容, 在此未对其进行详细介绍, 有关其实现细节可参见Berryman(1980)和Qi等(2019). 本实验所采用的岩石物理建模预测流程如图12所示.

对B区域的三口井开展岩石物理建模分析和纵横波速度预测. A井为该研究区唯一一口有实测横波资料的井, 利用A井对岩石物理建模及纵横波预测流程

图 11 等效饱和砂泥岩

据王璞和吴国忱(2015), 已获得《地球物理学进展》使用许可

图 12 岩石物理建模横波预测流程

进行验证, 预测结果如图13所示, 图中 K 为体积模量, u 为剪切模量, 实测 V_p 和 V_s 与预测 V_p 和 V_s 的相关系数如表3所列. 图13和表3的结果表明所建立的岩石物理模型能够对A井的纵横波速度做出较为准确的预测. 该实例应用验证了自相容近似岩石物理模型对于该研究区纵横波预测的有效性和适用性. 基于相同建模流程我们对于B和C井开展纵横波预测, 预测结果如图14、

图15和表3, 图中 K 为体积模量, u 为剪切模量. 图14和图15和表3的结果表明建立的模型对B井和C井的纵波速度进行了比较准确度预测, 因此我们能够推断出所建立的模型对B和C两口井的横波速度也进行了较准确的预测.

利用训练好的模型对B井和C井的横波速度进行预测, 基于DHNN、Geoscope软和自相容近似建立岩

图 13 A井岩石物理建模预测结果

图 14 B井岩石物理建模预测结果

表 3 岩石物理建模纵横波预测相关系数

井名	纵波实测和预测值相关系数	横波实测和预测值相关系数
A井(包含纵横波)	0.8884	0.8534
B井(缺失横波)	0.9685	/
C井(缺失横波)	0.9604	/

石物理模型的预测结果对比如图16和图17所示，图中左侧为输入数据，右侧为利用DHNN、Geoscope软件和岩石物理建模估计的横波速度。DHNN与岩石物理建模预测结果之间的交会图如图18所示。从图16和图17可看出，就本实验所涉及的数据而言Geoscope软件

的估算结果与岩石物理建模预测结果误差较大，表明就横波速度预测而言，Geoscope软件对本研究区域的致密砂岩储层基本不适用。图16~18表明DHNN与岩石物理建模预测结果很接近，取得了较好的估算结果，若获得了两者其一的结果便可以较好的反应实际横波速

图 15 C井岩石物理建模预测结果

度的情况.

以上结果表明在一定条件下, 可以用DHNN的预测结果替代岩石物理建模的预测结果. 此外, DHNN模型是利用测井数据(密度和纵波速度等)预测横波速度, 岩石物理建模法是利用弹性参数(体积模量和剪切模量等)预测横波速度, 相比而言, 测井数据更容易获得. 因此, 本文发展的方法比岩石物理建模更经济、实用. 再者, 本文方法是以井数据驱动的人工智能预测方法, 避免了复杂的岩石物理建模和参数调整过程, 且受

主观因素的影响较少, 无需依靠专家经验和一系列假设条件即可进行横波速度估计.

从图16和图17不难看出, DHNN与岩石物理建模预测结果之间仍然存在一定的偏差, 初步分析认为原因可能有如下三点: 一是本实验的训练数据非常少, 所包含有地层信息非常有限, 训练获得的模型泛化能力不足; 二是岩石物理建模得到的横波速度亦是基于一定假设获得的, 其与真实横波速度之间也存在一定的偏差; 三是DHNN模型和岩石物理模型是利用不同

图 16 DHNN模型和岩石物理建模预测结果(B井)

的参数建立的, DHNN模型是利用测井数据(密度和纵波速度等)预测横波速度, 岩石物理建模法是利用弹性参数(体积模量和剪切模量等)预测横波速度, 测井数据和弹性参数是对地下介质不同侧面的反映, 所包含的信息具有一定的差异, 以至于获得的模型预测结果之间存在一定的偏差. 当然, 也可能是其他原因引起的, 需要我们结合实际地质情况作进一步的深入研究和分析.

