

地质条件约束的多属性智能融合储层预测方法 ——以渤海湾盆地埕岛油田中二区为例

郭怡萱¹, 谢鹏飞¹, 邢恩浩², 尹艳树¹, 胡 迅¹, 王立鑫¹

(1. 长江大学 地球科学学院, 湖北 武汉 430100; 2. 中国石化 胜利油田分公司 海洋采油厂, 山东 东营 257237)

摘要:埕岛油田中二区馆陶组上段发育典型的曲流河沉积, 具有平面相变快、砂体叠置关系复杂的特点。受海上采集条件限制, 开发井网稀疏、地震资料品质低, 导致砂体准确预测困难, 无法满足剩余油开发的需求。鉴于此, 文中提出地质条件约束的多属性智能融合储层预测方法: ①通过井-震标定引入地质条件约束, 结合局部砂体相关性高的资料和曲流河模式, 准确刻画出局部的储层分布, 将其作为智能算法的监督标签; ②通过属性提取和频谱分解可优选出与储层相关性高的地震属性, 作为训练样本集; ③采用遗传-卷积神经网络融合算法(genetic algorithm-convolutional neural network), 对研究区海上稀井网条件下的储层砂体进行了精细刻画。研究结果表明: ①地质条件约束的多属性智能融合储层预测方法, 在显著提升计算效率的同时提高了储层预测的准确率; ②预测的平面属性与砂体厚度相关性好(决定系数 $R^2 = 0.865$), 河道的平面形态与边界得到了准确刻画; ③剖面上砂体的预测结果与井上构型剖面吻合率高, 将预测结果采样后与井上岩相测井解释对比, 预测准确率达到86.11%。该研究方法可为相似油田的储层预测提供一种高精度、可操作的手段, 具有重要的推广价值。

关键词: 稀井网; 卷积神经网络; 遗传算法; 智能融合; 曲流河; 储层预测; 中二区; 埕岛油田; 渤海湾盆地

中图分类号: TE122.2

文献标识码: A

Geologically constrained reservoir prediction via multi-attribute intelligent fusion: A case study of the Block Zhong-2, Chengdao oilfield, Bohai Bay Basin

GUO Yixuan¹, XIE Pengfei¹, XING Enhao², YIN Yanshu¹, HU Xun¹, WANG Lixin¹

(1. School of Geosciences, Yangtze University, Wuhan, Hubei 430100, China; 2. Offshore Oil Production Factory, Shengli Oilfield Branch Company, SINOPEC, Dongying, Shandong 257237, China)

Abstract: The upper member of the Guantao Formation in Block Zhong-2 of Chengdao oilfield develops typical meandering river deposits, featuring rapid lateral facies transitions and complex superimposed sandbodies. Constraints in offshore data acquisition have resulted in sparse development well patterns and degraded seismic data quality. These limitations hinder accurate sandbody prediction and fail to meet the requirements for remaining oil development. To address these challenges, this study proposes an intelligent reservoir prediction method based on geologically constrained multi-attribute fusion, with steps shown as follows. (1) Geological constraints are integrated via well-to-seismic calibration. By combining meandering river depositional models with datasets showing high local sandbody correlation, local reservoir distributions are accurately delineated to serve as supervisory labels for the intelligent algorithm. (2) Seismic attributes highly correlated with reservoir properties are optimized through attribute extraction and spectral decomposition to construct the training dataset. (3) An integrated Genetic Algorithm-Convolutional Neural Network (GA-CNN) algorithm is adopted to achieve high-resolution characterization of reservoir sandbodies under the sparse well patterns typical of offshore fields. The research results indicate that: (1) the proposed geologically constrained multi-attribute fusion method significantly enhances computational efficiency while simultaneously improving prediction accuracy; (2) the predicted planar attributes correlate well with sandbody thickness (coefficient of determination $R^2 = 0.865$), and the planform geometry and boundaries of the channels are

