文章编号:1673-5005(2020)04-0083-11

doi:10.3969/j. issn. 1673-5005.2020.04.010

基于小波变换和卷积神经网络的地震储层 预测方法及应用

张国印1,2, 王志章2, 林承焰1, 王伟方2, 李 令2, 李 诚1

(1. 中国石油大学(华东)地球科学与技术学院,山东青岛 266580; 2. 中国石油大学(北京)地球科学学院,北京 102249)

摘要:提高储层预测的分辨率和准确性一直是油气藏表征的一个关键问题。将频谱分解与深度学习相结合,提出基于小波变换和卷积神经网络的地震岩性、储层类型预测方法。小波变换能够提供包含高频和低频信息的二维时频谱图,卷积神经网络具有超强的二维图像特征提取和分类能力,时频谱图作为卷积神经网络的输入,有助于充分挖掘地震数据高频和低频信息进行岩性和储层预测。将提出的方法应用于川西沙溪庙组储层预测中,首先利用叠后地震数据预测得到河道砂体分布,然后利用叠前地震数据在河道内部预测储层类型分布。结果表明,深度学习反演预测岩性和储层类型的分辨率和精度更高,能够识别小河道砂体,与生产测试情况更加吻合,优于常规地震反演方法。

关键词:地震储层预测;岩性预测;深度学习;卷积神经网络;时频谱图

中图分类号:P631 文献标志码:A

引用格式:张国印,王志章,林承焰,等.基于小波变换和卷积神经网络的地震储层预测方法及应用[J].中国石油大学学报(自然科学版),2020,44(4);83-93.

ZHANG Guoyin, WANG Zhizhang, LIN Chengyan, et al. Seismic reservoir prediction method based on wavelet transform and convolutional neural network and its application [J]. Journal of China University of Petroleum (Edition of Natural Science), 2020, 44(4);83-93.

Seismic reservoir prediction method based on wavelet transform and convolutional neural network and its application

ZHANG Guoyin^{1,2}, WANG Zhizhang², LIN Chengyan¹, WANG Weifang², LI Ling², LI Cheng¹

- (1. School of Geosciences in China University of Petroleum (East China), Qingdao 266580, China;
 - 2. School of Geosciences in China University of Petroleum (Beijing), Beijing 102249, China)

Abstract: Improving the resolution and accuracy of seismic reservoir prediction has long been a key problem in reservoir characterization. A novel seismic reservoir prediction method based on wavelet transform and convolution neural network is proposed, which is driven by prestack seismic, poststack seismic and well logging data. Wavelet transform can obtain two-dimensional time-frequency spectrum including both high-frequency and low-frequency information. Convolutional neural network is good at feature extraction and classification of two-dimensional image-like data. Using the spectrum as the input of convolutional neural networks is helpful for making full use of high-frequency and low-frequency information of seismic data for lithology and reservoir prediction. The proposed method is applied to the reservoir prediction of the Shaximiao Formation in the Western Sichuan Basin. Firstly, the distribution of the channel sand body is predicted by poststack seismic data, and then the distribution of reservoir type is predicted by prestack seismic data within the channel. The results show that the proposed method has higher resolution and accuracy and can predict more small-scale channel sands than conventional inversion method.

Keywords: seismic reservoir prediction; lithology prediction; deep learning; convolutional neural network; time-frequency spectrum

收稿日期:2019-12-02

基金项目:国家自然科学基金项目(41772139);国家科技重大专项(2017ZX05009001,2017ZX05072);中国石油大学(华东)自主创新科研 计划项目(20CX06053A)

三维地震资料具有极强多解性和垂向低分辨率 特征,提高地震储层预测结果的分辨率和准确性一 直是油气藏表征的一个关键问题[12]。地震储层预 测方法可以分为模型驱动和数据驱动的方法。模型 驱动的方法是通过岩石物理模型和波动方程等,建 立地震响应与地质参数之间的物理关系[34]。数据 驱动的方法是通过统计学习或机器学习方法建立地 震响应和地质参数之间的统计关系[5-6]。模型驱动 和数据驱动的方法都是建立地震响应与地质参数之 间的复杂非线性预测模式,其关键是利用有效的算 法,充分提取地震波形中的有效信息,拟合复杂非线 性预测模式。深度学习作为当今最强大的统计学习 方法之一,具有很强的特征提取、非线性模式拟合能 力,与大数据和计算能力的提升一起引领了新一轮 的人工智能技术发展浪潮,已成功应用于许多领域, 如计算机视觉和自然语言处理等[7]。自 2017 年以 来基于深度学习的地震资料解释吸引了越来越多学 者的关注,尤其以深度卷积神经网络研究最多,开展 了基于卷积神经网络的盐体识别[8]、断层解释[9]、 层位追踪[10]、河道识别[11]、地震相分析[12]、地震反 演[13-14] 等研究,显示了较好的预测效果。深度学习 依靠数据驱动,不需要先验知识,直接从油气藏数据

