

基于BP神经网络的地震资料高频补偿

刘正文¹ 胡瑞卿^{2*} 陈飞旭¹ 顾小弟² 王兴军¹

1 中国石油塔里木油田分公司勘探开发研究院 2 东方地球物理公司研究院

DOI:10.12238/gmsm.v7i7.1892

[摘要] 常规地面数据常受分辨率问题的困扰,其主要原因为地震波传播过程中的地层对高频成分的吸收及衰减效应。而采用井间地震方法测得的井间地震数据则具有较高的分辨率。本文采用三层BP神经网络建立高频成分吸收衰减系统的逆响应模型以关联两类具有不同分辨率的数据——常规地面地震数据与井间地震数据。以常规地面地震数据作为网络输入,井间地震数据作为输出,通过逆响应模型进行高频补偿。从而达到提高常规地面地震资料分辨率的目的。针对某油田K1区块,本文提出的方法有效地提高主频约12Hz,频带宽度拓宽约8Hz。

[关键词] 高频补偿; BP神经网络; 井间地震

中图分类号: P631.4 文献标识码: A

High frequency compensation of seismic data based on BP Neural Network

Zhengwen Liu¹ Ruiqing Hu^{2*} Feixu Chen¹ Xiaodi Gu² Xingjun Wang¹

1 Research Institute of Exploration and Development Tarim Oil field Company

2 Geophysical Research Institute, BGP,

[Abstract] The surface seismic data has always been suffering from the problem of low resolution because of the absorption and the attenuation in the strata, while the cross-well seismic data has much higher resolution. In this paper, a three-layer BP neural network is employed to build the model which simulates the inversion response system of the absorption in the strata and connects these two kinds of seismic data. The surface seismic data is set as the input of the BP neural network model which can improve its resolution by recovering the high frequency component. The high frequency components are compensated and the resolution of the seismic data is enhanced. The practical results demonstrate that the frequency of the surface seismic data is increased about 12Hz and the frequency bandwidth is broadened about 8Hz.

[Key words] High frequency compensation; BP Neural Network; cross-well seismic

引言

分辨率是评估地震数据品质的重要参数之一,而影响地震资料分辨率的主要因素则是地层对高频成分的吸收及衰减效应。对常规地震勘探而言,地震波在地下介质中传播时,高频成分的衰减是无法避免的。而对井间地震勘探而言,高频成分的吸收大幅减弱,故该方法测得的数据具有主频较高的特点,同时也具有较高的分辨率,但由于受到成本及技术要求的限制,该勘探方法难以被广泛应用于各油田生产工区。

由于观测方法的不同,地震波在地层中的传播路径不同,导致井间地震勘探方法中地震波的吸收与衰减程度相比常规地震勘探方法要大幅降低。而常规地面地震数据与井间地震数据均在工区内,均反映相同的地质目标,两者具有直观的物理关联性,为两类数据体间关联系统的建立提供了理论基础。

本文采用BP神经网络建立关联系统逆响应模型,有效地对

常规地震数据进行高频分成的补偿以达到提高其分辨率的目的。文中采用已测得的常规三维地震数据与二维井间地震数据作为训练样本,训练完成后,对全区常规地震数据进行处理,得到全区内的高分辨资料。

1 BP神经网络的学习算法

BP神经网络的学习过程,实质上是权值矩阵与阈值的调整过程。BP神经网络采用最速下降法,将误差反向传播,逐层调整权值与阈值。以三层BP神经网络为例,其学习算法如下:

样本输入数组正向传播结束后,得到模型输出 O_k 。计算模型输出 O_k 与样本输出 d_k 的误差函数 E :

$$E = \frac{1}{2} \sum_{k=1}^m (d_k - O_k)^2 \quad (1)$$

其中 m 为样本输出数组的长度。

对于输出层与隐层间的权值调整量, 以输出层第 k 个神经元的第 i 个输入数据所对应的权值 ω_{jk} 为例, 有:

$$\Delta\omega_{jk} = -\eta \frac{\partial E}{\partial \omega_{jk}} = -\frac{\partial E}{\partial I_k} \cdot \frac{\partial I_k}{\partial \omega_{jk}} \cdot \eta \quad (2)$$

其中 η 为学习速率, 在训练过程中可进行控制调节, 优化训练速度。

定义局部梯度 δ_k :

$$\delta_k = -\frac{\partial E}{\partial I_k} = -\frac{\partial E}{\partial O_k} \cdot \frac{\partial O_k}{\partial \omega_{jk}} \quad (3)$$