收稿日期: 2025-09-23; 修回日期: 2026-02-24。

第一作者简介: 郭怡萱(2000—), 女, 硕士研究生, 油气田开发地质。E-mail: 2023710475@yangtzeu.edu.cn。

通信作者简介: 谢鹏飞(1993—), 男, 副教授, 硕士研究生导师, 油气田开发地质及机器学习。E-mail: pengfei.xie@yangtzeu.edu.cn。

基金项目: 国家科技重大专项(2025ZD1405403); 国家自然科学基金项目(42502128, 42372137)。

faithfully recovered; (3) predicted sandbodies on cross-sections exhibit high consistency with well-based architectural profiles, as the comparison between the sampled prediction results and lithofacies log interpretations yielding an accuracy of 86.11%. This proposed method provides a high-precision, robust, and operational tool for reservoir prediction in analogous oilfields, demonstrating significant potential for broad industrial application.

Key words: sparse well pattern, convolutional neural network (CNN), genetic algorithm (GA), intelligent fusion, meandering river, reservoir prediction, Block Zhong-2, Chengdao oilfield, Bohai Bay Basin

引用格式:郭怡萱,谢鹏飞,邢恩浩,等.地质条件约束的多属性智能融合储层预测方法——以渤海湾盆地埕岛油田中二区为例[J].石油与天然气地质,2026,47(4):1405–1420. DOI:10.11743/ogg20260422.

GUO Yixuan, XIE Pengfei, XING Enhao, et al. Geologically constrained reservoir prediction via multi-attribute intelligent fusion: A case study of the Block Zhong-2, Chengdao oilfield, Bohai Bay Basin[J]. Oil & Gas Geology, 2026, 47(4): 1405–1420. DOI: 10.11743/ogg20260422.

储层预测是指综合利用地质、地震和测井等各类资料,对地下储层的空间分布、岩性和物性进行综合推断和描述^[1]。一维高精度的岩心与测井资料可以较准确地推断井周储层信息,却难以预测井间三维储层的空间分布,尤其针对稀疏井网的情况^[2]。三维地震资料以其覆盖范围广、横向连续性好的独特优势,成为井间储层预测不可或缺的关键数据^[3],特别是井距较大的海上油田^[4–5]。但是,地震资料往往分辨率低,使得地震储层表征具有多解性强的特点,因此,如何降低地震储层预测结果的不确定性一直是油气藏表征的关键问题^[6]。近年来,随着人工智能技术的快速发展,机器学习方法在地震储层预测中的应用日益成熟^[7],使储层预测精度得到有效提升^[8]。该方法通过反向传播BP神经网络^[9]、支持向量机^[10–12]、随机森林^[13–14]和极限学习机^[15]等机器学习算法,较好地建立了地震数据与储层参数之间的非线性映射关系,进而预测储层分布。但BP神经网络训练效率较低,且容易陷入局部最优解^[16];支持向量机在小样本、高维地震属性分类问题上表现出良好的泛化能力,然而其参数调优过程较为复杂,在大规模三维地震数据体上训练耗时过长^[17];而随机森林基于集成学习策略,调节参数少,预测结果稳定,并能评估各地震属性的重要性,因而适用于多属性融合的储层表征^[18]。宋建国等使用随机森林算法对海上和陆地2种不同环境的实际工区进行储层预测,预测的结果较支持向量机算法更好^[19]。但是,随机森林模型本身缺乏空间连续性的感知能力且训练成本较高。极限学习机以前馈神经网络的快速训练为突出优势,且预测结果误差小,泛化能力强^[20]。张宪国等采用基于极限学习机的地震多属性融合技术进行曲流河相储层砂体预测,其单井吻合率较支持向量机和BP神经网络分别提高了6.6%和10.0%^[21]。极限学习机的预测结果受随机初始化影响较大,稳定性仍有待提高。然而,这些基于数据的机器储层预测学习方法