中进行信息提取和模式学习,如何组织和预处理地 震数据、获取地震数据对应的地质标签数据、构建深 度学习框架是深度学习反演方法的关键。笔者将频 谱分解与深度学习相结合,以叠后地震、叠前地震和 测井数据为输入和标签数据,提出基于小波变换和卷 积神经网络的地震岩性、储层类型的直接反演方法。

1 深度学习地震反演方法

对于深度学习地震反演方法,数据准备及预处 理是重要基础,深度学习反演框架是关键。

1.1 数据预处理

1.1.1 井震数据匹配

将测井数据和井旁地震数据作为深度学习模型的输入和标签数据。首先通过合成地震记录,进行地震数据与测井数据的时深匹配,获得准确的时深关系,将深度域的测井数据转换为时间域。测井与地震的匹配程度是影响反演结果的关键因素。测井数据与地震数据往往具有不同的采样率,考虑测井数据和地震数据的分辨率、储层厚度等因素,将时间域的测井数据和地震数据以相同的1 ms 采样率进行重采样。图1为 JS33-17 井时深匹配和重采样后的测井和地震数据。

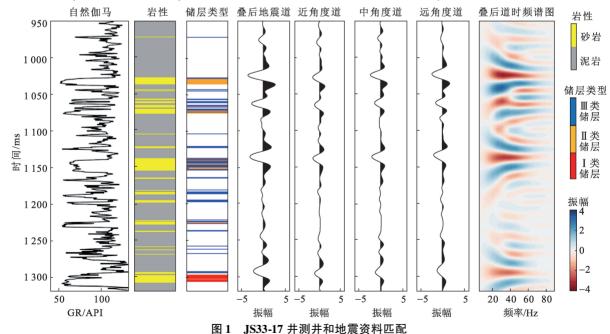


Fig. 1 Integration of well logs and seismic data of well JS33-17

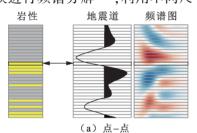
时深和采样率匹配后的地震和测井数据频带范围仍然差异很大,可分辨地层厚度差异也很大。地震数据仅包含中频信息,可分辨十几到几十米的岩层,而测井信息包含低频到高频的全频段信息,可分辨小于1 m 的地层。以川西沙溪庙地震资料为例,

地震频带范围在 12~60 Hz, 主频为 37 Hz, 目的层地层速度约 4000 m/s, 一般来说, 传统的地震视分辨率是 λ/4, 约13.5 m; 原始测井数据可分辨分米级厚度的岩层, 其分辨率远高于地震数据, 以 1 ms 的采样率重采样后的测井数据可区分的最薄岩层厚度

约为2 m。在不确定深度学习模型可以预测的岩层厚度极限的情况下,保留所有厚、中、薄岩层测井数据,充分挖掘地震数据的预测能力。需要注意的是,这种做法会在训练过程中降低一定的模型预测准确度数值,因为地震数据不能预测的薄岩层可能作为噪声存在。

1.1.2 时频谱图转换

频谱分解可以将复杂的地震信号分解为不同频率地震信号组合的时频谱图。频谱分解已被广泛应用于地震反演,地震信号中高频率成分的变化对地下薄层反射信息的变化敏感^[15],基于地震资料频谱的地震储层预测具有独特优势,特别是对于薄层识别具有优势^[16]。使用频谱分解后的时频谱图作为卷积神经网络输入,有助于从数据中进行特征提取,预期可帮助地震薄层识别,这是受卷积神经网络在语音识别领域的应用启发,声波通常被转换为时频谱以应用卷积运算进行特征提取^[17]。本文中选择Morlet 连续小波变换进行频谱分解^[18],利用不同尺



度的 Morlet 小波,可以对原始地震信号在不同频率和不同时间分辨率下进行分析,得到信号在时间和频率上的能量分布,获得高时间分辨率和高频率分辨率的时频谱图,如图 1 中所示 JS33-17 井井旁叠后地震道小波变换频谱分解后得到的时频谱图。

1.1.3 滑动时窗采样

将时深和采样率匹配后的测井和井旁地震波形、时频谱数据进行对应采样形成深度学习模型的训练数据集。图 2 为"点-点"和"点-窗"的采样方法。由于测井数据的每个时间深度的数据与一定时窗内的相邻数据点都相关,这与经典的卷积模型原理保持一致,即测井反射系数信息与子波长度内的地震波形相关,因此选择"点-窗"的匹配采样方法。选定合适的采样时间步长、时间窗口大小、时频谱图频率范围,时间窗口内的地震数据与时间窗口中心时间对应测井数据相匹配,进行可重叠的滑动时窗采样,形成输入二维时频谱图与测井标签数据样本,作为卷积神经网络的输入。

