

褶积神经网络高分辨率地震反演

张繁昌*^① 刘汉卿^① 钮学民^② 代荣获^①

(^①中国石油大学(华东)地球科学与技术学院,山东青岛 266555; ^②中国石化胜利油田物探研究院,山东东营 257022)

张繁昌,刘汉卿,钮学民,代荣获. 褶积神经网络高分辨率地震反演. 石油地球物理勘探, 2014, 49(6):1165-1169.

摘要 随着地震勘探精细化要求的提高,薄层及横向变化大的复杂储层反演越来越重要。而当前反演方法大多基于褶积模型,分辨率较低。本文提出了基于褶积神经网络的反演方法,该方法完全由数据驱动,不受褶积模型的限制。褶积神经网络具有层状结构,其输入输出之间的映射关系用褶积算子来描述,而非内积算子。基于褶积神经网络结构,本文给出了映射算子的优化算法,并将其应用到地震反演中。应用结果表明,通过褶积神经网络地震反演,可以获得比常规稀疏脉冲反演分辨率更高的地层波阻抗剖面。

关键词 褶积神经网络 高分辨率 映射算子 数据驱动 地震反演

中图分类号:P631 文献标识码:A

1 引言

测井约束反演是储层表征的关键技术之一。目前复杂储层的精细表征,例如寻找碎屑岩薄互层^[1]、非均质碳酸盐岩储层^[2]等,需要高分辨率的地震反演结果。目前业界广泛应用的是以地震资料为硬数据的稀疏脉冲反演方法^[3~5],但其纵向分辨率达不到此类储层精细表征的要求;以测井资料为硬数据的随机反演方法虽然反演的剖面纵向分辨率很高,但横向展布和地层产状的变化与地震剖面有较大出入。为充分挖掘地震数据中包含的地层岩性及物性信息,提出了基于褶积神经网络模型的数据驱动反演方法,以提高反演结果的分辨率。

常规监督型前馈神经网络^[6,7]模型中,输入输出之间的映射是内积运算^[8]。由于地层反射系数映射到地震数据并非简单的内积运算,Fukushima等^[9]发展了二维神经网络结构,Lawrence等^[10]、Fu^[11]和Lecun等^[12]提出了褶积神经网络结构。与内积型神经网络相比,褶积神经网络的稳定性和抗噪性更强,但褶积神经网络并非具有统一结构,不能直接应用于地震反演。本文将褶积算子融入到神经

网络中,构建了多层褶积神经网络,并将其应用到地震反演中,可得到较高分辨率的地层波阻抗剖面。

2 褶积神经网络反演原理

2.1 网络结构及输入输出关系

多层前馈褶积网络具有层状结构,由输入层、输出层、一个或多个隐层构成,其结构参数包括输入层尺寸、感受野尺寸^[13]、层数、连接方式等。每层有若干个节点,每个节点只与相邻层的节点连接,层内节点之间不相连。

在褶积神经网络中,层间连接方式有全连接、二叉连接和Toeplitz连接三种方式。在全连接中,每个节点与随后层的所有节点相连接,类似于普通的神经网络。二叉连接和Toeplitz连接是部分连接方式。二叉连接表示每一个节点只连接到随后层的两个节点上,Toeplitz连接是每个节点连接到随后层的多个节点上,如图1所示。Toeplitz连接可减少连接数量,增加神经网络的外推稳定性。

图2为多层褶积神经网络结构,节点之间按照Toeplitz方式连接,其中每一行表示一信号序列,是输入信号与映射算子褶积后再进行非线性运算的结

* 山东省青岛市中国石油大学地球科学与技术学院,266555。Email:zhangfch@upc.edu.cn

本文于2013年10月9日收到,最终修改稿于2014年8月24日收到。

本研究受国家“863”项目(2011AA060302)、国家“973”项目(2013CB228604)和中国石油大学(华东)研究生创新工程基金项目(YCX2014003)联合资助。

