

吴 媚, 符力耘, 李维新. 高分辨率非线性储层物性参数反演方法和应用. 地球物理学报, 2008, 51(2): 546 ~ 557

Wu M, Fu L Y, Li W X. A high-resolution nonlinear inversion method of reservoir parameters and its application to oil/gas exploration.

Chinese J. Geophys. (in Chinese), 2008, 51(2): 546 ~ 557

高分辨率非线性储层物性参数反演方法和应用

吴 媚¹, 符力耘¹, 李维新²

1 中国科学院地质与地球物理研究所, 北京 100029

2 中国海洋石油股份有限公司研究中心, 北京 100027

摘 要 对于陆相沉积环境下的复杂隐蔽岩性储层, 由于观测信息不准确, 如信息重叠、信息缺失和噪音污染, 以及岩石物理关系模糊等原因, 储层横向预测存在不惟一性、不稳定性和不确定性. 基于线性假定的常规储层横向预测技术已不适用于复杂隐蔽岩性储层的勘探. 本文采用一种非线性储层岩性物性褶积模型, 建立波阻抗与孔隙度/泥质含量的函数关系, 通过多级结构分解和双向边沿子波检测来刻画复杂岩石物理关系. 通过 Caianiello 褶积神经网络实现确定性反演、统计反演和非线性理论三者有机结合, 最后联合应用基于逆算子的反演方法和基于正算子的重建算法实现了综合地质、测井和地震波阻抗信息进行高分辨率储层物性参数反演. 非线性储层物性参数反演采用多井约束机制和分频反演方式, 在陆相和近海油气勘探资料的实际应用中, 取得了明显应用效果.

关键词 非线性反演, 物性参数, 褶积模型, Caianiello 褶积神经网络, 边沿检测子波, 分频反演

文章编号 0001-5733(2008)02-0546-12 中图分类号 P631 收稿日期 2007-07-10, 2007-12-09 收修定稿

A high-resolution nonlinear inversion method of reservoir parameters and its application to oil/gas exploration

WU Mei¹, FU Li-Yun¹, LI Wei-Xin²

1 Institute of Geology and Geophysics, Chinese Academy of Sciences, Beijing 100029, China

2 CNOOC Research Center, Beijing 100027, China

Abstract In the prediction of complex reservoir in continental deposition environment, because of inexact data (e. g., information-overlapping, information-incomplete, and noise-contaminated) and ambiguous physical relationship, inversion results suffer from nonuniqueness, instability, and uncertainty. Thus, reservoir prediction technologies based on linear assumption are unsuited for these complex areas. By means of nonlinear rock physical models, the method presented in the paper establishes a relationship between impedance and porosity/clay-content. Through multistage decomposition and bidirectional edge wavelet detection, it can depict more complex rock physical relationship. Moreover, it uses the Caianiello neural network to implement the combination of deterministic inversion, statistical inversion and nonlinear theory. Last, it incorporates geological information, well data and seismic impedance to perform petrophysical parameters inversion by combined applications of model-based and deconvolution-based methods. The joint inversion consists of four steps: (1) multistage vertical edge detection wavelets extraction at the wells and nonlinear factor estimation, (2) initial petrophysical parameters estimation by vertical edge detection wavelets, (3) multistage transverse edge detection wavelets extraction and nonlinear factor estimation, (4) final petrophysical parameters reconstruction by transverse edge detection wavelets. The scheme adopts multi-well constraint and separate-frequency inversion

基金项目 国家高技术研究发展计划(863计划)专题(2006AA06Z240)资助.

作者简介 吴 媚, 女, 1975 年生, 1998 年毕业于大庆石油学院, 现为中国科学院地质与地球物理研究所在读博士, 主要从事储层预测方面的研究工作. E-mail: wu_zong_hong@126.com

mode and achieves good results in the application on some continental and near-sea exploration data.

Keywords Nonlinear inversion, Petrophysical parameters, Convolution model, Caianiello neural network, Edge detection wavelet, Separate-frequency inversion

1 引 言

针对陆相沉积环境下的复杂隐蔽岩性储层:储层厚度薄物性差、岩性物性高度非均质且横向变化大、储层岩性对比弱、有效储层分布分散等特征,如何有效地进行储层预测和流体识别是当前中国中部、东部和近海地区石油勘探和开发中面临的主要问题。综合利用地质、地震、测井和钻井等资料进行储层横向预测,涉及许多学科和地质地球物理深层次的问题。大多数地质地球物理过程是非线性的,求取各种地质地球物理问题的非线性变换一直是长期研究的课题。根据有关的信息理论^[1]绝大多数地质地球物理过程是不可逆的,即信息的缺失在物理上不能可靠重建。在地质地球物理过程中,由于可观测数据的信息不全、信息重叠和数据噪音污染等原因,储层横向预测存在不惟一性、不稳定性和不确定性。

目前广泛推广应用的各种储层物性横向预测技术极大地简化物理问题的复杂性,适用于结构简单和物性横向变化较均匀的储层。如 Wyllie 时间平均方程^[2] $1/v_p = (1 - \phi)v_m + \phi/v_f$ (其中 ϕ 表示地层孔隙度, v_p 表示纵波速度, v_m 表示岩石骨架的速度, v_f 表示孔隙流体的速度)以其简单性而被广泛应用,但它只能描述中等孔隙度范围内速度与孔隙度之间的关系。Raymer 方程^[3] $v_p = (1 - \phi)v_m + \phi v_f$ 是修正的时间平均方程,适用于不同的孔隙度范围。但这两种模型均适用于纯砂岩而不适用于泥质砂岩。而且它们只能描述大尺度的物性横向变化,缺乏细节的描述。对于陆相复杂隐蔽岩性储层,基于线性假定的储层物性横向预测技术已不适用于该类储层的研究。因此,基于统计反演理论的非线性反演方法应运而生,如地质统计法和神经网络法^[4-6]等。

在储层横向预测中,关键问题是如何利用带限资料(地震和地质资料)进行宽带高分辨率反演。目前,还没有成熟的理论能从带限资料中可靠恢复缺失的高频信息,无法解决反演中从带限到宽带的问题。我们结合 Robinson 地震褶积模型^[7-10]和 Caianiello 褶积神经网络^[11-13]已实现了高分辨率非线性地震波阻抗反演^[14,15]。本文在此基础上,采用一种非线性储层岩性物性褶积模型,建立波阻抗与孔

隙度/泥质含量的函数关系,通过多级结构分解和双向边沿子波检测来刻画复杂岩石物理关系;通过 Caianiello 褶积神经网络实现确定性反演、统计反演和非线性理论三者有机结合;最后联合应用基于逆算子的反演方法和基于正算子的重建算法实现了综合地质、测井和地震波阻抗信息进行高分辨率储层物性参数反演。非线性储层物性参数反演采用多井约束机制和分频反演方式,该方法在陆相和近海油气田复杂隐蔽岩性储层的物性横向预测实践中取得了明显应用效果。

2 非线性储层物性参数反演方法原理

2.1 非线性储层岩性物性褶积模型

在储层物性参数反演中,我们使用如下的波阻抗与孔隙度非线性储层岩性物性模型^[16]:

$$\frac{\phi_m(\phi_m - 2\phi)}{\phi(\phi_m - \phi)} = \lambda \ln \left[\frac{z_p - z_f}{z_m - z_p} \right], \quad (1)$$

式中, ϕ 表示地层孔隙度, ϕ_m 表示储层砂岩的最大孔隙度, z_p 、 z_f 和 z_m 分别表示纵波阻抗、孔隙流体波阻抗和岩石骨架波阻抗, λ 为非线性因子,可以非线性地调整方程的函数形式以拟合实际的数据关系。图 1 为非线性因子 λ 取不同值得到的拟合曲线,表现为 S-型曲线特征。对于固定的 λ 值,孔隙度随波阻抗变化的非线性程度不同,不同岩性物性构成的岩石具有不同的 λ 值。