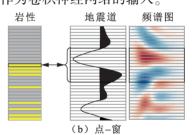


图 2 井震匹配采样方法

Fig. 2 Seismic and well log sampling method

1.2 卷积神经网络

卷积神经网络是实现数据驱动地震反演的关键。卷积神经网络可以被视为深度学习架构的一种,与传统人工神经网络类似,具有输入层、隐含层和输出层。基础的深度神经网络中的隐含层为全连接层,全连接层对输入进行线性运算后经过激活函数输出,可表示为

$$\mathbf{y} = f(\mathbf{W}\mathbf{x} + \mathbf{b}). \tag{1}$$

式中,x 为输入特征向量;W和b分别为权重系数矩阵和偏置向量;f为激活函数;y 为输出。卷积神经网络具有局部连接和共享权重的卷积层(convolutional layer),起到从结构性输入数据中提取特征的重要作用。特征图(feature map)是卷积层使用滤波器(filter)进行特征提取后的输出结果。该过程与信号处理中的卷积运算类似,可表示为

$$\mathbf{Q}_{j} = f\left(\sum_{i=1}^{I} \mathbf{O}_{i} * \mathbf{w}_{i,j}\right), j = 1, 2, \cdots, J.$$
(2)
式中, \mathbf{O}_{i} 为第 i 输入图; \mathbf{Q}_{i} 为第 j 特征图; I 为输入

图的层数; J 为滤波器的数量; $w_{i,j}$ 为滤波器,是连接 O_i 与 Q_j 的权重系数矩阵。滤波器以指定的步幅在输入图 O_i 上滑动做卷积运算产生特征图 Q_j 。I、J 可以根据需要指定。卷积层中的滤波器数量决定了产生的特征图的数量。特征提取可以被视为输入图的一种变换,以突出输入图的特定特征(图 3)。不同的滤波器可以从输入图中提取不同的特征。理论上,滤波器越多,提取的特征就越多,但是过多的滤波器会增加模型的训练负担。应用中,输入图所具有的特征有限,应该设置最佳数量的滤波器。激活函数 f 使用 ReLU 函数 190 :

$$f(x) = \max(0, x). \tag{3}$$

ReLU 函数可以减轻梯度消失问题,提高训练效率。

岩性或储层类型的反演问题可以作为分类问题,用于 M 类分类问题的卷积神经网络,可以在输出层中使用 softmax 函数估计每类的后验概率:

$$s_i^L = \mathbf{w}_i^L \mathbf{y}^{L-1}, j = 1, 2, \dots, M,$$
 (4)

$$y_j^L = \frac{e^{s_j^L}}{\sum_{i=1}^{M} e^{s_m^L}}, \ j = 1, 2, \dots, M.$$
 (5)

式中, y_j^L 为第模型输出的第 j 类的后验概率。使用交叉熵函数 Cross-entropy 作为 M 类分类问题的损失函数 [20]:

$$\min_{\boldsymbol{W},b} \varepsilon(\boldsymbol{g}, \boldsymbol{y}^L) = -\sum_{j=1}^{M} \boldsymbol{g}_j \lg(\boldsymbol{y}_j^L). \tag{6}$$

式中, ε 为损失函数;g 为真实标签; y^L 为 softmax 函数输出的后验概率。使用优化函数 Adam 控制学习过程。通过定义的损失函数和优化函数,可以优化、学习网络中的权重和偏差。

$$(\mathbf{W}, \mathbf{b}) \leftarrow (\mathbf{W}, \mathbf{b}) - \eta \frac{\partial \varepsilon}{\partial (\mathbf{W}, \mathbf{b})}.$$
 (7)

式中,W和b分别为需要学习的权重和偏差; η为学习率。在训练过程中,权重和偏差将根据每个样品或一小批样品的误差进行更新,小批量训练在每次迭代时使用多个样本,使学习过程更加稳定。学习率 η 可以是固定值或变化的值,使用优化函数Adam 时,学习率随着学习过程而变化,使学习过程更稳定高效。为避免过度拟合,在隐含层后使用Dropout 提高模型的泛化能力[21]。Dropout 在每一步训练时随机删除一定比例的隐藏层神经元,被移

除的神经元的权重和偏差被保留但不更新,并且可以在下一次训练迭代中再次工作。

1.3 深度学习反演框架

图 3 为结合小波变换与卷积神经网络的深度 学习地震反演框架。以时频谱图作为输入的二维 卷积神经网络由输入层、卷积层、全连接层和输出 层组成,时频谱图输入卷积层进行特征提取,卷积 层包含64个过滤器,卷积层输出的所有特征图像 输入全连接层进行分类。为了保留特征图像的正 值和负值,在卷积层中不使用 ReLU 激活函数。不 进行粗化,以卷积的滑动步长控制特征图像的分 辨率。全连接层后应用 Dropout, 取值 0.4 以防止 模型过拟合。最后一层是输出层,使用交叉熵函 数计算每类标签的后验概率作为输出,以岩性预 测深度学习模型为例,输出为砂岩和泥岩的后验 概率。模型采用20个样本的小批量训练方式,使 模型收敛更加稳定。优化函数 Adam 的学习率从 0.0001开始,并在培训过程中自动调整。当验证误 差在一定训练步数之后仍然没有下降时,则终止训 练。深度学习反演模型使用 TernsorFlow 在 Pvthon3.6 上编程搭建,同时使用 Scikit-learn、Obspy 等工具包进行数据预处理。