缺少地质条件的约束,储层预测结果往往不符合地质模式,难以真实地再现地下储层分布,从而影响到后续剩余油开发。

为此,本文提出了地质条件约束的多属性智能融合储层预测方法。该方法在传统基于数据的地震储层预测方法的基础上,充分考虑了研究区的地质特征。首先,将地震资料进行分频处理,通过相关性分析,优选出与储层砂体相关性高的地震属性。其次,根据测井和地震解释结果,对砂体进行识别与刻画,并将地质认识纳入其中。最后,利用遗传-卷积神经网络建立地震属性与砂体分布之间的非线性关系,得到网络模型,用于预测储层分布。以渤海湾盆地埕岛油田中二区为例,对该方法进行了检验,预测准确率达到86.11%。

1 地质条件约束的多属性智能融合储层预测方法

1.1 方法原理

本方法将研究区地质条件以标签的形式融入卷积神经网络的训练框架,利用其强大的二维图像特征提取与分类能力^[22],从地震属性中自主学习与砂体标签相关联的判别性模式,最终获得符合研究区地质特征的网络模型。

卷积神经网络的结构由输入层、卷积层、池化层及全连接层(也称输出层)构成(图1)^[23]。卷积神经网络的核心是卷积层,包括卷积运算和激活函数[整流线性单元(ReLU)^[24]]。卷积神经网络由多个卷积层组成,通过堆叠多个卷积层,形成从低级到高级的层次化特征表示。浅层卷积学习边界等低级特征,中层卷积学习局部组合模式,深层卷积通过深层网络和非线性激活逐步融合全局信息。




图1 地震属性的卷积过程示意图

Fig. 1 Schematic of the convolution process for seismic attributes

在本文卷积神经网络的应用中,卷积层由一个 3×3 滤波器(ω)构成,其公式为:

$$h_{u,v}^k(x_{u,v}) = f\left(\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} \omega_{i,j}^k x_{u+i, v+j} + b^k\right) \quad (1)$$

式中: $h(x)$ 为卷积层的输出层; x 为输入特征图; u 和 v 为输出特征图的位置坐标; i 和 j 为滤波器内部的权重坐标; $\omega_{i,j}^k$ 为第 k 个滤波器在位置 (i,j) 的权重参数; N_i 和 N_j 分别为滤波器的高度和宽度; b^k 为第 k 个滤波器的偏置(用于调整输出值的偏移)。其中采用ReLU函数作为激活函数,其定义为 $f(x) = \max(0, x)$,该函数具有计算量小、梯度求取简单以及收敛速度快等优点。为确定最优的 ω 和 b^k ,卷积神经网络的训练过程需要花费大量时间。此外,卷积神经网络也有可能收敛到局部最优而不是全局最优^[25]。

为解决卷积神经网络易陷入局部最优的问题,本方法采用遗传算法优化卷积神经网络。遗传算法是一种模仿自然选择和遗传过程的启发式搜索算法,具有很强的鲁棒性与出色的全局寻优能力^[26]。遗传算法还可以与其他优化方法相结合,创建混合算法,利用每种算法的优势来提高求解的效率与质量^[27-28]。遗传-卷积神经网络首先将卷积网络的各种超参数(如学习率、优化器和隐含神经元层数等)转换为编码形式,随机生成初始种群。之后,利用遗传算法进行种群演化,其中以卷积神经网络的预测误差作为个体适应度评价依据,通过选择、交叉与变异等遗传操作逐步搜寻得到最优解(图2)。具体分3个步骤。

1) 编码

根据卷积神经网络的架构,可确定其待训练网络的权重数量。每个权重值对应染色体上的一个基因,将这些基因按网络层顺序排列,即定义了染色体的长




图2 遗传算法流程

Fig. 2 Workflow of the genetic algorithm

度与结构。将需要优化的超参数(如各层卷积核数量和学习率等)的取值空间,作为遗传算法的搜索空间^[29]。在此空间内随机生成一组编码后的染色体,即构成初始种群 X_1 。

2) 评估适应度

在遗传算法中,采用适应度函数对种群中的个体进行评价。将适应度定义为训练过程中在验证集上所能达到的最高准确率。为提升评估效率,训练过程中采用了早停技术(early stopping)^[30],其耐心参数(patience)设置为5,用来监控验证集准确率的变化,并在其性能不再提升时提前终止训练。