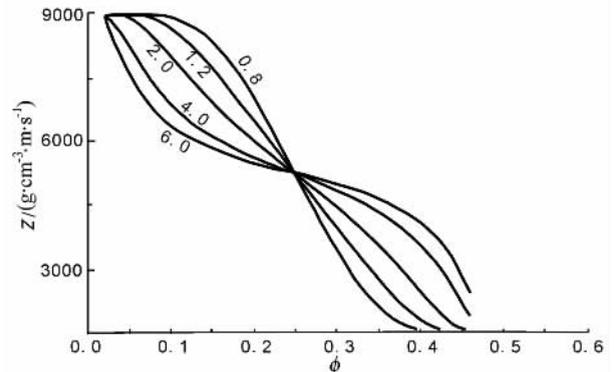


图 1 不同非线性因子对应的波阻抗 z 与孔隙度 ϕ 函数关系图

Fig. 1 Relationship map between impedance and porosity corresponding to different nonlinear factors

为便于实际应用, 可将 (1) 式写成:

$$\frac{\phi_m(t) \chi \phi_m(t) - 2\phi(t)}{\phi(t) \chi \phi_m(t) - \phi(t)} = \lambda(t) \ln \left[\frac{z_p(t) - z_c(t)}{z_m(t) - z_p(t)} \right], \quad (2)$$

式中, $\phi(t)$ 表示时间域孔隙度曲线, $z_p(t)$ 表示时间域阻抗曲线. 如何精确估算不同深度不同岩性的时变非线性因子 $\lambda(t)$ 是储层物性参数反演中的一个关键性问题. Caianiello 褶积神经网络提供了一个能迭代调整 $\lambda(t)$ 的最优算法, 使之对纵向上沿井的岩性变化产生自适应响应.

图 2 为墨西哥湾由测井资料编制的孔隙度和波阻抗交会图. 它表明在硅质碎屑岩中, 岩性的变化、孔隙中凝析气与水等流体类型的变化会使波阻抗与孔隙度之间的关系发生明显变化, 表现在孔隙度和波阻抗交会图上数据点散状分布具有不同的分布范围, 其中 + 点代表上覆泥岩, Δ 点代表含矿硅质碎屑岩, \circ 点代表含矿火山碎屑岩, \square 点代表含水硅质碎屑岩. 图中直的实线是 Burge 和 Neff^[17] 利用时间平均方程拟合的结果, 虚的曲线是本文方法拟合的结果. 可见虚的拟合曲线更加符合实际数据点的分布.

同样地, 可建立如下的波阻抗与泥质含量之间的非线性储层物性模型:

$$\frac{c_m(c_m - 2c)}{c(c_m - c)} = \lambda \ln \left[\frac{c_m(z_p - z_c)}{c_m(z_m - z_p) - c(z_m - z_c)} \right], \quad (3)$$

式中, c 表示泥质含量, c_m 表示泥质含量的最大值, z_c 表示纯泥岩波阻抗.

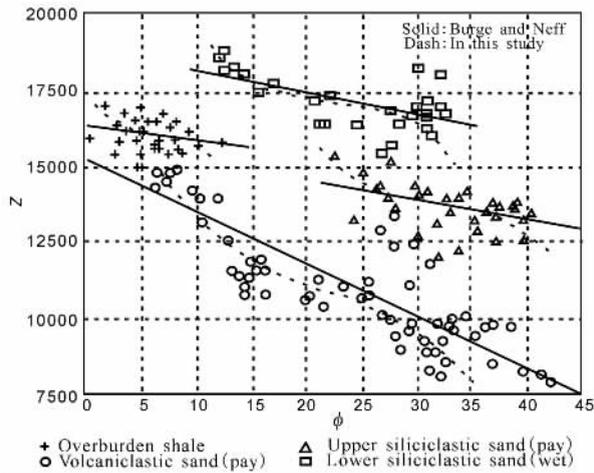


图 2 墨西哥湾地区由测井资料编制的波阻抗与孔隙度交会图 (本数据来自 Burge 和 Neff^[17])

Fig. 2 Acoustic impedance versus porosity for a well in a Gulf of Mexico field (The data is provided by Burge and Neff^[17])

2.2 多级结构分解和双向边沿子波检测

从图 2 中可以注意到, 拟合曲线只能反映数据点的分布走势, 不能反映数据点沿拟合曲线相对集中和分散的分布特征. 一般地, 不同沉积环境下, 不同岩性物性构成的岩石其数据点具有不同的分散分布特征. 为了将岩性物性交会图中数据点的这种分散分布特征引入到非线性储层岩性物性模型中, 我们将地震波阻抗与储层物性参数之间的关系统一表示为一种隐式的关系:

$$z(t) = f(\phi(t), u(t), \lambda(t)), \quad (4)$$

式中, $z(t)$ 表示时间域地震波阻抗, $\phi(t)$ 表示时间域孔隙度, $u(t)$ 为数据点散状分布的边沿检测子波, $f(\cdot)$ 为非线性变换, 表示非线性因子 $\lambda(t)$ 的影响. 为了利用 Caianiello 褶积神经网络实现统计反演, 将 (4) 式进行多级分解, 例如一个三级分解可表示为

$$z(t) = f_3(f_2(f_1(\phi(t)) * w_1(t)) * w_2(t)) * w_3(t), \quad (5)$$

式中, $f_i(\cdot)$ ($i = 1, 2, 3$) 为多级非线性变换, 隐含非线性因子 $\lambda(t)$, $w_i(t)$ ($i = 1, 2, 3$) 为多级边沿检测子波. (5) 式为非线性储层岩性物性褶积模型.

边沿检测子波 $u(t)$ 沿纵向和横向两个方向进行数据分布的边沿检测. 将边沿检测子波 $u(t)$ 作为 Caianiello 褶积神经网络的神经子波进行估计, 图 3 为与 (5) 式对应的三层 Caianiello 褶积神经网络结构. 利用 Caianiello 褶积神经网络算法^[13], 可以迭代调整边沿检测子波使网络实际输出信号和期望输出信号达到匹配. 定义的价值函数为如下均方误差函数:

$$E = \frac{1}{2} \sum_k \sum_t e_k^2(t) = \frac{1}{2} \sum_k \sum_t [d_k(t) - o_k(t)]^2, \quad (6)$$

式中, $d_k(t)$ 表示期望输出信号, $o_k(t)$ 表示网络实际输出信号. 在每层中应用误差逆向传播技术对该层中所有神经元的边沿检测子波进行递归修正. 如从隐层向下到输入层的边沿检测子波修正公式为

$$\Delta w_{ji}(t) = \eta(t) \delta_j(t) \otimes o_i(t), \quad (7)$$

式中, \otimes 为互相关运算符; $\eta(t)$ 为学习速率. 对于输出层, 其第 k 个神经元的逆向传播误差 $\delta_k(t)$ 可以表示为

$$\delta_k(t) = e_k(t) f'(N_k(t) - \theta_k(t)), \quad (8)$$

式中, $f'(\cdot)$ 表示对非线性变换求导.

$$N_k(t) = \sum_j w_{kj}(t) * o_j(t). \quad (9)$$

对于隐层, $\delta_j(t)$ 可由链规则得到, 即

$$\delta_j(t) = f'(N_j(t) - \theta_j(t)) \sum_k \delta_k(t) \otimes w_{jk}(t), \quad (10)$$

$$N_j(t) = \sum_i w_{ji}(t) * o_i(t). \quad (11)$$

在 Caianiello 褶积神经网络中, 褶积运算的误差正向传播和互相关运算的误差逆向传播可通过快速傅里叶变换在频率域中实现.