综合而言, 在同一研究区域, 若某些井的横波速度异常或缺失但具有完整的其他相关测井数据, 并且由

于各种原因, 导致岩石物理建模预测难度较大甚至不可能实现, 同时该研究区域具有一些实测横波速度的井数据. 此时, 可以利用具有实测横波速度的井数据训练DHNN模型, 然后根据无横波速度井中其他完整测井数据对该井的横波速度进行预测, 替代岩石物理建模预测的结果. 在条件允许的情况下, 也可以同时开展基于深度学习和岩石物理模型的横波速度反演预测, 综合分析两者的估计结果以准确指导油气勘探开发. 当然, 如果待预测井所在区域具有更多实测横波的井数据, 且这些井数据可用于模型训练时, 那么被

图 17 DHNN模型和岩石物理建模预测结果(C井)

训练模型的泛化能力将得到明显的提升, 对未知井横波速度预测的准确度也会得到一定的提升.

4 结论

本文将深度学习中经典的CNN和LSTM网络引入横波速度反演预测中, 发展了一种基于深度混合神经网络的横波速度反演预测方法, 利用擅长提取数据内在特征信息的CNN建立输入数据与横波速度间的非

线性映射关系, 利用擅长提取数据时序特征信息的LSTM网络融入地层垂向变化趋势信息, 实现数据驱动的横波速度智能反演预测. 模型框架设计符合CNN和LSTM网络的原理, 结合了两者的优点, 克服了它们的不足, 又充分考虑了横波反演预测问题的特殊性, 最终构建了既能充分利用井下对应深度测井数据的响应值, 又能兼顾测井数据随深度变化的横波速度反演预测模型.

实际数据应用结果表明, 本文发展的方法比基准

图 18 DHNN模型与岩石物理建模预测结果交会图

模型方法更准确和先进, 在一个小的数据集上进行训练即能获得与岩石物理建模预测相当的结果, 具有较强的泛化适用性. 具体应用结果如下, 在同一勘探区, 可以利用该区域具有实测横波速度的井数据训练DHNN模型, 对邻井缺失的横波速度进行预测; 在不同的勘探区域, 可以利用其他区域拥有实测横波速度的井数据训练DHNN模型, 然后对另一区域的横波速度进行预测. 与基准模型CNN和LSTM的预测结果相比, DHNN能够更有效地提取测井数据内禀特征, 预测准确度更高, 在数值模拟难度较大时确保预测结果稳健, 可较好地满足当前油气勘探的需要. 与岩石物理建模预测结果相比, DHNN的预测结果与自相容近似建立岩石物理模型的结果相当, 但其以井数据驱动, 避免了复杂的岩石物理建模和参数调整过程, 更简单高效, 且受主观因素的影响较少, 无需依靠专家经验和一系列假设条件即可进行可靠的横波速度估计, 更易推广使用.

总体而言, 本文发展的方法能最大程度地避免储层横向和纵向非均质性带来的影响, 具有较高预测准确度, 是一种可靠的预测方法. 此外, 该方法还可以应用于波阻抗反演和储层物性参数预测等. 在一定条件下, 这种数据驱动的横波速度智能反演预测方法在储层岩石物理确定性建模和反演难度较大时具有可操作性, 容易得到大规模应用并获得大量较详实的横波数据. 本研究为横波速度的稳健简便预测提供了新的思路和方法, 但其仅仅初步验证了该方法的可行性, 需要利用不同地质背景下的大数据集进行更多测试和比较, 才能得出更可靠的结论. 此外, 如何结合领域知识

揭示设计深度网络的“黑匣子”也值得深入研究.

致谢 感谢责任编辑和匿名审稿人对本文提出的宝贵修改意见和建议.