果。每一行的信号序列即每一个节点的分节点,其映射算子相同。

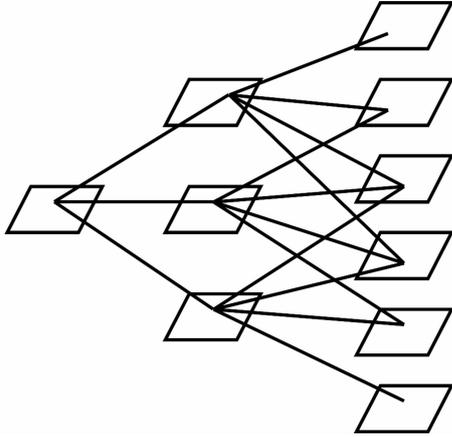


图1 Toeplitz 连接方式

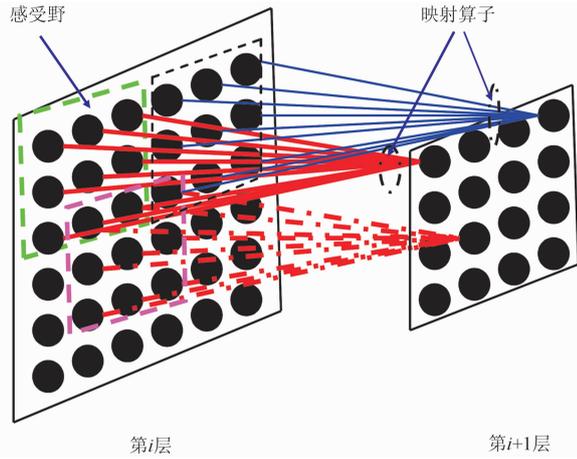


图2 褶积神经网络结构

每一行信号序列与前一层的连接关系由 Toeplitz 连接方式决定。每个分节点从先前层的感受野中获得输入,每个隐层都有固定的感受野,不同隐层的感受野尺寸可以不同。图 2 表示第 $i+1$ 层每行的节点与第 i 层每一行的三个节点相连,服从褶积运算。

在褶积神经网络中,节点的输入输出关系为

$$y_{hj}^{(k)}(t) = g_j^{(k)} \left(\sum_{i=1}^{N_{k-1}} \sum_{\tau=0}^t W_{ij}^{(k)}(\tau) y_{hi}^{(k-1)}(t-\tau) \right) \quad (1)$$

式中: $y_{hj}^{(k)}(t)$ 为第 k 层第 j 个节点的输出序列; $W_{ij}^{(k)}(t)$ 为第 k 层第 j 个节点到第 $k-1$ 层第 i 个节点的连接权,即映射算子; $g_j^{(k)}$ 为传递函数^[14]; N_k 为第 k 层节点数目; h 为训练样本数,在地震反演中即是井的数目。映射算子能够自适应优化,从而使网络具备时变学习能力。

2.2 映射算子的优化过程

褶积神经网络反演分为映射算子优化和反演外推两个阶段。在算子优化阶段,将井中波阻抗加载到输入层,在输出层得到合成地震记录,通过实测地震记录与网络输出地震记录的误差,优化映射算子,直至二者的误差足够小为止。在反演外推阶段,将初始波阻抗模型加载到输入层,实测地震数据仍作为期望输出,利用训练好的网络修改波阻抗模型,直至网络输出地震记录与实测地震记录达到最佳匹配,最终得到反演结果。

映射算子的优化采用误差反传法^[15]。在地震反演过程中,将波阻抗加载到输入层节点,隐层和输出层节点的输入输出满足式(1)。将式(1)中的输入记为

$$\sum_{i=1}^{N_{k-1}} \sum_{\tau=0}^t W_{ij}^{(k)}(\tau) y_{hi}^{(k-1)}(t-\tau) = N_{hj}^{(k)}(t) \quad (2)$$

若第 h 口井的波阻抗为 $[y_{h1}^{(0)}(t), \dots, y_{hN_0}^{(0)}(t)]$, 利用式(1)可得到网络输出,即合成地震记录为 $[y_{h1}^{(M)}(t), \dots, y_{hN_M}^{(M)}(t)]$, 此合成记录与实测地震记录的误差为

$$E_h = \frac{1}{2} \sum_m \sum_t [y_{hm}(t) - y_{hm}^M(t)]^2 \quad (3)$$

其中 $(y_{h1}(t), \dots, y_{hN_m}(t))$ 为实测地震记录; m 表示第 m 个节点, M 为总层数。将 E_h 对每个算子求导

$$\begin{aligned} \frac{\partial E_h}{\partial W_{ij}(\tau)} &= \frac{\partial E_h}{\partial N_{hj}(t)} \cdot \frac{\partial N_{hj}(t)}{\partial W_{ij}(\tau)} \\ &= \frac{\partial E_h}{\partial N_{hj}(t)} \cdot y_{hi}(t-\tau) \end{aligned} \quad (4)$$