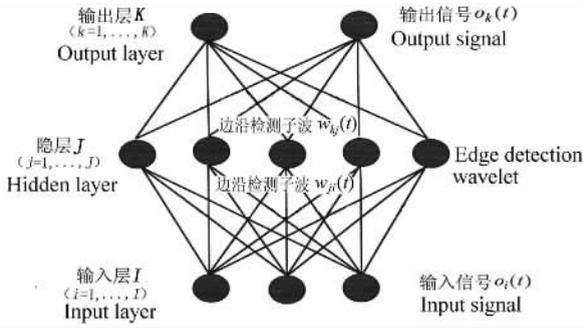


图 3 三层 Caianiello 褶积神经网络体系结构

Fig.3 Three-layer Caianiello neural network architecture

2.3 输入信号重建方法

通常情况下, 在输入和期望输出已知的信息环境中, 神经网络首先要进行学习(权调整), 训练后的网络可用于新信息环境中对输入的新数据体进行预测, 即在新信息环境中输入是已知的, 而输出是未知的. 然而在大多数情况下, 新信息环境通常是由未知或不准确的输入和已知或不完整的输出构成. 因此, 需要利用训练的神经网络对新信息环境进行预测, 反推未知或不准确的输入信号.

利用已知的边沿检测子波和期望输出, 我们可

以对输入信号作迭代调整, 重建输入信号. 定义的价值函数与(6)式类似, 在图 3 中, 对网络隐层的输入信号进行迭代调整, 可表示为

$$\Delta o_j(t) = \mu(t) \delta_k(t) \otimes w_{jk}(t), \quad (12)$$

式中, $\mu(t)$ 是增益向量, 第 k 个神经元的逆向传播误差 $\delta_k(t)$ 可由(8)式得到. 通过(10)式, 可以得到输入层 $o_i(t)$ 的修正方程如下:

$$\Delta o_i(t) = \mu(t) \delta_j(t) \otimes w_{ji}(t). \quad (13)$$

2.4 非线性因子优化

为得到一个最优的储层物性模型来拟合不同岩性的测井数据, 就要不断调整时变非线性因子(见(2)式). 将误差逆向传播技术应用于每一层的神经元中就可以产生一个修正的非线性因子方程. 定义如(6)式的价值函数, 对于任一层中的任一神经元, 修正的非线性因子方程都具有递归形式. 例如, 对图 3 输入层的非线性因子修正可表示为

$$\Delta \lambda_i(t) = \beta(t) r_i(t) f'(\lambda_i(t)), \quad (14)$$

式中, $\beta(t)$ 是增益因子; $r_i(t) = \sum_j \delta_j(t) \otimes w_{ji}(t)$ 为校正函数, 其中 $\delta_j(t)$ 由(10)式得到.

3 非线性储层物性参数反演的流程及关键技术

3.1 反演流程

非线性储层物性参数反演分为四个步骤^[16]: (1)并约束纵向边沿检测子波提取和非线性因子估计 (2)基于纵向边沿检测子波直接反演储层物性

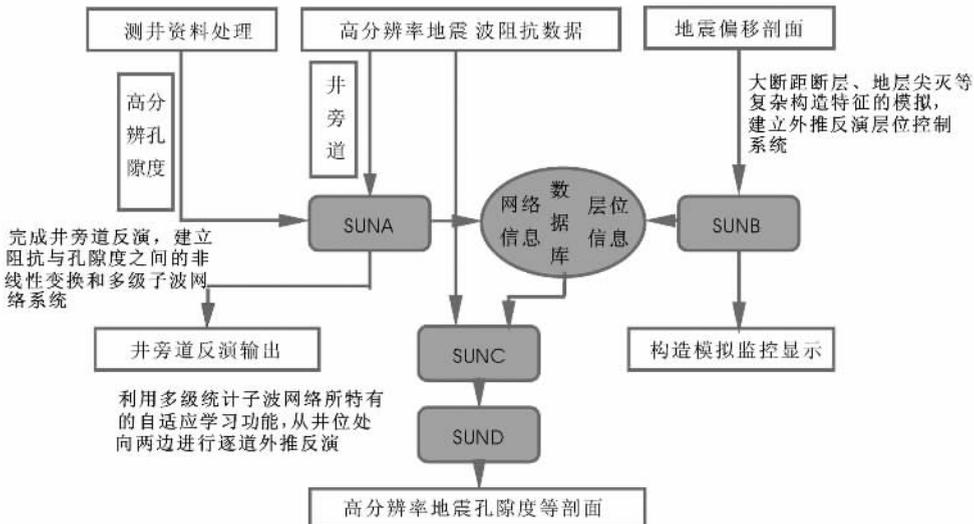


图 4 非线性储层物性参数反演流程图(以孔隙度反演为例)

Fig.4 Flow chart of nonlinear petrophysical parameters inversion (e.g. porosity inversion)

(孔隙度和泥质含量),作为储层物性初始模型估计;
(3)井约束横向边沿检测子波提取和非线性因子估计
(4)基于横向边沿检测子波间接反演最终储层物性.图 4 是反演流程图(以孔隙度反演为例).

3.2 沿纵向边沿检测估计储层物性

受砂岩中泥质含量的影响,地震波阻抗与孔隙度交会图中数据点呈“云”状分布.从图 5 波阻抗-孔隙度交会图中可以看出,非线性储层岩性物性拟合曲线只能确定数据点云状分布的整体变化趋势,不能反映数据点的散状分布特征.为修正(2)式的非线性储层岩性物性模型,实现同时估计波阻抗与孔隙度之间的整体趋势变化和沿趋势线数据点的散状分布特征.本文中利用边沿检测子波作为扫描因子从两个方向确定趋势线周围数据点散状分布特征,一个是沿着平行 z 轴的方向(图 5 中的 AB 线),另一个是沿着平行 ϕ 轴的方向(图 5 中的 CD 线).前者可以表示为 $\phi(t) = f(z(t), w_z(t), \lambda(t))$, 式中 $w_z(t)$ 称为纵向边沿检测子波.利用隐含非线性因子的储层物性模型 $f(\cdot)$ 以及相关截止参数可以确定趋势线,波阻抗 $z(t)$ 与纵向边沿检测子波的褶积运算可以确定数据点沿 z 轴方向的散状分布范围.

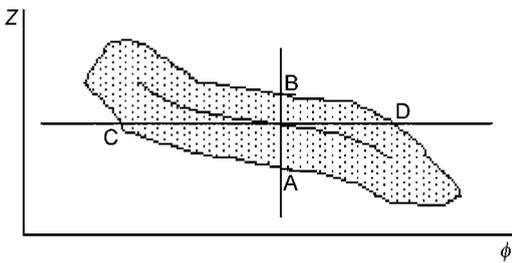


图 5 储层物性参数反演方法描述

Fig. 5 Schematic description of petrophysical parameters inversion

结合 Caianiello 褶积神经网络和基于(2)式的非线性储层物性模型提取纵向边沿检测子波和非线性因子,然后利用纵向边沿检测子波直接反演孔隙度.井旁地震波阻抗曲线作为神经网络的输入,测井孔隙度曲线作为期望输出.纵向边沿检测子波的估计揭示了一个从地震波阻抗到地层孔隙度的多级近似过程.网络训练序列由输入矩阵 $z_{il}(t)$ $l = 1, 2, \dots, L$, L 为目标区井的个数, $i = 1, 2, \dots, I$, I 表示第 l 口井处输入地震波阻抗的个数,也代表输入层神经元个数和期望输出矩阵 $\phi_{kl}(t)$ $l = 1, 2, \dots, L$, $k = 1, 2, \dots, K$, K 表示第 l 口井处孔隙度测井的个数,也代表输出层神经元个数)构成.通常情况下,参数 l 要选取足够大以充分利用相邻道特性的空间相关性.网络训练实质上是一个优化的过程,与常规神经网络

应用的主要区别在于在进行逆向传播时,神经子波的调整受(2)式的非线性储层岩性物性模型控制.

对所有井进行训练后,得到一个褶积神经网络系统,在一定程度上可以给出地震波阻抗(输入)和地层孔隙度(输出)的对应关系.每口井有各自的纵向边沿检测子波和非线性因子,井越多,得到的结果就越可靠.对于横向稳定的沉积单元,边沿检测子波在横向上也是稳定的,在井少情况下也可以得到较好的结果.利用神经网络训练得到的纵向边沿检测子波,可进行井外推直接反演.褶积神经网络系统通过井间自动插值可以生成一系列新的纵向边沿检测子波和非线性因子,用于井间孔隙度反演,得到的孔隙度剖面作为孔隙度的初始模型估计.