参考文献

- 白俊雨, 宋志翔, 苏凌, 杨文广, 朱凌燕, 李诗健. 2012. 基于Xu-White模型横波速度预测的误差分析. 地球物理学报, 55: 589-595
- 曹俊兴. 2017. 深度学习及其在深层天然气储层预测中的应用实验. 物探化探计算技术, 39: 775-782
- 郭庆华, 金时超, 李敏, 杨秋丽, 徐可心, 巨袁臻, 张菁, 宣晶, 刘瑾, 苏艳军, 许强, 刘瑜. 2020. 深度学习在生态资源研究领域的应用: 理论、方法和挑战. 中国科学: 地球科学, 50: 1354-1373
- 匡立春, 刘合, 任义丽, 罗凯, 史谔宇, 苏健, 李欣. 2021. 人工智能在石油勘探开发领域的应用现状与发展趋势. 石油勘探与开发, 48: 1-11
- 李道伦, 刘旭亮, 查文舒, 杨景海, 卢德唐. 2020. 基于卷积神经网络的径向复合油藏自动试井解释方法. 石油勘探与开发, 47: 583-591
- 李宁, 徐彬森, 武宏亮, 冯周, 李雨生, 王克文, 刘鹏. 2021. 人工智能在测井地层评价中的应用现状及前景. 石油学报, 42: 508-522
- 李维新, 王红, 姚振兴, 刘伊克, 常旭. 2009. 基于约束条件横波速度反演和流体替代. 地球物理学报, 52: 785-791
- 林年添, 张栋, 张凯, 王守进, 付超, 张建彬, 张冲. 2018. 地震油气储层的小样本卷积神经网络学习与预测. 地球物理学报, 61: 4110-4125
- 罗水亮, 杨培杰, 胡光明, 刘书会. 2016. 基于变形P-L模型的矩阵方程迭代精细横波预测. 地球物理学报, 59: 1839-1848
- 孙歧峰, 李娜, 段友祥, 李洪强, 唐海全. 2021. 基于长短期记忆神经网络的随钻地层倾角解释方法. 石油勘探与开发, 48: 843-850