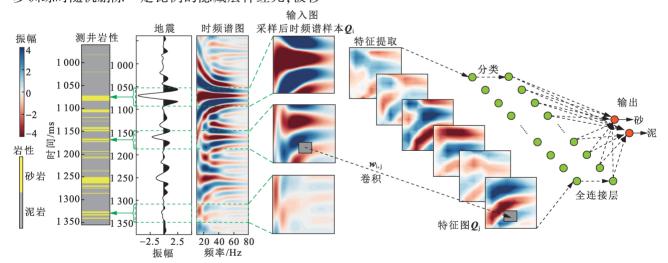


图 3 基于小波变换和卷积神经网络的深度学习地震反演架构

Fig. 3 Architecture of seismic inversion based on wavelet transform and convolutional neural network

2 储层预测应用

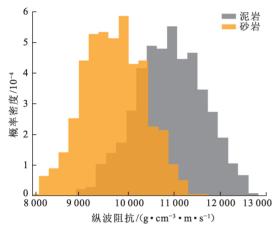
选取川西坳陷中江地区约200 km²叠前地震覆盖区作为主要研究区。研究区目的层沙溪庙组主要发育三角洲平原和三角洲前缘沉积,储层类型以分流河道致密砂岩为主。研究区致密砂岩储层按照孔隙度、渗透率、含气性等特征分为3类储层,并根据

测井响应特征形成测井解释成果曲线。 I 类储层具有相对最好的孔隙度、渗透率, 孔隙度为 8.0% ~ 14.6%, 平均为 11.7%; 渗透率分布在 $(0.483 \sim 16.200) \times 10^{-3} \, \mu m^2$, 平均为 $1.312 \times 10^{-3} \, \mu m^2$ 。 含气性好, 钻遇井多为高产井。 II 类储层孔隙度仍然较好,但渗透率较差, 孔隙度为 $7.6\% \sim 14.3\%$, 平均为 10.6%; 渗透率分布在 $(0.017 \sim 0.518) \times 10^{-3} \, \mu m^2$,

平均为 0. 153×10⁻³ μm²; 含气性一般, 钻遇井多为低产井。Ⅲ类储层孔隙度、渗透率都较差, 孔隙度为 2. 6%~10. 1%, 平均为 7. 4%; 渗透率分布在(0. 008~0. 336)×10⁻³ μm², 平均为 0. 048×10⁻³ μm²。含气性差, 钻遇井多为非气井。 Ⅰ类储层为最好储层类型, Ⅱ类次之, Ⅲ类较差。选取研究区叠后地震、叠前地震数据以及资料较全的 13 口井参与地震反演, 对比常规反演方法和深度学习地震反演方法, 预测岩性和不同储层类型的空间展布。

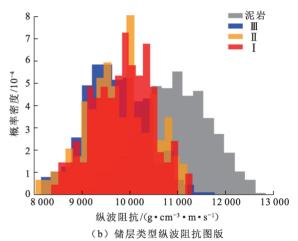
2.1 常规地震储层反演思路

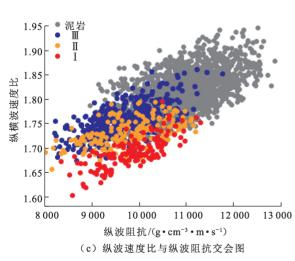
常规地震储层预测中,岩石物理分析是建立地



(a) 主要河道砂岩与泥岩纵波阻抗图版

质参数与地震资料响应之间的桥梁,是开展地震反演储层预测的基础。进行岩石物理分析,分析储层的敏感岩石物理参数,进而优选合适的地震反演预测方法。图 4 统计分析了沙溪庙组主要河道砂岩、储层类型与泥岩岩石物理弹性参数特征。主要河道砂岩纵波阻抗范围是 8 000 ~ 11 000 g/cm³·m/s,泥岩纵波阻抗分布在 10 000 ~ 13 000 g/cm³·m/s,级波阻抗可以区分主要河道砂岩和泥岩,却不能区分不同的储层类型。引入横波信息,计算更多岩石弹性参数,如横波阻抗、纵横波速度比、泊松比、弹性模量等,通过分析纵横波速度比与纵波阻抗结合,可以区分不同的储层类型。





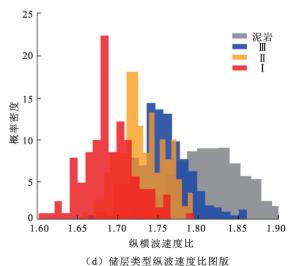


图 4 沙溪庙组岩石物理分析

Fig. 4 Analysis of rock physics of Shaximiao Formation

根据岩石物理特征制定合适地震储层预测方法。叠后地震反演可得到稳定纵波阻抗,进而可以根据岩性与纵波阻抗的关系,推测岩性信息。与叠后地震资料相比,叠前地震资料虽然信噪比相对较低,但保留了振幅随炮检距变化的信息,通过叠前同

时反演得到横波速度、密度等信息,进行储层类型预测。为了增加信噪比、提高资料品质、降低计算量,叠前同时反演从近道(0°~12°)、中道(12°~24°)和远道(24°~36°)3个角度部分叠加数据体中反演纵、横波阻抗和密度,并在此基础上计算纵波速度、