3.3 沿横向边沿检测重建储层物性

从图 5 中可以看到,用边沿检测子波确定散状分布特征的另一种方式可以表示为 $z(t) = f(\phi(t), w_\phi(t), \lambda(t))$, 式中 $w_\phi(t)$ 称为横向边沿检测子波.孔隙度 $\phi(t)$ 与横向边沿检测子波 $w_\phi(t)$ 的褶积运算可以确定数据点沿 ϕ 轴方向的散状分布特征.

首先进行横向边沿检测子波提取.井孔隙度曲线作为 Caianiello 褶积神经网络的输入,井旁地震波阻抗曲线作为期望输出.利用神经网络训练得到的横向边沿检测子波,可以进行井外推间接反演,即以上一步直接反演得到的初始孔隙度模型作为本步训练好的神经网络的输入,以地震波阻抗作为神经网络的期望输出,采用第 2.3 节介绍的 Caianiello 褶积神经网络输入信号重建算法,通过多步迭代修正初始孔隙度模型,间接反演最终孔隙度剖面.对于每一个孔隙度反演道,可以将其与相邻几个地震波阻抗道组合作为期望输出,以加强反演的自适应能力.在井外推间接反演过程中,神经网络通过井间自动插值生成一系列新的横向边沿检测子波和非线性因子,用于井间孔隙度反演.

3.4 大尺度地质模型约束

地质模型提供了沉积单元的构造形态,通过地质模型对反演进行约束,实现地质信息的有效应用.在每一个沉积单元中,岩性和地质特性相似,地震特征横向变化较缓,因此,同一沉积单元中纵横向边沿检测子波和非线性因子在横向上是渐变的.每一个沉积单元都对应着一组纵横向边沿检测子波和非线性因子,代表其地震响应和地质特性.在复杂地质构造地区,存在大断距断层、地层尖灭和陡倾角地层等地质形态,需要地震解释来确定一个控制地震主要同相轴的大尺度地质模型,在储层物性反演外推中

作为地层约束,确保在同一地质层序中应用同一组边沿检测子波和非线性因子。

4 应用实例

琼东南盆地勘探目的层古近系的陵水组以扇三角洲、滨海和浅海沉积为主,新近系的三亚组以浅海和滨海沉积为主。图 6 为琼东南西区 YA136 地震测线,过相距 23 km 的 A1 和 A2 两口钻井。该区主要发育两套储盖组合:①陵三段扇三角洲、滨海砂岩与陵二段海侵泥岩的储盖组合;②三亚组和梅山组滨海相砂岩或低位扇储层与梅山组—莺黄组浅海、半深海相泥岩的储盖组合。主要勘探目的层陵水组埋藏较深,其波阻抗特征复杂,砂、泥岩阻抗特征接近,利用常规波阻抗很难识别储层和有效盖层。为此,文献 [15] 利用 A1 井的测井资料和地震资料,对 YA136 地震测线进行了高分辨率非线性地震波阻抗多尺度分频反演,并利用 A2 井的实测波阻抗对反演结果进行了验证。图 7 为反演的中高频波阻抗剖面,反映了细微的地层岩性结构。由该图可见,插入剖面中的 A1 井中高频阻抗分量与井旁道反演结果吻合得很好,这是因为地震数据中有相当多的微弱高频成分,且介质的高频成分与中频成分之间存在很好的自仿射映射关系。因此,由中频为主的地震数据外推反演高频阻抗,相对反演低频阻抗来说精度要高些。图 8 为利用低频、中频和高频反演分量合成的全频波阻抗剖面,插入剖面中的 A1 井波阻抗曲线与井旁道反演结果吻合得很好,钻井揭示的陵三段扇三角洲厚砂岩,在波阻抗剖面上表现为低阻抗特征。文献 [15] 利用 A2 井的实测波阻抗对反演结果进行了验证,在 A2 井处,二者的相似系数达 80.64%。交叉验证效果较好的主要原因之一是:在计算中尺度的地震相对波阻抗时,不用井进行约束,但计算的相对波阻抗与 A1 和 A2 两口井实测的波阻抗中频分量有很好的相似性,说明地震数据的井-震相关性很好,确保外推反演结果可靠。这为下面我们将要进行的高分辨率非线性储层物性参数反演打下良好的基础。

钻井揭示的岩性有含砾砂岩、粗砂岩、中砂岩、细砂岩、粉砂岩、砂质泥岩、泥岩、灰质泥岩、灰岩、灰质砂岩。砂岩孔隙度分布范围为 5%~21%,平均为 15%,为中孔高渗型。琼东南盆地西区由西北部向东南储层物性变差。根据已发现气田,有效储层孔隙度大于 10%。利用 A1 井资料和地震资料,我们对

YA136 地震测线进行了高分辨率非线性储层物性参数(孔隙度和泥质含量)多尺度分频反演,同时利用 A2 井的实测储层物性曲线对反演结果进行了验证。

首先对 A1 井的泥质含量和孔隙度时间域曲线进行了多尺度分解(图 9a),并进行了频谱分析(图 9b)。从频谱图上可见,大/中尺度分量在 0~100 Hz 左右,相当于地震数据本身的分辨率;小尺度分量达 250 Hz,是地震反演需要外推的部分。对不同尺度的频率分量分别进行了反演。首先输入井旁地震波阻抗数据,以井的各孔隙度/泥质含量分量为期望输出,进行井旁地震道反演,完成井约束边沿检测子波提取和非线性因子估计。图 10 和图 11 分别为 A1 井约束泥质含量和孔隙度反演提取的多级边沿检测子波:下为第一级边沿检测子波;上为第二级边沿检测子波。其中左为中低频分量反演提取的边沿检测子波,右为高频分量反演提取的边沿检测子波。通常,第二级子波的频率高于第一级。

图 12 和图 13 分别为利用 A1 井的中/低频分量约束和高频分量约束反演得到的中/低频泥质含量剖面和高频泥质含量剖面,图 14 是合成的全频泥质含量剖面。可见,插入剖面中的 A1 井实测各泥质含量分量曲线与反演结果吻合得很好。图 15 为约束井 A1 井的泥质含量各分量与反演结果对比,其中,粗线为井曲线,细线为反演曲线,二者相似系数均在 96% 以上。

图 16 为利用 A1 井孔隙度的中/低频分量约束反演得到的中/低频孔隙度剖面,同时进行高频分量约束孔隙度反演,图 17 是合成的全频孔隙度剖面。可见,插入剖面中的 A1 井实测各孔隙度分量曲线与反演结果吻合得很好。图 18 为约束井 A1 井的孔隙度各分量与反演结果对比图,其中,粗线为井曲线,细线为反演曲线,二者相似系数均在 96% 以上。在井旁做好砂体的标定和储层精细描述工作,就可以从井外推直接在高分辨率的储层物性剖面上较准确地勾画有效砂体的分布。

图 19 和图 20 为 YA136 连井测线储层物性反演交叉验证对比(粗线为井的泥质含量和孔隙度曲线,细线为合成的反演泥质含量和孔隙度曲线)。在每张图上,右为约束井 A1 的实测物性曲线与反演结果对比,二者的相似系数对于泥质含量为 98.32%,对于孔隙度为 99.02%;左为在 23 km 处的验证井 A2 的实测物性曲线与反演结果对比,二者相似系数对于泥质含量为 83%,对于孔隙度为 85.81%。