- 田亚军, 高静怀, 王大兴, 陈道雨. 2021. 基于深度神经网络的地震强反射剥离方法. *地球物理学报*, 64: 2780–2794
- 汪凯翔, 黄清华, 吴思弘. 2020. 长短时记忆神经网络在地电场数据处理中的应用. *地球物理学报*, 63: 3015–3024
- 王璞, 吴国忱. 2015. 基于自相容近似的致密储层岩石物理建模. *地球物理学进展*, 30: 2233–2238
- 奚先, 黄江清. 2020. 基于卷积神经网络的地震偏移剖面中散射体的定位和成像. *地球物理学报*, 63: 687–714
- 叶素娟, 朱宏权, 李嵘, 杨映涛, 黎青. 2017. 天然气运移有机-无机地球化学示踪指标——以四川盆地川西坳陷侏罗系气藏为例. *石油勘探与开发*, 44: 549–560
- 印兴耀, 宗兆云, 吴国忱. 2015. 岩石物理驱动下地震流体识别研究. *中国科学: 地球科学*, 45: 8–21
- 张东晓, 陈云天, 孟晋. 2018. 基于循环神经网络的测井曲线生成方法. *石油勘探与开发*, 45: 598–607
- 张广智, 陈怀震, 王琪, 印兴耀. 2013. 基于碳酸盐岩裂缝岩石物理模型的横波速度和各向异性参数预测. *地球物理学报*, 56: 1707–1715
- 张逸伦, 喻志超, 胡天跃, 何川. 2021. 基于U-Net的井中多道联合微地震震相识别和初至拾取方法. *地球物理学报*, 64: 2073–2085
- 赵明, 陈石, Dave Y. 2019. 基于深度学习卷积神经网络的地震波形自动分类与识别. *地球物理学报*, 62: 374–382
- 周飞燕, 金林鹏, 董军. 2017. 卷积神经网络研究综述. *计算机学报*, 40: 1229–1251
- Akhundi H, Ghafoori M, Lashkaripour G R. 2014. Prediction of shear wave velocity using artificial neural network technique, multiple regression and petrophysical data: A case study in Asmari Reservoir (SW Iran). *Open J Geo*, 04: 303–313
- Anemangely M, Ramezanzadeh A, Tokhmechi B. 2017. Shear wave travel time estimation from petrophysical logs using ANFIS-PSO algorithm: A case study from Ab-Teymour Oilfield. *J Nat Gas Sci Eng*, 38: 373–387
- Araya-Polo M, Jennings J, Adler A, Dahlke T. 2018. Deep-learning tomography. *Leading Edge*, 37: 58–66
- Asoodeh M, Bagheripour P. 2012. Prediction of compressional, shear, and stoneley wave velocities from conventional well log data using a committee machine with intelligent systems. *Rock Mech Rock Eng*, 45: 45–63
- Azadpour M, Saberi M R, Javaherian A, Shabani M. 2020. Rock physics model-based prediction of shear wave velocity utilizing machine learning technique for a carbonate reservoir, southwest Iran. *J Pet Sci Eng*, 195: 107864
- Bengio Y, Simard P, Frasconi P. 1994. Learning long-term dependencies with gradient descent is difficult. *IEEE Trans Neural Netw*, 5: 157–166
- Bergen K J, Johnson P A, de Hoop M V, Beroza G C. 2019. Machine learning for data-driven discovery in solid Earth geoscience. *Science*, 363: eaau0323
- Berryman J G. 1980. Long-wavelength propagation in composite elastic media I. Spherical inclusions. *J Acoust Soc Am*, 68: 1809–1819
- Buland A, Omre H. 2003. Bayesian linearized AVO inversion. *Geophysics*, 68: 185–198
- Cao J, Wu S, He X. 2016. Gas reservoir identification basing on deep learning of seismic-print Characteristics. In: AGU Fall Meeting Abstracts, doi: 2016AGUFMNS31A1926C
- Cao J, Wu S. 2017. Deep learning: Chance and challenge for deep gas reservoir identification. In: International Geophysical Conference. Qingdao. 17–20
- Castagna J P, Batzle M L, Eastwood R L. 1985. Relationships between compressional-wave and shear-wave velocities in elastic silicate rocks. *Geophysics*, 50: 571–581
- Chen W, Yang L, Zha B, Zhang M, Chen Y. 2020. Deep learning reservoir porosity prediction based on multilayer long short-term memory network. *Geophysics*, 85: WA213–WA225
- Chen Y, Zhang D. 2020. Well log generation via ensemble long short-term memory (EnLSTM) network. *Geophys Res Lett*, 47: e87685
- Cui R, Cao D, Liu Q, Zhu Z, Jia Y. 2021. V_p and V_s prediction from digital rock images using a combination of U-Net and convolutional neural networks. *Geophysics*, 86: MR27–MR37
- Eskandari H, Rezaee M R, Mohammadnia, M. 2004. Application of multiple regression and artificial neural network techniques to predict shear wave velocity from wireline log data for a carbonate reservoir South-West Iran. *CSEG Recorder*, 42: 40–48
- Feng R. 2020. Estimation of reservoir porosity based on seismic inversion results using deep learning methods. *J Nat Gas Sci Eng*, 77: 103270
- Gao H, Wu X, Liu G. 2021. ChannelSeg3D: Channel simulation and deep learning for channel interpretation in 3D seismic images. *Geophysics*, 86: IM73–IM83
- Goltsev A, Rachkovskij D. 2001. A recurrent neural network for partitioning of hand drawn characters into strokes of different orientations. *Int J Neur Syst*, 11: 463–475
- Goodfellow I, Bengio Y, Courville A. 2016. Deep Learning (Vol. 1). Cambridge: MIT Press. 326–366
- Graves A, Mohamed A R, Hinton G. 2013. Speech recognition with deep recurrent neural networks. In: 2013 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Vancouver. 6645–6649
- Graves A, Schmidhuber J. 2005. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18: 602–610
- Greenberg M L, Castagna J P. 1992. Shear-wave velocity estimation in