横波速度、纵横波速度比等多种弹性参数。结合岩石物理分析结果,通过反演得到的弹性参数可以得到不同类型储层的预测结果。

2.2 深度学习地震储层反演思路

深度学习地震储层反演方法从数据中自动学习 地震储层预测模式,不必要进行岩石物理分析等步 骤,但是岩石物理分析可以帮助制定有效的深度学 习反演策略。根据岩石物理分析结果,叠后地震可 以预测岩性信息,储层类型需要通过叠前地震数据 预测。制定以下储层层次预测思路:以叠后地震数据和测井解释岩性为训练数据,建立叠后深度学习 地震反演模型,预测岩性展布;以叠前地震数据和测 井解释储层类型为训练数据,建立叠前深度学习地 震反演模型,在岩性预测结果的约束下,预测不同类 型储层展布,如图 5 所示。

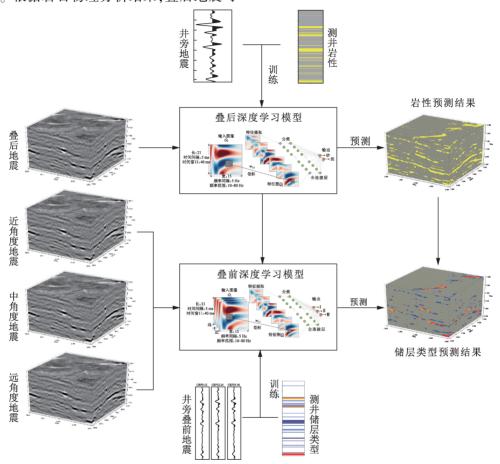


图 5 基于深度学习的储层层次预测策略

Fig. 5 Reservoir prediction based on deep learning

叠前深度学习地震反演模型,采用与叠后深度学习反演模型类似的卷积网络结构,将部分角度叠加的远、中、近角度地震数据分别做小波变换,形成三通道二维图像作为输入,即在式(2)中 I=3,以测井解释三类储层类型划分结果作为输出。与叠后深度学习地震反演模型相比,叠前深度学习地震反演模型同样具有卷积层与全连接层,不同的是卷积层对近、中、远三通道输入图像进行特征提取。模型预测结果同样得到每一类储层的后验概率,预测后验概率最大的储层类型作为最终模型预测结果。

深度学习储层反演分为两步:叠后深度学习

反演预测岩性和叠前深度学习反演预测储层类型。首先,训练岩性预测的叠后深度学习模型,对研究区 13 口井进行数据预处理后,形成共 3 770 个样本的数据集。输入时频谱图的频率范围选择 10~80 Hz,时间窗长采用 40 ms,时间窗口应为研究区地震波形的一个波长以上[13]。整个数据集分为 3 个子集:训练集、验证集和测试集。测试集为来自一口指定井 JS7 的所有样本从一开始就被单独拿出,作为测试盲井,用于最终建立模型的性能评估。验证集和训练集用于训练模型,除测试盲井外样本的随机 30% 为验证集,70% 为训练集。通过统计,砂岩标签样本的比例为所有样品的

17%,远小于泥岩标签样本的比例,将少数类的砂岩样本进行 2 倍过采样,用于平衡训练集和验证集中的砂岩和泥岩样本比例。过采样会降低训练集和验证集的拟合准确性,但会使模型更容易训练。第二步,训练储层类型预测的叠前深度学习模型时,从数据集中选取所有 650 个砂岩标签样本数据,以叠前远、中、近角度叠加地震数据作为输入,以测井解释三类储层类型划分结果作为输出。同样以 JS7 为盲井测试,其余样本的随机30% 为验证集,70% 为训练集。利用训练数据进行模型训练,进行适度的参数优化,得到岩性预测的叠后深度学习反演模型和用于储层类型预测的叠前深度学习反演模型,最终在单井、剖面、平面上验证深度学习反演储层预测效果。

2.3 储层预测结果

2.3.1 单井结果

通过测试盲井的预测结果分析深度学习对厚层、中层及薄层砂的预测能力。深度学习模型的输出是不同岩性和储层类型的后验概率,取后验概率大的类型即得到岩性和储层类型的预测结果。图 6 为测试盲井 JS7 井常规反演与深度学习反演岩性和储层类型的预测结果。深度学习反演比常规地震反演在1100、1150、1325 ms 处预测出更多的砂岩,与测井岩性吻合更好。在岩性约束下进行储层类型预测,深度学习反演对 JS7 井 1080 ms 处的 II 类储层预测更好。盲井 JS7 井预测结果表明,深度学习反演在岩性和储层类型的预测上,与测井岩性和储层类型的合更好,优于常规反演方法。