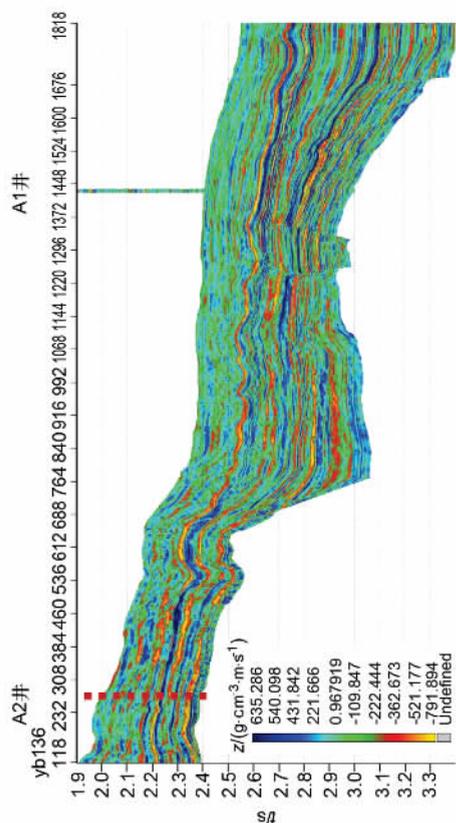


图 7 中高频分量约束地震反演得到的中高频波阻抗剖面
Fig.7 Middle/high-frequency impedance profile obtained by middle/high-frequency well constraint

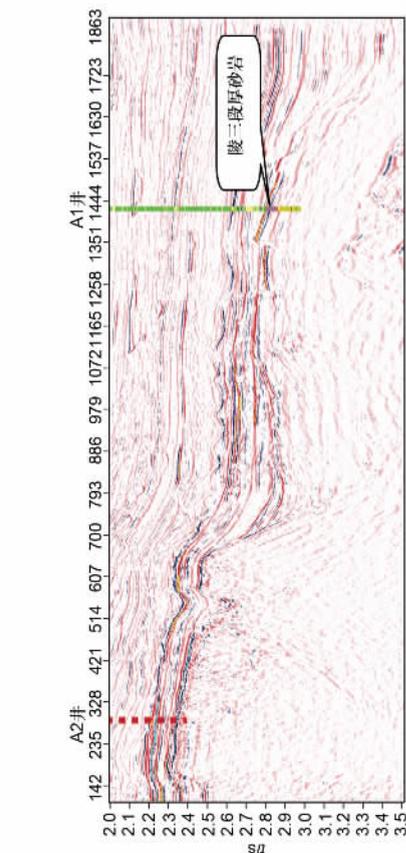


图 6 YAI36 连井测线地震剖面
Fig.6 YAI36 seismic profile

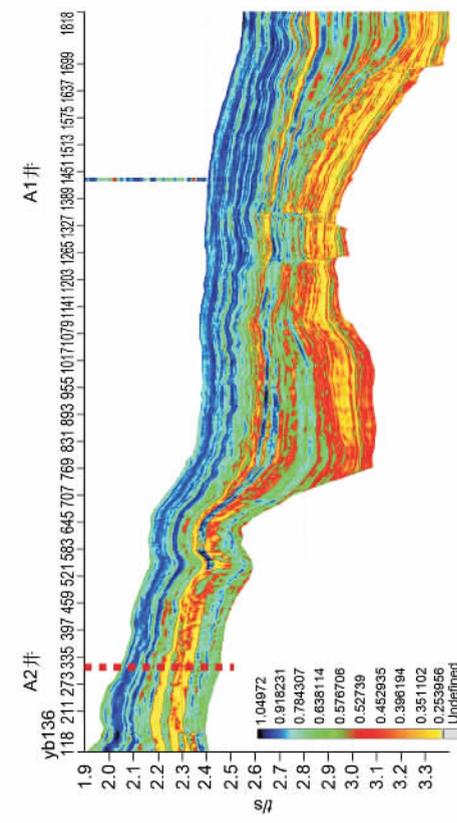


图 12 中/低频分量约束储层物性反演得到的中/低频泥质含量剖面
Fig.12 Middle/low-frequency clay-content profile obtained by middle/low-frequency component constraint inversion

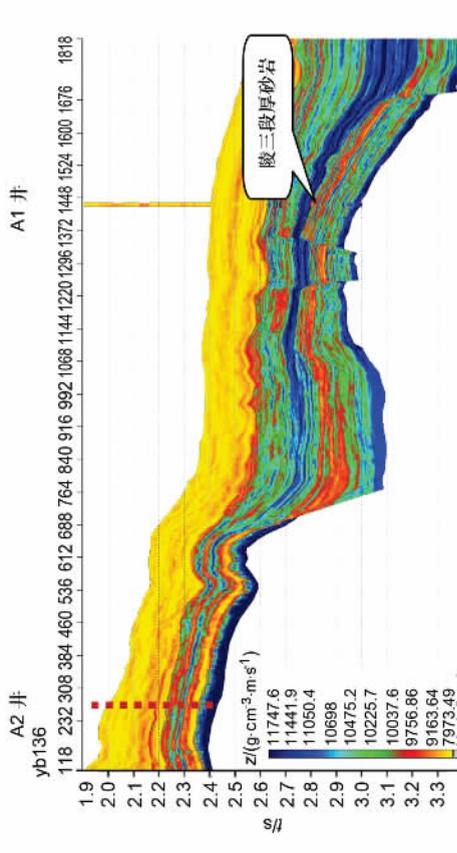


图 8 合成的全频波阻抗剖面
Fig.8 Synthetic full-frequency impedance profile

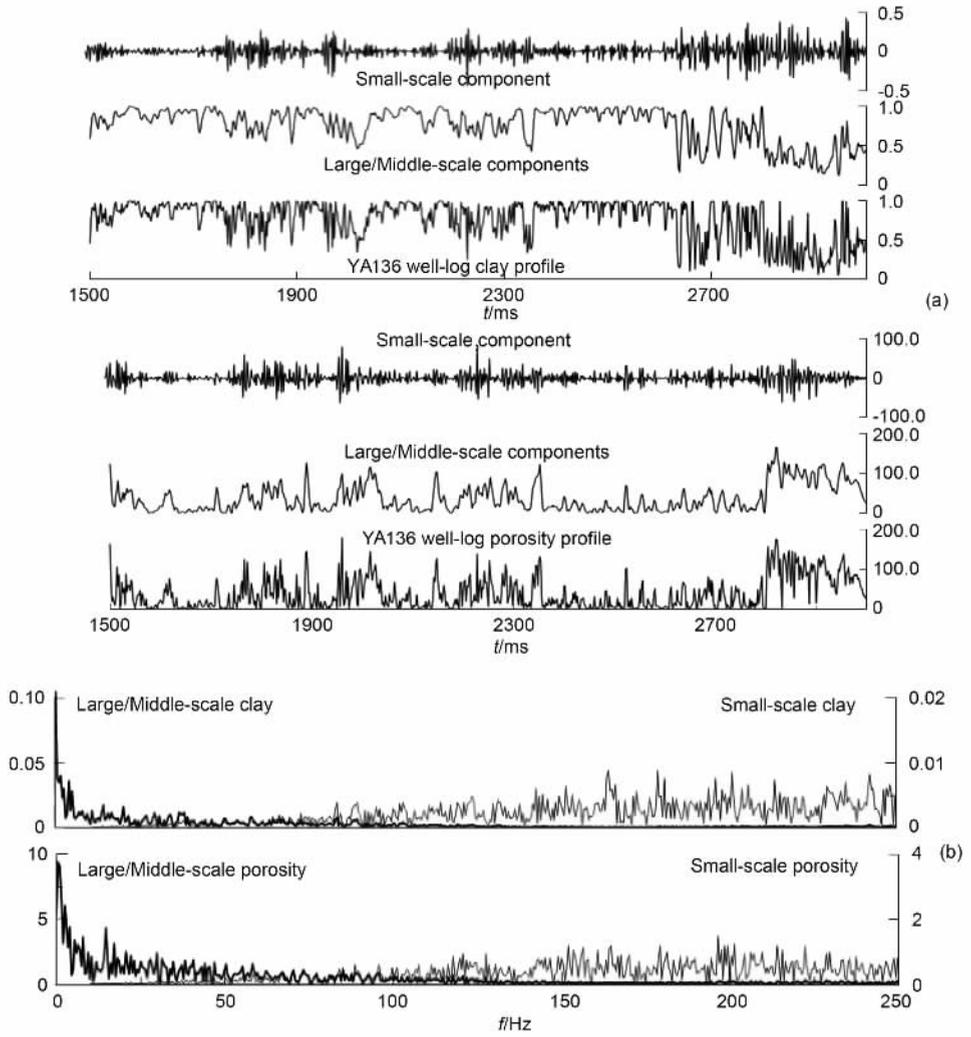


图 9 A1 井泥质含量(上)和孔隙度(下)的频率分解(a)及其相应的频谱分析(b)