- porous rocks: Theoretical formulation, preliminary verification and applications. *Geophys Prospect*, 40: 195–209
- Han D, Nur A, Morgan D. 1986. Effects of porosity and clay content on wave velocities in sandstones. *Geophysics*, 51: 2093–2107
- Hinton G E, Osindero S, Teh Y W. 2006. A fast learning algorithm for deep belief nets. *Neural Comput*, 18: 1527–1554
- Hochreiter S, Schmidhuber J. 1997. Long short-term memory. *Neural Comput*, 9: 1735–1780
- Imamverdiyev Y, Sukhostat L. 2019. Lithological facies classification using deep convolutional neural network. *J Pet Sci Eng*, 174: 216–228
- Jeong J, Park E, Emelyanova I, Pervukhina M, Esteban L, Yun S T. 2021. Application of conditional generative model for sonic log estimation considering measurement uncertainty. *J Pet Sci Eng*, 196: 108028
- Jørstad A, Mukerji T, Mavko G. 1999. Model-based shear-wave velocity estimation versus empirical regressions. *Geophys Prospecting*, 47: 785–797
- Krief M, Garat J, Stellingwerf J, Ventre J. 1990. A petrophysical interpretation using the velocities of P and S waves (full-waveform sonic). *Log Analyst*, 31: 355–369
- Krizhevsky A, Sutskever I, Hinton G. 2012. ImageNet classification with deep convolutional neural networks. *Adv Neural Inform Process Syst*, 25: 1097–1105
- Lambrecht B N, Vanderkerken M, Hammad H. 2018. The emerging role of ADAM metalloproteinases in immunity. *Nat Rev Immunol*, 18: 745–758
- Langer H, Falsaperla S, Masotti M, Campanini R, Spampinato S, Messina A. 2009. Synopsis of supervised and unsupervised pattern classification techniques applied to volcanic tremor data at Mt Etna, Italy. *Geophys J Int*, 178: 1132–1144
- LeCun Y, Bengio Y, Hinton G. 2015. Deep learning. *Nature*, 521: 436–444
- Lee S H. 1990. Regression models of shear wave velocities in Taipei basin. *J Chin Institute Eng*, 13: 519–532
- Lin S S, Shen S L, Zhang N, Zhou A. 2021. Modelling the performance of EPB shield tunnelling using machine and deep learning algorithms. *Geosci Front*, 12: 101177
- Lindberg D V, Rimstad E, Omre H. 2015. Inversion of well logs into facies accounting for spatial dependencies and convolution effects. *J Pet Sci Eng*, 134: 237–246
- Ma X, Tao Z, Wang Y, Yu H, Wang Y. 2015. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Tran Res Part C-Emer Technol*, 54: 187–197
- Mousavi S M, Horton S P, Langston C A, Samei B. 2016. Seismic features and automatic discrimination of deep and shallow induced-microearthquakes using neural network and logistic regression. *Geophys J Int*, 207: 29–46
- Nebauer C. 1998. Evaluation of convolutional neural networks for visual recognition. *IEEE Trans Neural Netw*, 9: 685–696
- Olayiwola T, Sanuade O A. 2021. A data-driven approach to predict compressional and shear wave velocities in reservoir rocks. *Petroleum*, 7: 199–208
- Pan J G, Wang H B, Li C, Zhao J G. 2015. Effect of pore structure on seismic rock-physics characteristics of dense carbonates. *Appl Geophys*, 12: 1–10
- Pham N, Wu X, Zabihi Naeini E. 2020. Missing well log prediction using convolutional long short-term memory network. *Geophysics*, 85: WA159–WA171
- Qi Q, Cheng A C H, Li Y E. 2019. Determination of formation shear attenuation from dipole sonic log data. *Geophysics*, 84: D73–D79
- Qi Q, Müller T M, Pervukhina M. 2017. Sonic Q_p/Q_s ratio as diagnostic tool for shale gas saturation. *Geophysics*, 82: MR97–MR103
- Rajabi M, Bohloli B, Gholampour Ahangar E. 2010. Intelligent approaches for prediction of compressional, shear and Stoneley wave velocities from conventional well log data: A case study from the Sarvak carbonate reservoir in the Abadan Plain (Southwestern Iran). *Comput Geosci*, 36: 647–664
- Rezaee M R, Kadkhodaie-Ilkhchi A, Barabadi A. 2007. Prediction of shear wave velocity from petrophysical data utilizing intelligent systems: An example from a sandstone reservoir of Carnarvon Basin, Australia. *J Pet Sci Eng*, 55: 201–212
- Russell B H, Hedlin K, Hiltebert F J, Lines L R. 2003. Fluid-property discrimination with AVO: A Biot-Gassmann perspective. *Geophysics*, 68: 29–39
- Saad O M, Chen Y. 2020. Deep denoising autoencoder for seismic random noise attenuation. *Geophysics*, 85: V367–V376
- Sohail G M, Hawkes C D. 2020. An evaluation of empirical and rock physics models to estimate shear wave velocity in a potential shale gas reservoir using wireline logs. *J Pet Sci Eng*, 185: 106666
- Tan M, Peng X, Cao H, Wang S, Yuan Y. 2015. Estimation of shear wave velocity from wireline logs in gas-bearing shale. *J Pet Sci Eng*, 133: 352–366
- Tian M, Omre H, Xu H. 2021. Inversion of well logs into lithology classes accounting for spatial dependencies by using hidden markov models and recurrent neural networks. *J Pet Sci Eng*, 196: 107598
- Wang J, Cao J, Yuan S. 2020. Shear wave velocity prediction based on adaptive particle swarm optimization optimized recurrent neural network. *J Pet Sci Eng*, 194: 107466
- Wang P, Peng S. 2019. On a new method of estimating shear wave velocity from conventional well logs. *J Pet Sci Eng*, 180: 105–123