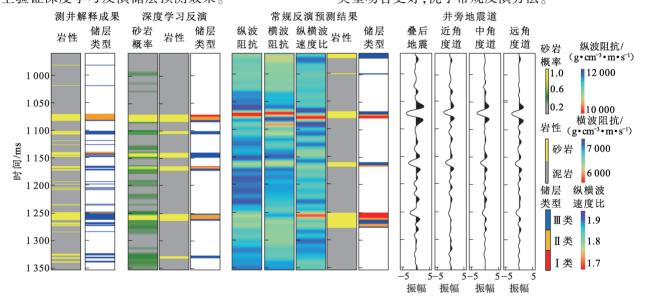


图 6 JS7 井岩性与储层类型预测结果

Fig. 6 Lithology and reservoir prediction for well JS7

图 7 为综合统计 13 口井预测砂体、I 类储层、II 类储层与测井厚度的交汇分析。如果按照能否预测出砂体进行统计,厚度大于 5 m 的砂体,深度学习反演的预测精度达到 92.5%,常规地震波阻抗反演预测精度 47.5%;如果按照预测的砂体厚度误差,厚度大于 5 m 的砂体,深度学习反演预测砂岩厚度平均相对误差在 34%,常规地震波阻抗反演预测砂岩厚度平均相对误差在 66%。薄层砂体预测上,深度学习展现出较高的精度。

按照能否预测出厚度大于 5 m 的 I 类或 II 类储 层进行统计,叠前深度学习反演 I 类储层预测精度 达到 83.3%, II 类储层预测精度达到 87.5%;常规 叠前反演 I 类储层预测精度为 33.3%, II 类储层预测精度为 69%。按照预测厚度大于 5 m 的 I 类或

Ⅱ类储层厚度误差,叠前深度学习反演 I 类储层厚度预测平均相对误差为 34%, Ⅱ类储层厚度预测平均相对误差为 15%;常规叠前反演 I 类储层厚度预测平均相对误差为 75%, Ⅲ类储层厚度预测平均相对误差为 72%。储层类型上,深度学习同样具有更好的预测能力。

预测厚度与测井厚度统计结果表明,深度学习 反演预测砂体、I 类和 II 类储层的精度都高于常规 地震反演方法,具有更好的预测能力。

2.3.2 剖面结果

图 8 为深度学习反演得到的砂岩概率、岩性以及储层类型剖面与常规地震反演得到的波阻抗、岩性和储层类型剖面,剖面 AB 位置见图 9。常规波阻抗反演分辨率低、连续性差,难以预测薄层砂岩,叠

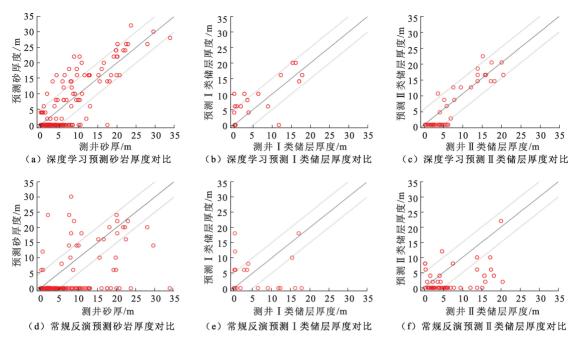


图 7 深度学习反演与常规反演预测砂岩、Ⅰ类、Ⅱ类储层厚度与测井厚度误差分析

Fig. 7 Accuracy of sand, I and II reservoirs predicted by deep learning model and conventional seismic inversion

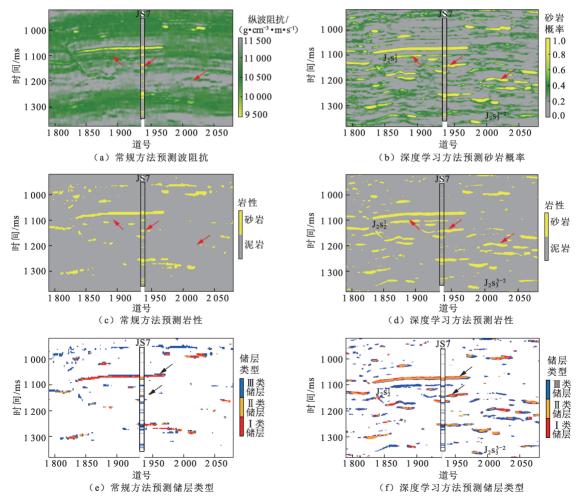


图 8 深度学习反演与常规反演预测岩性与储层类型剖面对比

Fig. 8 Profiles of predicted lithology and reservoirs predicted by deep learning model and conventional seismic inversion

后深度学习反演预测岩性分辨率高,预测砂岩与盲井 JS7 吻合率更高,如图 8(c)和(d)所示。常规地震反演方法需要首先预测纵波阻抗,然后根据岩石物理分析得到岩性分布,如图 8(a)和(c)所示。叠后深度学习反演可以直接得到砂岩概率剖面,不需要岩石物理分析,直接得到岩性结果,减少了大量的统计分析工作。砂岩概率剖面还可以为岩性分布提供更多参考信息,如图 8(b)和(d)所示。

常规和深度学习储层类型预测都是在岩性约束下进行,叠前深度学习反演预测储层类型与盲井JS7吻合更好,如图 8(e)和(f)所示。河道砂体内部不同方法预测的储层类型分布不同,在预测河道砂