Fig.9 (a) Frequency decomposition for clay-content (top) and porosity (bottom);

(b) Spectra analyses for clay-content (top) and porosity (bottom)

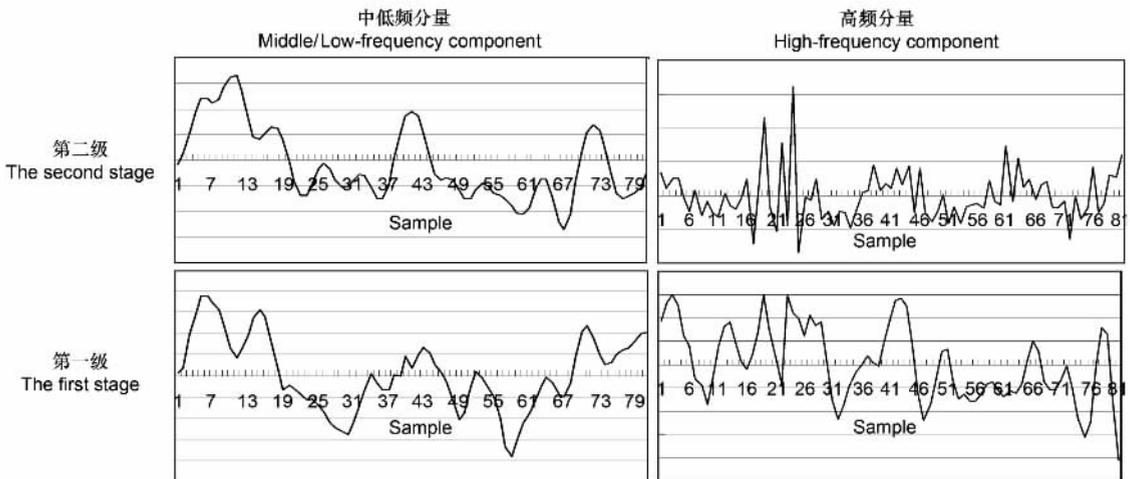


图 10 A1 井约束泥质含量反演提取的多级统计边缘检测子波序列

Fig. 10 Multistage edge detection wavelets sequences for well A1 constraint clay-content inversion

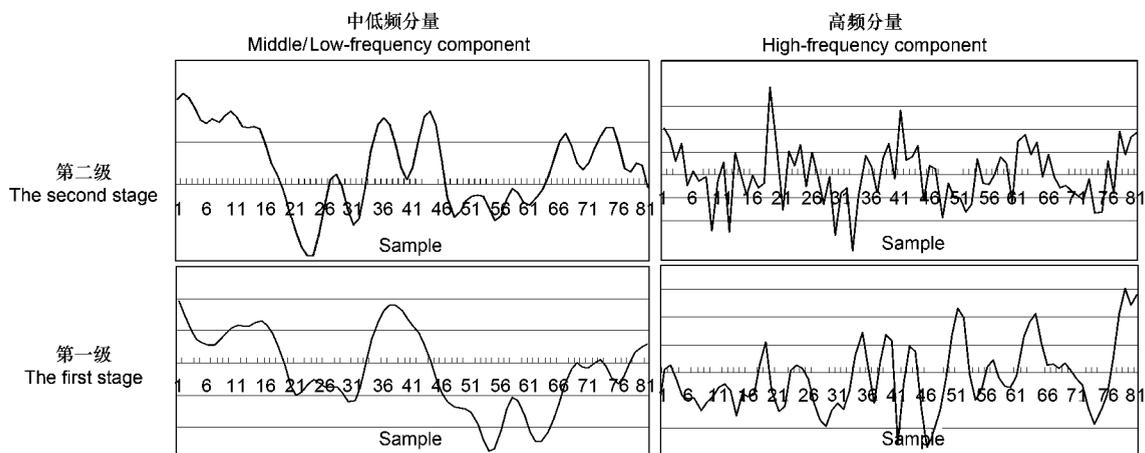


图 11 A1 井约束孔隙度反演提取的多级统计边缘检测子波序列

Fig. 11 Multistage edge detection wavelets sequences for well A1 constraint porosity inversion

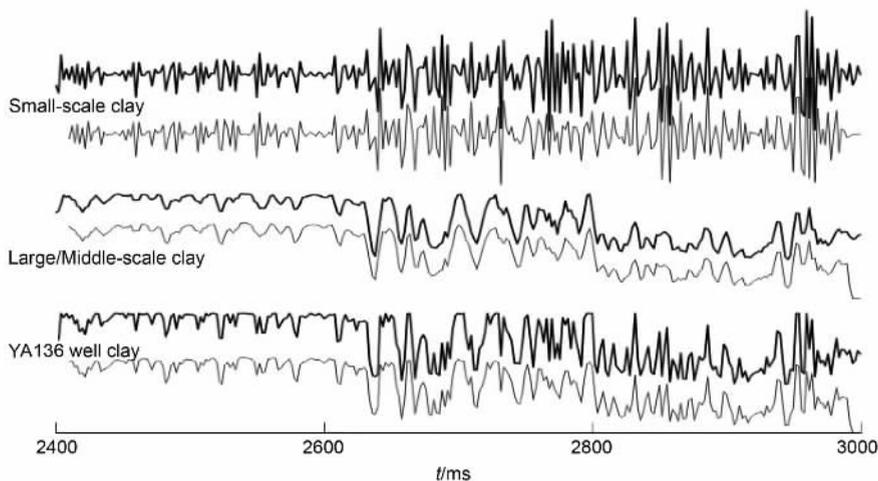


图 15 约束井 A1 井的泥质含量各分量与反演结果的对比

Fig. 15 Comparison between different clay-content components and inversion results at constraint well A1

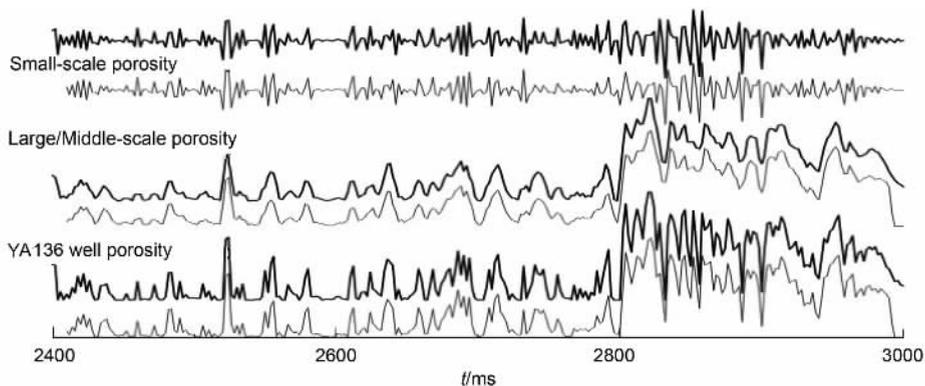


图 18 约束井 A1 井的孔隙度各分量与反演结果的对比

Fig. 18 Comparison between different porosity components and inversion results at constraint well A1