其中: $\frac{\partial E}{\partial O_k} = -(d_k - O_k)$, I_k 为输出层第 k 个神经元

的输入, O_k 为输出层第 k 个神经元的输出。

又有:

$$\begin{aligned} \frac{\partial O_k}{\partial I_k} &= \frac{\partial f(I_k)}{\partial I_k} = \\ &f(I_k) \cdot [1 - f(I_k)] = O_k(1 - O_k) \end{aligned} \quad (4)$$

$$\frac{\partial I_k}{\partial \omega_{jk}} = \frac{\partial [\sum_{j=1}^H \omega_{jk} \cdot O_j]}{\partial \omega_{jk}} = O_j \quad (5)$$

其中 O_j 为隐层第 j 个神经元的输出, f 为激活函数。 H

为隐层神经元个数。

则权值 ω_{jk} 的修正量:

$$\Delta\omega_{jk} = \eta \cdot \delta_k \cdot O_j \quad (6)$$

或写为:

$$\Delta\omega_{jk} = \eta \cdot O_k(1 - O_k)(d_k - O_k)O_j$$

对于隐层与输入层间的权值调整量, 以隐层第 j 个神经元的第 i 个输入数据所对应的权值 ω_{ij} 为例, 有:

$$\Delta\omega_{ij} = -\eta \cdot \frac{\partial E}{\partial I_j} \cdot \frac{\partial I_j}{\partial \omega_{ij}} = -\eta \cdot \frac{\partial E}{\partial I_j} \cdot O_i \quad (7)$$

又有:

$$\begin{aligned} -\frac{\partial E}{\partial I_j} &= -\frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial I_j} = \left(\sum_{k=1}^m \frac{\partial E}{\partial I_k} \cdot \frac{\partial I_k}{\partial O_j} \right) \cdot \frac{\partial f(I_j)}{\partial I_j} \\ &= \sum_{k=1}^m \left[\left(-\frac{\partial E}{\partial I_k} \right) \cdot \frac{\partial \left[\sum_{j=1}^H \omega_{jk} \cdot O_j \right]}{\partial O_j} \right] \cdot \frac{\partial f(I_j)}{\partial I_j} \\ &= \sum_{k=1}^m (\delta_k \cdot \omega_{jk}) \cdot f'(I_j) \end{aligned} \quad (8)$$

其中 I_i 为隐层第 i 个神经元的输入。

则权值 ω_{ij} 的修正量:

$$\Delta\omega_{ij} = \eta \cdot f'(I_j) \cdot \left(\sum_{k=1}^m \delta_k \cdot \omega_{jk} \right) \cdot O_i \quad (9)$$

或写为:

$$\Delta\omega_{ij} = \eta O_i(1 - O_i) \left(\sum_{k=1}^m \delta_k \cdot \omega_{jk} \right) \cdot O_i$$

2 BP神经网络建模

2.1 样本集的建立

如图1所示, 井K1-3与K1-120间, 提取地面地震数据道作为输入样本(蓝色), 提取井间地震数据道作为输出样本(黄色)。两种勘探方法布线方式不同, 需根据道头信息选取坐标相同的数据道配对成输入-输出样本集。如表1所示, X数组表示地面地震资料中提取的输入样本组, Y数组表示井间地震资料中提取的输出样本组。

2.2 隐层节点数的选取

针对实际情况的隐层节点数的确定一直没有可靠的理论依据, 故常采用经验判断。本文针对目标工区, 对3至11范围内的节点数进行实验, 并选取最优解。

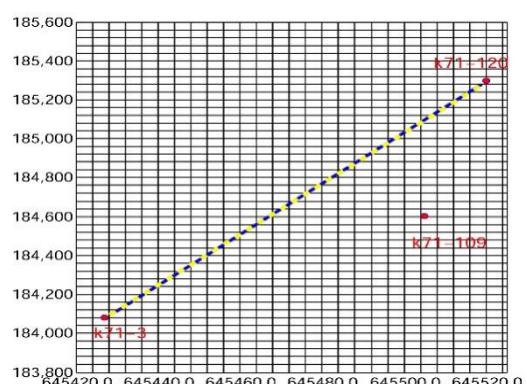


图1 训练样本集的选取

根据2.1中建立的输入输出样本集,依次设置节点数为3, 4, 5, 6, 7, 8, 9, 10, 11(结点数过高导致计算成本过高,故设置结点数上限为11),逐次训练网络,至权值调整合适,网络趋近稳定时,记录均方误差值MSE。实验结果如图2所示,可见当隐层节点数为6时,MSE值最小,为0.0059956。