体的约束下,深度学习反演预测优质储层 Ⅰ 类和 Ⅱ 类储层往往位于河道砂体中部, Ⅲ 类储层往往位于 河道砂体边部,更符合地质认识。

2.3.3 平面结果

图 9 和 10 为利用深度学习与常规反演预测岩性、储层类型数据体提取的 $J_2s_2^1$ 层和 $J_2s_3^{3-2}$ 层砂岩厚度、I 类和 II 类储层厚度。根据叠后反演预测 $J_2s_2^1$ 层和 $J_2s_3^{3-2}$ 层砂岩厚度图分析河道砂体展布,深度学习预测河道砂体连续性更好,两个层中都可以识别常规反演无法识别的小河道,如图 9(a) 和图 10(a)。盲井 JS7 可以证实预测 $J_2s_2^1$ 河道的存在,证明深度学习反演预测岩性分辨率更高且更准确,

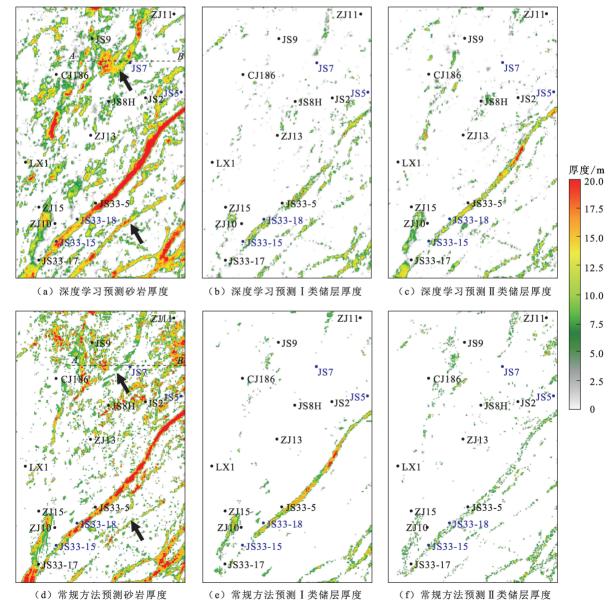


图 9 深度学习反演与常规反演预测 $J,s,^1$ 层砂岩厚度、I 类和 II 类储层厚度

Fig. 9 Sand and reservoir thickness of $J_2s_2^{-1}$ predicted by CWT-CNN and conventional seismic inversion

如图 8(d)和图 9(a)所示。分析 $J_2s_2^1$ 层和 $J_2s_3^{3-2}$ 层 物性较好的 I 类储层、II 类储层分布,由于深度学习和常规反演方法均利用叠前地震资料,两种方法均能在一定程度上预测河道内不同储层类型展布,如图 9 和图 10 所示。

在 $J_2s_3^{3-2}$ 层主力产气河道内,利用盲井 JS33-5、JS33-17、JS5 验证河道内部储层类型的预测精度,

JS33-15 和 JS33-18 井测试产气情况较好,分别为 6.47×10⁴ 和 11.4×10⁴ m³/d,深度学习反演结果证实以钻遇 I类储层为主;JS5 井测试产气 0.11×10⁴ m³/d,深度学习反演结果证实以钻遇 II 类和Ⅲ类储层为主。与常规叠后反演结果对比,深度学习反演预测不同储层类型厚度分布与生产测试情况更加吻合。

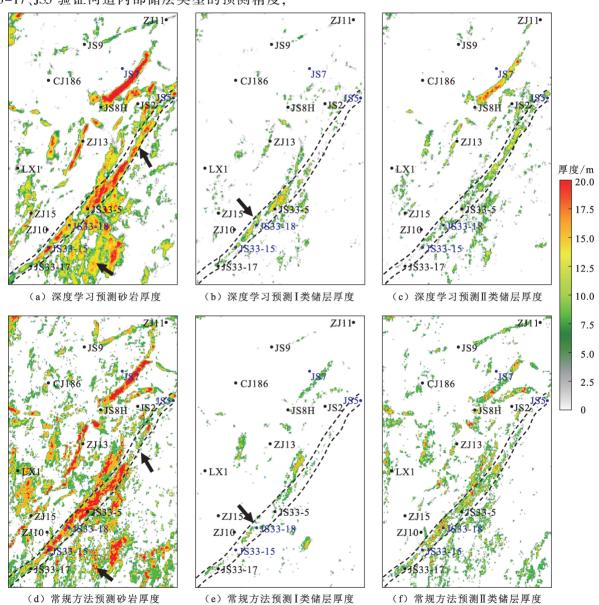


图 10 深度学习反演与常规反演预测 $J_2s_3^{3-2}$ 层砂岩厚度、I 类和 II 类储层厚度

Fig. 10 Sand and reservoir thickness of $J_2s_3^{3-2}$ predicted by CWT-CNN and conventional seismic inversion

3 结束语

基于小波变换和卷积神经网络的深度学习地震 反演方法可以实现储层参数的直接预测。通过结合 小波变换与卷积神经网络,有助于充分挖掘地震数 据高频和低频信息,能够提高地震预测的分辨率和 准确度。该方法以测井和井旁地震数据为训练数据,自动学习地震储层预测模式,不必要进行岩石物理分析等工作,但是岩石物理分析可以帮助制定有效的深度学习反演策略。将新方法成功应用于川西沙溪庙组储层预测中,制定了岩性与储层类型的层次约束预测思路,深度学习反演预测岩性和储层类