定义误差传播项为

$$\delta_{hj}(t) = - \frac{\partial E_h}{\partial N_{hj}(t)} \quad (5)$$

则式(4)可写为

$$- \frac{\partial E_h}{\partial W_{ij}(\tau)} = \delta_{hj}(t) \cdot y_{hi}(t-\tau) \quad (6)$$

若要使 E_h 按梯度下降,第 k 层到第 $k-1$ 层的映射算子调整量为

$$\Delta_h W_{ij}(t) = \delta_{hj}(t) * y_{hi}(-t) \quad (7)$$

式中“ $*$ ”为褶积。其中 $y_{hi}(-t)$ 容易得到,对 $\delta_{hj}(t)$ 则需继续进行分解。

$$\begin{aligned} \delta_{hj}(t) &= - \frac{\partial E_h}{\partial N_{hj}(t)} = - \frac{\partial E_h}{\partial y_{hj}(t)} \cdot \frac{\partial y_{hj}(t)}{\partial N_{hj}(t)} \\ &= - \frac{\partial E_h}{\partial y_{hj}(t)} \cdot g'_j[N_{hj}(t)] \end{aligned} \quad (8)$$

式中: $g'_j[N_{hj}(t)]$ 为传递函数的导数。 $\delta_{hj}(t)$ 分两种情况计算: 当 j 为输出层节点时, 有

$$\frac{\partial E_h}{\partial y_{hj}(\tau)} = -(y_{hj}(\tau) - y_{hj}^M(\tau)) = -e_j(\tau) \quad (9)$$

带入式(8)可得

$$\delta_{hj}(t) = e_j(t) \cdot g'_j(N_{hj}(t)) \quad (10)$$

当 j 为隐层节点时, 有

$$\frac{\partial E_h}{\partial y_{hj}(\tau)} = \sum_l \sum_t \frac{\partial E_h}{\partial N_{hl}(t)} \cdot \frac{\partial N_{hl}(t)}{\partial y_{hj}(\tau)} \quad (11)$$

由于

$$\frac{\partial N_{hl}(t)}{\partial y_{hj}(\tau)} = \frac{\partial \left[\sum_i W_{il}(t) * y_{hi}(t) \right]}{\partial y_{hj}(\tau)} = W_{jl}(t - \tau) \quad (12)$$

故

$$\begin{aligned} \frac{\partial E_h}{\partial y_{hj}(\tau)} &= \sum_l \sum_t \frac{\partial E_h}{\partial N_{hl}(t)} \cdot W_{jl}(t - \tau) \\ &= - \sum_l \sum_t \delta_{hl}(t) \cdot W_{jl}(t - \tau) \\ &= - \sum_t \delta_{hl}(\tau) * W_{jl}(-\tau) \end{aligned} \quad (13)$$

代入式(8)得

$$\delta_{hj}(t) = g'_j[N_{hj}(t)] \sum_l \delta_{hl}(t) * W_{jl}(-t) \quad (14)$$

式(9)中 $e_j(\tau)$ 为实际地震数据与合成地震记录的差; 式(11)中 l 表示第 l 个节点。每次迭代分别由式(10)、式(14)得到输出层和隐层节点的误差传播项, 再代入式(7)计算映射算子的调整量, 优化映射算子, 直到式(3)的误差函数足够小为止。

2.3 传递函数的选取

褶积神经网络将地震反演问题表示为测井波阻抗与地震数据之间的非线性映射。由于反射系数是地层对数阻抗 $p(t)$ 的微分^[16], 可设传递函数为

$$g[p(t)] = \frac{d \ln[p(t)]}{dt} \quad (15)$$

这样, 对于具有双层结构的褶积神经网络, 以井中 $p(t)$ 作为输入, 相应的井旁地震道 $x(t)$ 作为期望输出, 反复训练网络, 使输出地震道与实测地震道一致。褶积神经网络经训练后, 满足

$$x(t) = \frac{d \ln \left\{ \left[\frac{d \ln(p(t) * W_1(t))}{dt} \right] * W_2(t) \right\}}{dt} \quad (16)$$