表1 训练样本集

含油污泥组成	水	原油	泥砂
质量含量(%)	2	50.1	47.9

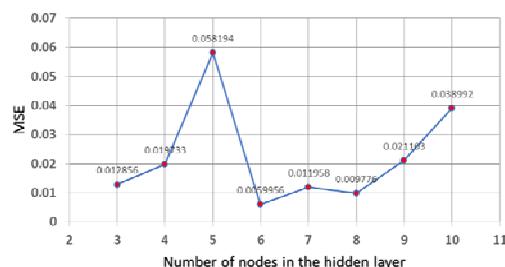


图2 隐层节点数与均方误差关系图

Sample 1		Sample i		Sample m	
Coordinate(645430, 184770)		Coordinate(645500, 184540)		Coordinate(645520, 185070)	
X ₁₁	Y ₁₁	X _{i1}	Y _{i1}	X _{m1}	Y _{m1}
X ₁₂	Y ₁₂	X _{i2}	Y _{i2}	X _{m2}	Y _{m2}
X ₁₃	Y ₁₃	X _{i3}	Y _{i3}	X _{m3}	Y _{m3}
X ₁₄	Y ₁₄	X _{i4}	Y _{i4}	X _{m4}	Y _{m4}
X ₁₅	Y ₁₅	X _{i5}	Y _{i5}	X _{m5}	Y _{m5}
⋮	⋮	⋮	⋮	⋮	⋮
X _{1j}	Y _{1j}	X _{ij}	Y _{ij}	X _{mj}	Y _{mj}
⋮	⋮	⋮	⋮	⋮	⋮
X _{1n}	Y _{1n}	X _{in}	Y _{in}	X _{mn}	Y _{mn}

2.3 建模流程步骤

(1) 网络参数初始化。包括各节点的权值 ω , 阈值b以及学习速率 η 。通常将参数设置接近于0的随机数。(2)选取输入样本,由输入层正向传入隐层,至输出层,得到输出结果。(3)将输出结果与输出样本对比,计算误差E。将误差反向传回隐层各神经元节点。(4)根据各节点上误差大小,修改权值与阈值。(5)重复步骤(2)至(4),直到误差达到最小或可接收范围内。(6)训练完成,保存网络。

详细流程如图3所示:

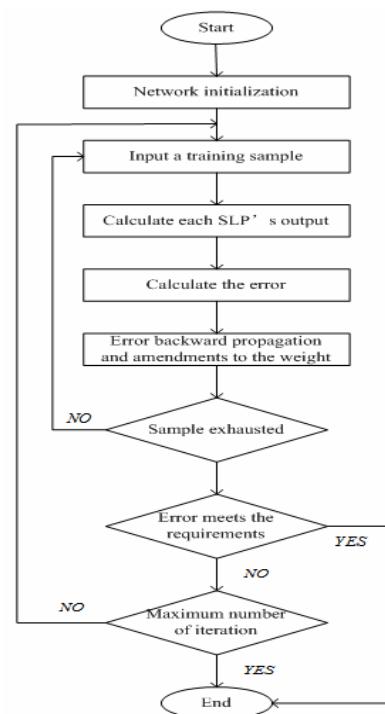
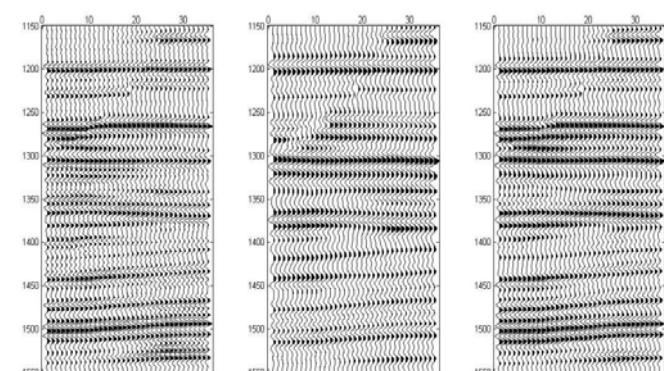


图3 BP神经网络建模流程图

3 实际资料处理结果分析

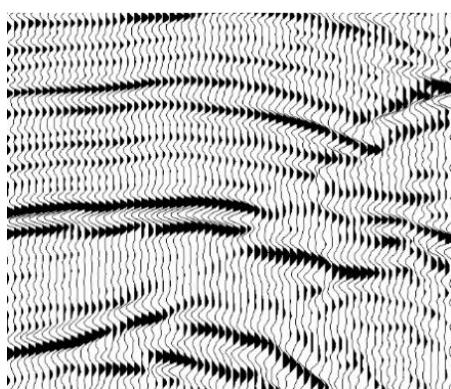
以某油田K71区块资料为例,该区块内共计6组井间地震资料,全区已进行常规三维地面地震勘探,根据本文提出的方法,对常规三维地面地震资料进行高频补偿。图4为井间资料剖面图,及常规地面地震资料高频补偿前后对比。图5为测线530剖面图。通过资料处理前后对比,可见经过高频补偿处理后,层位信息更丰富,较弱的层位信息得到增强,部分薄层对应的同相轴显现,在保证主要特征不变的条件下,有效提高了地震资料的分辨率。