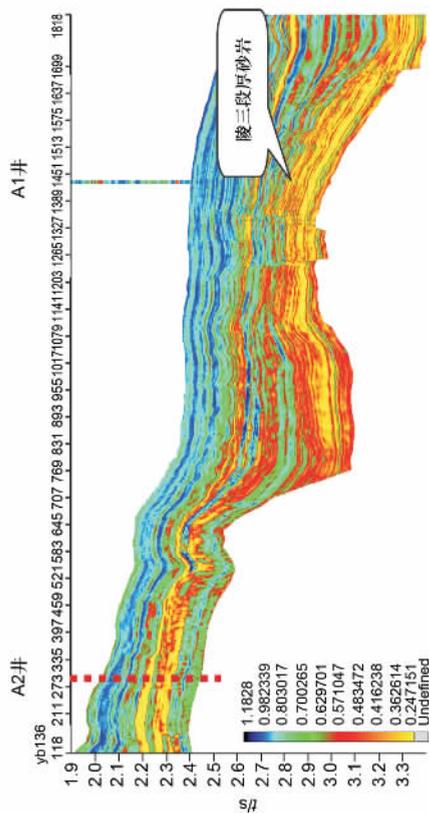


图 14 合成的全频泥质含量剖面
Fig.14 Synthetic full-frequency clay-content profile

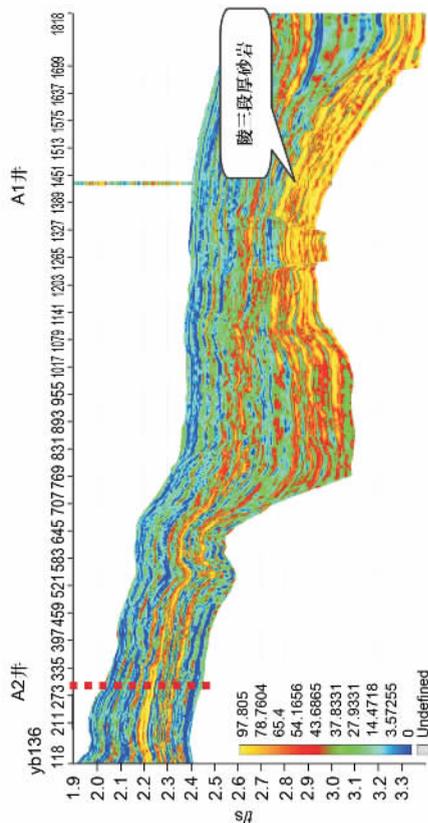


图 17 合成的全频孔隙度剖面
Fig.17 Synthetic full-frequency porosity profile

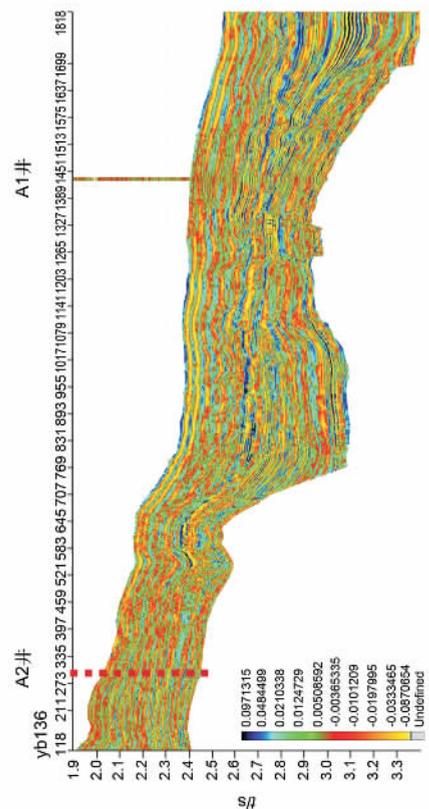


图 13 高频分量约束储层物性反演得到的高频泥质含量剖面
Fig.13 High-frequency clay-content profile obtained by high-frequency component constraint inversion

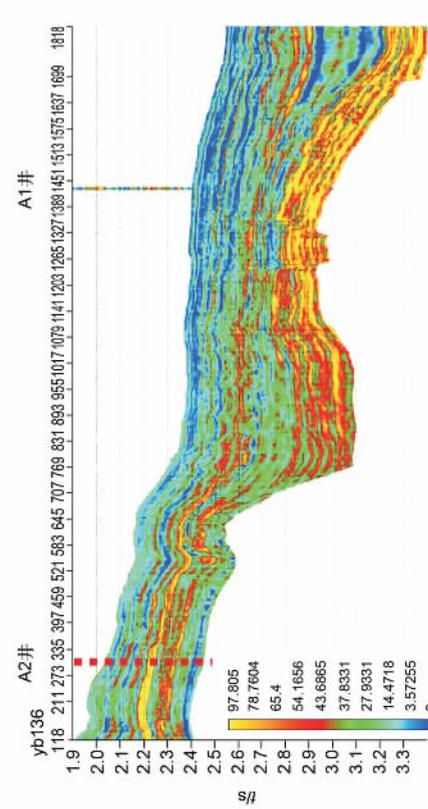


图 16 中/低频分量约束储层物性反演得到的中/低频孔隙度剖面
Fig.16 Middle/low-frequency porosity profile obtained by middle/low-frequency component constraint inversion

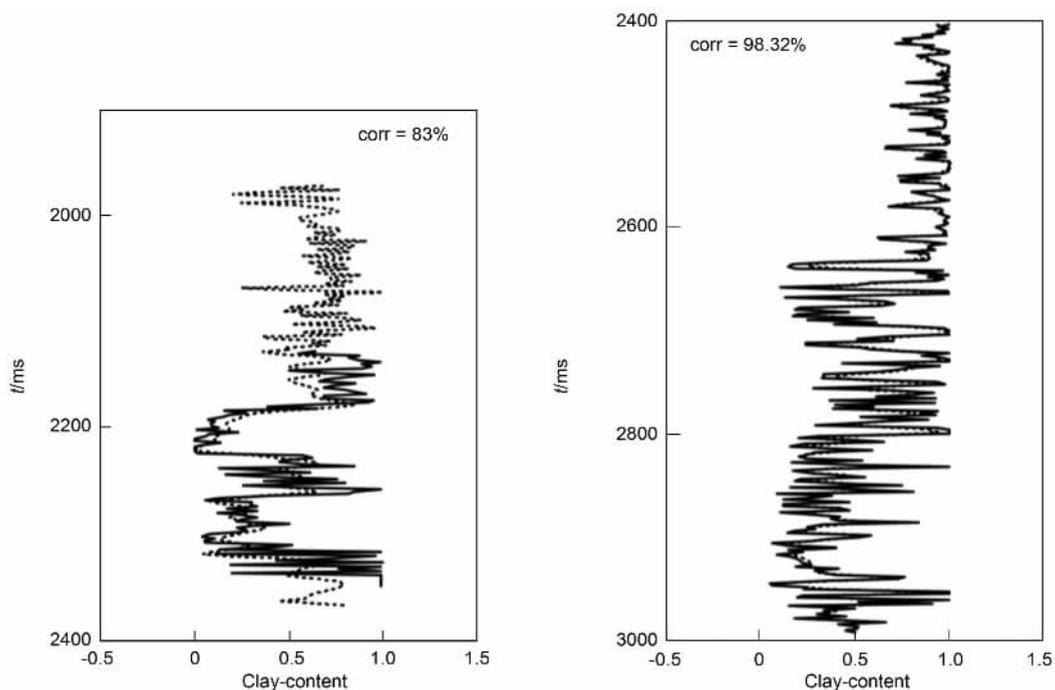


图 19 泥质含量反演交叉验证对比

左为验证井 A2, 右为约束井 A1, 粗线为井曲线, 细线为反演曲线.

Fig. 19 Crossvalidation for clay-content inversion

Test well A2 (left) and constraint well A1 (right), thick line represents log curve and thin line inversion result.