型的分辨率和精确更高,能够识别小河道砂体,与生产测试情况更加吻合,优于常规地震反演方法。提出的深度学习地震反演方法取得了较好的应用效果,具有较高推广应用价值,但仍处于初步探索阶段,更多深入的研究急需开展,如不同频谱分解方法的应用、模型泛化能力的提升、低频信息的融合、预测结果的不确定性评价等。

参考文献:

- [1] 林承焰,张宪国,董春梅. 地震沉积学及其初步应用 [J]. 石油学报,2007,28(2):69-72. LIN Chengyan, ZHANG Xianguo, DONG Chunmei. Concept of seismic sedimentology and its preliminary application [J]. Acta Petrolei Sinica, 2007,28(2):69-72.
- [2] 刘海,林承焰,董春梅,等. 基于地震沉积学的复杂曲流带沉积相研究[J]. 中国石油大学学报(自然科学版),2018,42(6):30-39.
 LIU Hai, LIN Chengyan, DONG Chunmei, et al. Sedimentary facies of complex meandering belt based on seismic sedimentology [J]. Journal of China University of Petroleum (Edition of Natural Science),2018,42(6):30-39.
- [3] BOSCH M, MUKERJI T, GONZALEZ E F. Seismic inversion for reservoir properties combining statistical rock physics and geostatistics: a review [J]. Geophysics, 2010,75(5):165-176.
- [4] 张国印,王志章,郭旭光,等. 准噶尔盆地乌夏地区风城组云质岩致密油特征及"甜点"预测[J]. 石油与天然气地质,2015,36(2):219-229.

 ZHANG Guoyin, WANG Zhizhang, GUO Xuguang, et al. Characteristics and 'sweet spot' prediction of dolomitic tight oil reservoirs of the Fengcheng Formation in Wuxia area, Junggar Basin [J]. Oil & Gas Geology, 2015, 36 (2):219-229.
- [5] HAMPSON D P, SCHUELKE J S, QUIREIN J A. Use of multi attribute transforms to predict log properties from seismic data[J]. Geophysics, 2001,66(1):220-236.
- [6] FATTAHI H, KARIMPOULI S. Prediction of porosity and water saturation using pre-stack seismic attributes; a comparison of Bayesian inversion and computational intelligence methods [J]. Computational Geosciences, 2016,20(5):1075-1094.
- [7] SCHMIDHUBER J. Deep learning in neural networks; an overview [J]. Neural Networks, 2015,61;85-117.
- [8] WALDELAND A U, JENSEN A C, GELIUS L J, et al. Convolutional neural networks for automated seismic interpretation [J]. The Leading Edge, 2018, 37 (7): 529-537.
- [9] WU X, LIANG L, SHI Y, et al. Fault Seg 3D: using

- synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation [J]. Geophysics, 2019,84(3):IM35-IM45.
- [10] WU H, ZHANG B, LIN T, et al. Semiautomated seismic horizon interpretation using the encoder-decoder convolutional neural network[J]. Geophysics, 2019,84 (6):B403-B417.
- [11] PHAM N, FOMEL S, DUNLAP D. Automatic channel detection using deep learning[J]. Interpretation, 2019, 7(3); SE43-SE50.
- [12] QIAN F, YIN M, LIU X Y, et al. Unsupervised seismic facies analysis via deep convolutional autoencoders [J]. Geophysics, 2018,83(3); A39-A43.
- [13] ZHANG G, WANG Z, CHEN Y. Deep learning for seismic lithology prediction [J]. Geophysical Journal International, 2018,215(2);1368-1387.
- [14] BISWAS R, SEN M K, DAS V, et al. Prestack and poststack inversion using a physics-guided convolutional neural network[J]. Interpretation, 2019,7(3):SE161-SE174.
- [15] STEEGHS P, DRIJKONINGEN G. Seismic sequence analysis and attribute extraction using quadratic time-frequency representations [J]. Geophysics, 2001,66(6): 1947-1959.
- [16] CHAKRABORTY A, OKAYA D. Frequency-time decomposition of seismic data using wavelet-based methods [J]. Geophysics, 1995,60(6):1906-1916.
- [17] ABDEL-HAMID O, MOHAMED A, JIANG H, et al.
 Convolutional neural networks for speech recognition
 [J]. IEEE/ACM Transactions on Audio, Speech, and
 Language Processing, 2014,22(10):1533-1545.
- [18] LIN J, QU L. Feature extraction based on Morlet wavelet and its application for mechanical fault diagnosis [J]. Journal of Sound and Vibration, 2000,234(1):135-148.
- [19] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines [C/OL]. Proceedings of the 27th International Conference on Machine Learning (ICML-10), June 21-24, 2010, Haifa, Israel. Omnipress, 2010. [2019-05-20]. http://www.cs. toronto.edu/~fritz/absps/reluICML.pdf
- [20] KLINE D M, BERARDI V L. Revisiting squared-error and cross-entropy functions for training neural network classifiers [J]. Neural Computing & Applications, 2005,14(4):310-318.
- [21] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014,15(1):1929-1958.

(编辑 修荣荣)