该工区资料处理前后频谱对比如图6所示。处理后主频提高约12Hz,优势频带宽度提高约8Hz。

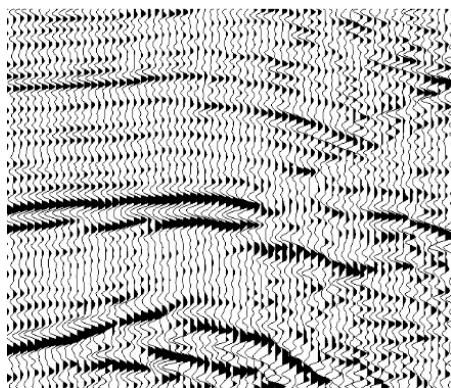


a. 井间地震剖面 b. 常规地震资料剖面 c. 高频补偿后资料剖面

图4 井间地震资料剖面及高频补偿前后资料剖面对比



a. 高频补偿前



b. 高频补偿后

图5 Line530测线处, 高频补偿前后剖面对比

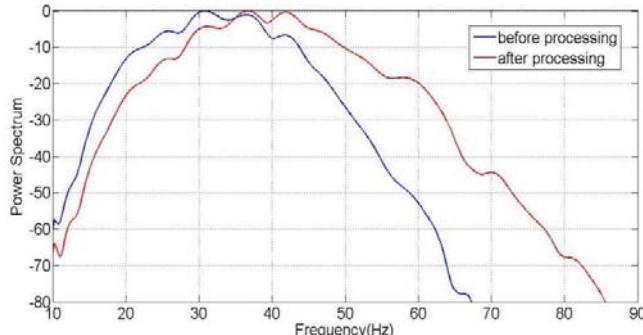


图6 高频补偿前后资料频谱分析对比

4 结论

本文基于BP神经网络建模的方法,提出一种联合多尺度地震资料进行高频补偿的新方法,该方法具有理论可靠性与实际可行性。通过对某油田K71区块的处理分析,结果显示该方法可一定程度地恢复常规地面地震勘探中,地震波传播时被地层吸

收以及衰减的高频成分。处理结果及频谱分析均表明该方法的良好效果。

[参考文献]

[1]Feng Gao, Prediction of sand thickness using seismic attributes based on BP-neural network[J]. Advanced Materials Research,2012;524:180–183.

[2]Yingming Zhou, Shuwei Wang.An Application of BP Neural Network Model to Predict the Moisture Content of Crude Oil[J].Advanced Materials Research,2012;527:1327–1330.

[3]Wongpa J,Kiattikomol K,Jaturapitakkul C, Chindaprasirt P, Compressive strength, modulus of elasticity, and water permeability of inorganic polymer concrete[J]. Mater Design, 2010;31:4748–4754.

[4]Pak J, Jang J, Bhadeshia HKDH, Karlsson L, Optimization of neural network for Charpy toughness of steel welds[J]. Mater Manuf Process,2009;24:16–21.

[5]M. Desbazeille, R.B. Randall, F. Guillet, M. El Badaoui, C.Hoisonard. Model-based diagnosis of large diesel engines based on angular speed variations of the crankshaft[J]. Mechanical System and Signal Processing,2011;24:1529–1541.

[6]Chopra, S., Alexeev, V., and Sudhakar, V. High-frequency restoration of surface seismic data[J]. The Leading Edge, 2003. 22:730–738.

[7]Mohamed N. Nounou, Hazem N. Nounou. Improving the prediction and parsimony of ARX models using multiscale estimation[J].Applied Soft Computing Journal,2006;7:711–721.

[8] Marjan Golob, Boris Tovornik. Input–output modeling with decomposed neuro–fuzzy ARX model[J]. Neurocomputing, 2007;71:875–884.

[9]Ince R. Prediction of fracture parameters of concrete by artificial neural networks[J]. Eng Fract Mech, 2004; 71: 2143–2159.

作者简介:

刘正文(1983—),男,汉族,湖南湘潭人,硕士研究生,工程师,主要从事石油物探研究。

*通讯作者:

胡瑞卿(1989—),男,汉族,中国湖北荆门人,博士研究生,中级职称,主要从事地球物理与石油资源勘查技术,地球探测信息技术,地震数据处理方法。