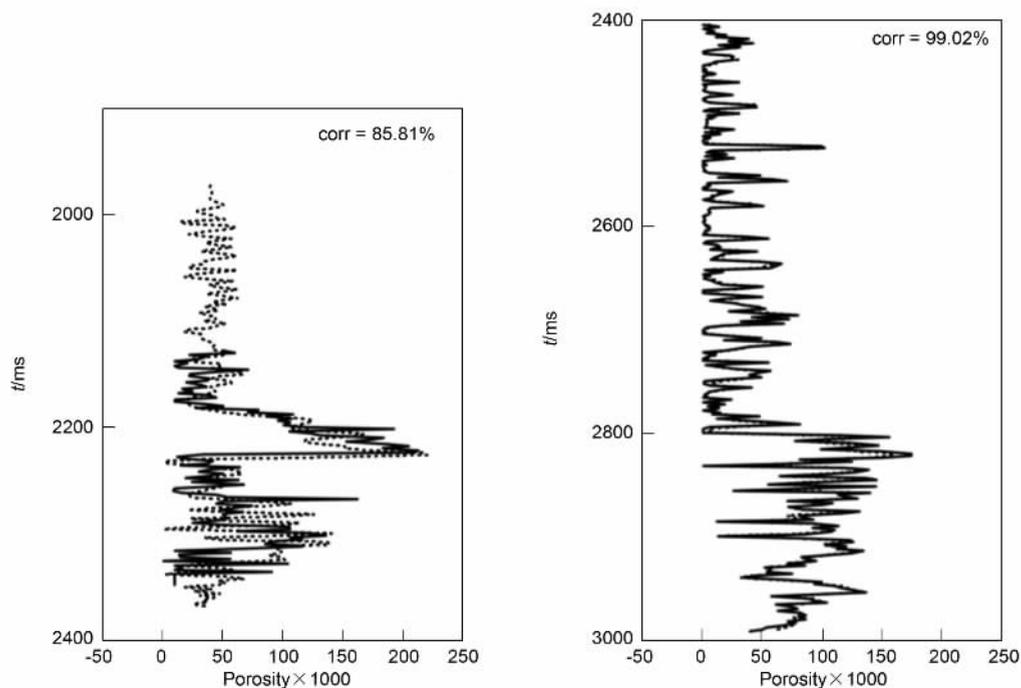


图 20 孔隙度反演交叉验证对比

左为验证井 A2, 右为约束井 A1, 粗线为井曲线, 细线为反演曲线.

Fig. 20 Crossvalidation for porosity inversion

Test well A2 (left) and constraint well A1 (right), thick line represents log curve and thin line inversion result.

5 结 论

陆相沉积环境下的复杂隐蔽岩性储层普遍具有储层厚度薄物性差、岩性物性高度非均质且横向变化大、储层岩性对比弱、有效储层分布分散等特征。由于地球物理观测信息重叠、信息缺失、噪音污染和储层岩石物理关系模糊等原因,导致复杂隐蔽岩性储层横向预测不惟一、不确定和不稳定。现有的许多储层综合横向预测技术由于基于线性假定和缺乏坚实的横向外推理论依据,对上述复杂隐蔽岩性储层描述和预测的精度有限。

本文研究和应用一种高分辨率非线性储层物性反演方法。首先针对储层声属性与储层物性参数之间物理关系模糊,即二者交会图上数据点分布呈“云”状的分散分布,这种散状分布特征显然与包括储层岩性物性特征在内的诸多因素有关。我们定义一种非线性储层岩性物性褶积模型来刻画这种复杂的岩石物理关系,从而建立波阻抗与孔隙度/泥质含量的非线性关系,主要包括:(1)利用隐含非线性因子的储层物性模型 $f(\cdot)$ 以及相关截止参数来拟合数据点“云”状分布的整体变化趋势;(2)通过对岩性物性参数褶积双向边沿子波检测来描述沿趋势线(拟合曲线)附近数据点的散状分布特征。

我们将非线性储层岩性物性褶积模型作多级结构分解,并与 Caianiello 褶积神经网络结合,从而实现将确定性反演、统计反演和非线性理论三者有机结合。确定性反演是使用确定的物理模型,即非线性储层岩性物性褶积模型,以确保反演的可靠性;统计反演是使用统计的物理模型,即 Caianiello 褶积神经网络,以提高反演的抗噪音能力。最后联合应用基于纵向边沿检测子波的直接反演方法和基于横向边沿检测子波的间接反演重建算法,实现了综合地质、测井和地震波阻抗信息进行高分辨率储层物性参数反演。非线性储层物性参数反演采用多井约束机制和分频反演方式。实际资料应用表明,反演的中低频分量物性剖面反映了大套地层的物性特征;反演的高频分量物性剖面反映局部的细微特征,可直接用于勾画有效砂体的分布。

参考文献(References)

[1] Brillouin L. Science and Information Theory. New York :Academic , 1962

- [2] Wyllie M R J , Gregory A R , Gardner G H F . An experimental investigation of factors affecting elastic wave velocities in porous media. *Geophysics* , 1958 , **23** :459 ~ 493
- [3] Nur A , Mavko G , Dvorkin J , et al . Critical porosity : a key to relating physical properties to porosity in rocks. *The Leading Edge* , 1998 , **17** :357 ~ 362
- [4] 印兴耀,吴国忱,张洪宙.神经网络在储层横向预测中的应用.石油大学学报(自然科学版),1994,**18**(5):20~25
Yin X Y , Wu G C , Zhang H Z . The application of neural networks in the reservoir prediction. *Journal of the University of Petroleum , China (Edition of Natural Science)* (in Chinese) , 1994 , **18** (5) : 20 ~ 25
- [5] 杨文采.神经网络算法在地球物理反演中的应用.石油物探,1995,**34**(2):116~120
Yang W C . Application of neural network algorithms to geophysical inversion. *GPP* , 1995 **34** (2) :116 ~ 120
- [6] 陆文凯,李衍达,牟永光.误差反传播神经网络法地震反演.地球物理学报,1996,**39**(增):292~301
Lu W K , Li Y D , Mu Y G . Seismic inversion using error-back-propagation neural network. *Chinese J . Geophys .* (in Chinese) , 1996 , **39** (Suppl .) :292 ~ 301
- [7] Robinson E A . Predictive decomposition of time series with application to seismic exploration. *Geophysics* , 1954 , **32** :418 ~ 484
- [8] Robinson E A . Predictive decomposition of seismic traces. *Geophysics* , 1957 , **22** :767 ~ 778
- [9] Robinson E A , Treitel S . Geophysical Signal Analysis. Prentice-Hall , Inc , 1980
- [10] Saggaf M M , Robinson E A . A unified framework for the deconvolution of traces of nonwhite reflectivity. *Geophysics* , 2000 , **65** :1660 ~ 1676
- [11] Caianiello E R . Outline of a theory of thought-processes and thinking machines. *J . Theoret . Biol .* , 1961 , **2** :204 ~ 235
- [12] Fu L Y . A neuron filtering model and its neural network for space-and time-varying signal processing. Third International Conference on Cognitive and Neural Systems , Boston University , Paper Vision B03 , 1999
- [13] Fu L Y . Caianiello neural network method for geophysical inverse problems. In : Poulton M . Computational Neural Networks for Geophysical Data Processing. Amsterdam : Pergamon Press , 2001 . 187 ~ 215
- [14] Fu L Y . Joint inversions of seismic data for acoustic impedance. *Geophysics* , 2004 , **69** :994 ~ 1004
- [15] 崔炯成,吴媚,李维新等.高分辨率非线性地震波阻抗反演方法和应用.石油物探,2007,**46**(1):1~12
Cui J C , Wu M , Li W X , et al . Nonlinear high-resolution impedance inversion method and its application. *GPP* , 2007 **46** (1) :1 ~ 12
- [16] Fu L Y . Joint lithologic inversion. In : Wong P , Aminzadeh F , Nikravesh M eds . Soft Computing for Reservoir Characterization and Modeling. Springer-Verlag Publishers , 2002 . 511 ~ 530
- [17] Burge D W , Neff D B . Well-based seismic lithology inversion for porosity and pay-thickness mapping. *The Leading Edge* , 1998 , **17** : 166 ~ 171