从式(16)看出, 每一层的输出是对地震道的一次逼近。

3 方法测试

褶积神经网络反演是一种数据驱动的反演方法, 不再受 Robinson 褶积模型^[17,18]的限制, 反演结果具有较高的纵向分辨率。为了验证该方法的有效性, 首先对模型地震剖面进行了常规稀疏脉冲反演和褶积神经网络反演。图 3 是波阻抗模型, 其中包含断层、透镜体、尖灭和薄层(图中椭圆内), 图 4 为对应的地震剖面。对图 4 的地震剖面进行反演, 所得的稀疏脉冲反演剖面如图 5 所示, 而图 6 是褶积神经网络方法的反演剖面。

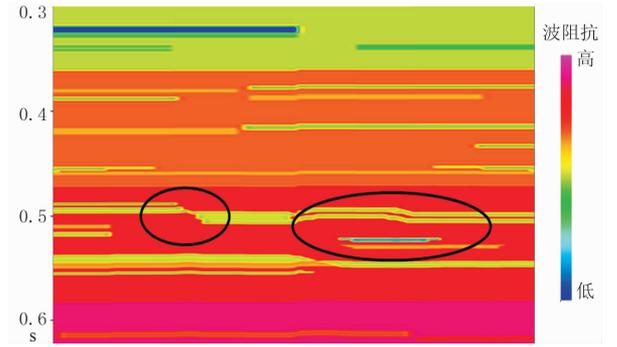


图 3 波阻抗模型



图 4 地震剖面

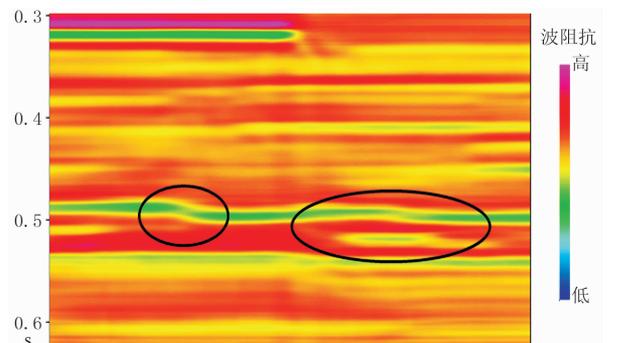


图 5 常规稀疏脉冲反演结果

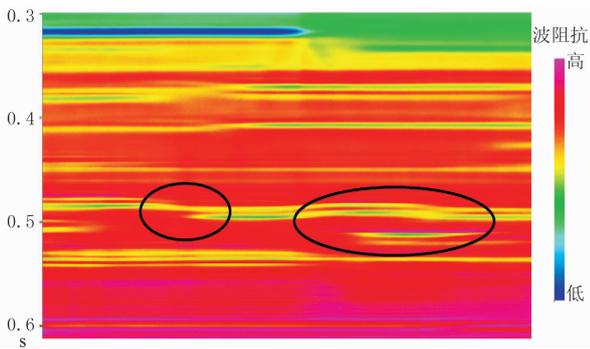


图6 褶积神经网络反演结果

对比图5及图6看出,常规稀疏脉冲反演剖面可以反映宏观地质规律,但分辨率较低,没有分辨出透镜体和薄层等细微的地层变化(图中椭圆内),而褶积神经网络反演结果分辨率明显提高,几乎完全恢复透镜体和薄层的真实形状(图中椭圆内)。