- Wu X, Geng Z, Shi Y, Pham N, Fomel S, Caumon G. 2020. Building realistic structure models to train convolutional neural networks for seismic structural interpretation. *Geophysics*, 85: WA27–WA39
- Xing F, Xie Y, Su H, Liu F, Yang L. 2017. Deep learning in microscopy image analysis: A survey. *IEEE Trans Neural Netw Learn Syst*, 29: 4550–4568
- Xu J, Tan M, Wang X, Wu C. 2017. Predicting acoustic-wave velocities and fluid sensitivity to elastic properties in fractured carbonate formation. *Interpretation*, 5: SB69–SB80
- Xu S, Payne M A. 2009. Modeling elastic properties in carbonate rocks. *Leading Edge*, 28: 66–74
- Xu S, White R E. 1996. A physical model for shear-wave velocity prediction1. *Geophys Prospect*, 44: 687–717
- Yu S, Ma J, Wang W. 2019. Deep learning for denoising, *Geophysics*, 84: V333–V350
- Yu S, Ma J. 2021. Deep learning for geophysics: Current and future trends. *Rev Geophys*, 59: e00742
- Zhang B, Jin S, Liu C, Guo Z, Liu X. 2020. Prediction of shear wave velocity based on a statistical rock-physics model and Bayesian theory. *J Pet Sci Eng*, 195: 107710
- Zhang G, Wang Z, Chen Y. 2018. Deep learning for seismic lithology prediction. *Geophys J Int*, 215: 1368–1387
- Zhang Y, Zhong H R, Wu Z Y, Zhou H, Ma Q Y. 2020. Improvement of petrophysical workflow for shear wave velocity prediction based on machine learning methods for complex carbonate reservoirs. *J Pet Sci Eng*, 192: 107234
- Zhu K, Wang L, Du Y, Jiang C, Sun Z. 2020. DeepLog: Identify tight gas reservoir using multi-log signals by a fully convolutional network. *IEEE Geosci Remote Sens Lett*, 17: 568–571

(责任编辑: 印兴耀)