4 实际数据应用

图7为A油田的一段地震剖面。该区主力储层为河流相沉积,目的层段储层较薄,薄互层发育,且层系横向变化大。

图8为常规稀疏脉冲反演波阻抗剖面,图中的

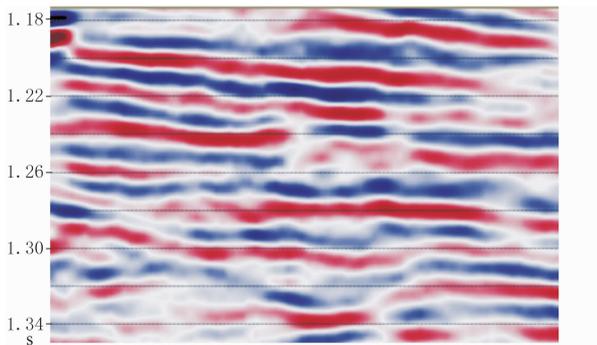


图7 A油田地震剖面

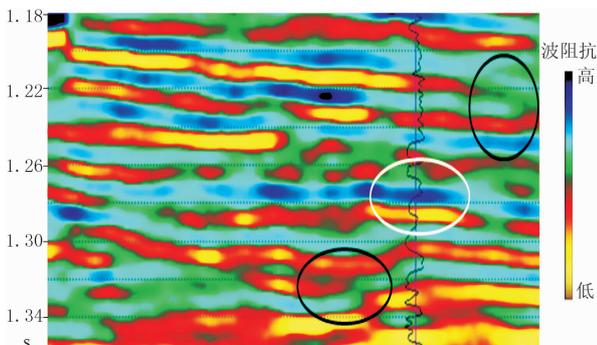


图8 常规稀疏脉冲波阻抗剖面

曲线为井中波阻抗曲线。由于受地震数据分辨率的限制,反演剖面只能反映大套砂组,无法满足该区薄层精细划分的要求。图9为褶积神经网络反演波阻抗剖面,反演结果具有较高的纵向分辨率,在井位置与测井波阻抗吻合较好,如图中位于1.26s以及1.28s附近的3.6m和5.3m厚的储层;该反演结果还可将图8中不能分辨的薄层区分开,例如位于黑色椭圆位置的薄储层得以分辨。

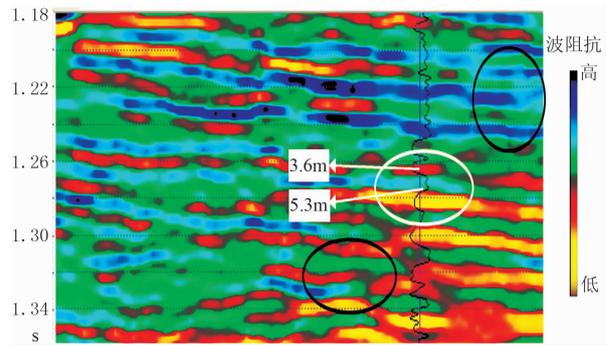


图9 褶积神经网络反演剖面

5 结束语

常规稀疏脉冲反演方法由于分辨率较低,在薄层识别和储层非均质性研究中受到限制。本文通过分析地震反演过程中测井与地震数据的非线性关系,提出了多层褶积神经网络反演方法。该方法是一种数据驱动的反演方法,不受Robinson褶积模型的限制。

褶积神经网络地震反演分为两个阶段。首先利用井数据对网络进行训练,得到井数据和井旁地震数据之间的映射关系;然后在地震数据的引导下,在外推反演阶段迭代修改加载到输入层的初始波阻抗模型,获得波阻抗反演剖面。模型和实际资料的反演结果表明,该方法得到的反演剖面不仅整体面貌与地震剖面一致,而且在一定程度上能够提高反演结果的纵向分辨率,有利于识别较薄的地层。

参考文献

[1] 李国发,岳英,熊金良等. 基于三维模型的薄互层振幅属性实验研究. 石油地球物理勘探, 2011, 46(1): 115-120.
Li Guofa, Yue Ying, Xiong Jinliang et al. Experimental study on seismic amplitude attribute of thin interbed based on 3D model. OGP, 2011, 46(1):

- 115-120.
- [2] 林忠民. 塔河油田奥陶系碳酸盐岩储层特征及成藏条件. 石油学报, 2002, 23(3): 23-26.
Lin Zhongmin. Carbonate rock reservoir features and oil gas accumulating conditions in the Ordovician of Tahe Oilfield in northern Tarim Basin. Acta Petroleii Sinica, 2002, 23(3): 23-26.
- [3] 郭朝斌, 杨小波, 陈红岳等. 约束稀疏脉冲反演在储层预测中的应用. 石油物探, 2006, 45(4): 397-400.
Guo Chaobin, Yang Xiaobo, Chen Hongyue et al. Constrained sparse pulse inversion research in north of Haitongji depression. GPP, 2006, 45(4): 397-400.
- [4] 李爱山, 印兴耀, 张繁昌等. 叠前 AVA 多参数同步反演技术在含气储层预测中的应用. 石油物探, 2007, 46(1): 64-68.
Li Aishan, Yin Xingyao, Zhang Fanchang et al. Application of prestack simultaneous AVA multi-parameter inversion in gas-bearing reservoir prediction. GPP, 2007, 46(1): 64-68.
- [5] 印兴耀, 张世鑫, 张繁昌等. 利用基于 Russell 近似的弹性波阻抗反演进行储层描述和流体识别. 石油地球物理勘探, 2010, 45(3): 373-380.
Yin Xingyao, Zhang Shixin, Zhang Fanchang et al. Utilizing Russell approximation-based elastic wave impedance inversion to conduct reservoir description and fluid identification. OGP, 2010, 45(3): 373-380.
- [6] 徐雷, 迟惠生. 静态前馈型网络的监督学习方法研究进展. 电子学报, 1992, 20(10): 106-113.
Xu Lei, Chi Huiheng. Research advances on supervised learning of static feedforward networks. Acta Electronica Sinica, 1992, 20(10): 106-113.
- [7] 王钰, 郭其一, 李维刚. 基于改进 BP 神经网络的预测模型及其应用. 计算机测量与控制, 2005, 13(1): 39-42.
Wang Yu, Guo Qiyi and Li Weigang. Predictive model based on improved BP neural networks and Its application. Computer Measurement & Control, 2005, 13(1): 39-42.
- [8] 郑永爱. 内积空间的特征. 数学杂志, 1995, 15(4): 477-484.
Zheng Yongai. Characterizations of inner product spaces. Journal of Mathematics, 1995, 15(4): 477-484.
- [9] Fukushima K, Miyake S and Ito T. Neocognitron: A neural network model for a mechanism of visual pattern recognition. IEEE Transactions on Systems, Man and Cybernetics, 1983, 13(5): 826-834.
- [10] Lawrence S, Giles C L, Tsoi A C et al. Face recognition: A convolutional neural-network approach. IEEE Transactions on Neural Networks, 1997, 8(1): 98-113.
- [11] Fu L Y. Caianiello neural network method for geophysical inverse problems. Handbook of Geophysical Exploration; Seismic Exploration, 2001, 30: 187-215.
- [12] Lecun Y et al. Backpropagation applied to handwritten zip code recognition. Neural Computation, 1989, 1(4): 541-551.
- [13] Olshausen B A. Emergence of simple-cell receptive field properties by learning a sparse code for natural images. Nature, 1996, 381(6583): 607-609.
- [14] 张繁昌, 印兴耀. 用模拟退火神经网络技术进行波阻抗反演. 石油大学学报(自然科学版), 1997, 21(6): 16-18.
Zhang Fanchang, Yin Xingyao. Impedance inversion by using annealing neural network. Journal of the University of Petroleum, 1997, 21(6): 16-18.
- [15] 陈善广, 鲍勇. BP 神经网络学习算法研究. 应用基础与工程科学学报, 1995, 3(4): 437-442.
Chen Shanguang, Bao Yong. Studies on learning algorithms for BP net. Journal of Basic Science and Engineering, 1995, 3(4): 437-442.
- [16] 张繁昌, 印兴耀, 印海燕. 基于共轭方向置换的叠前三参数反演方法及其实现. 石油地球物理勘探, 2009, 44(4): 430-435.
Zhang Fanchang, Yin Xingyao and Yin Haiyan. Prestack three-term inversion based on conjugate direction substitution and realization. OGP, 2009, 44(4): 430-435.
- [17] Robinson E A. Predictive decomposition of time series with application to seismic exploration. Geophysics, 1967, 32(3): 418-484.
- [18] Robinson E A. Predictive decomposition of seismic traces. Geophysics, 1957, 22(4): 767-778.

(本文编辑:金文昱)

作者简介



张繁昌 教授, 1972 年生; 1994 年本科毕业于石油大学(华东) 勘查地球物理专业, 1998 年和 2004 年先后获得石油大学(华东) 应用地球物理专业硕士和地质资源与地质工程专业博士学位; 主要从事地震信号处理、地球物理反演、油气储层预测等方面的研究。现在中国石油大学(华东) 从事石油地球物理勘探领域的教学工作。