3) 分3个阶段进行遗传操作

①选择阶段:反映了自然选择的概念,即选择表现出最小误差的个体。计算每个个体的学习误差(E):

$$E = \sum_{i=1}^N E_i, \text{ 其中 } E_i = \frac{1}{2} \sum_{l=1}^L (y_l^i - c_l^i)^2 \quad (2)$$

式中: N 为训练样本总数; E_i 为第 i 个样本的学习误差; L 为输出的单元数量; $y_l^i - c_l^i$ 为第 i 个样本训练时第 l 个

输出的实际输出与期望输出的差。选择的个体基于其适应度值按概率从种群中筛选出父代个体。个体被选中的概率由其适应度值决定,适应度值越高,被选中的概率越大。根据公式(3)计算个体被选中的概率:

$$P(i) = \frac{f(i)}{\sum_{j=1}^N f(j)} \quad (3)$$

式中: $P(i)$ 为被选中的概率; $f(i)$ 为适应度值; N 为种群中个体的总数; $\sum_{j=1}^N f(j)$ 为种群中所有个体的适应度值的总和。根据各染色体适应度值,采用轮盘赌法^[31]进行复制,得到种群 X_2 。

②交叉阶段:通过交换或组合父代个体的基因来产生新个体。在此过程中,种群 X_2 中染色体的权值集合会随机交换片段,从而创造出新的优化组合,这一机制类似于自然进化中的随机基因交换^[32]。交叉操作以一定概率发生,将交叉概率 P_c 初始值设为0.8,通过此过程得到群体 X_3 。在卷积层中,该过程随机从父代中选择一个,将其对应的过滤器结构编码复制到子代。对全连接层的每个神经元,同样随机选择一个父代,并将其对应的连接权重编码拷贝至子代。交叉操作算子如下。

设2个父代个体为:

$$P_1 = \{C_1^1, C_2^1, \dots, C_m^1, F_1^1, F_2^1, \dots, F_n^1\} \quad (4)$$

$$P_2 = \{C_1^2, C_2^2, \dots, C_m^2, F_1^2, F_2^2, \dots, F_n^2\} \quad (5)$$

式中: C_k^p 为父代 p 中第 k 个卷积过滤器的编码(包含所有权重参数), $p = 1, 2, k = 1, 2, \dots, m$; F_l^p 为父代 p 第 l 个全连接神经元的编码(包含所有输入连接权重), $l = 1, 2, \dots, n$ 。假设网络结构固定,2个父代具有卷积过滤器(m 个)和全连接神经元(n 个)。

生成的子代个体 Y 为:

$$Y = \{\tilde{C}_1, \tilde{C}_2, \dots, \tilde{C}_m, \tilde{F}_1, \tilde{F}_2, \dots, \tilde{F}_n\} \quad (6)$$

式中: $\tilde{C}_k$ 为子代中第 k 个卷积过滤器的编码; $\tilde{F}_l$ 为子代中第 l 个全连接神经元的编码。

每个模块选择的规则为:

$$\tilde{C}_k = \begin{cases} C_k^1 & r_k < 0.5 \\ C_k^2 & r_k \geq 0.5 \end{cases}, k = 1, 2, \dots, m \quad (7)$$

$$\tilde{F}_l = \begin{cases} F_l^1 & s_l < 0.5 \\ F_l^2 & s_l \geq 0.5 \end{cases}, l = 1, 2, \dots, n \quad (8)$$

式中: $r_k, s_l \sim U(0, 1)$ 为独立均匀分布的随机变量。

③变异阶段:为了避免收敛到局部极小值,一旦误差函数稳定,就会引入变异。在这一阶段,权重被随机改变,由变异特定的参数控制(如变异的概率和涉及的突变数量)。若对卷积层的权重进行变异,则采用高斯变异^[33],为每个权重添加一个均值为0、标准差为0.05

的高斯随机噪声。若针对神经元,则将权重以一定概率替换为来自初始分布的新随机值。通常情况下,变异率明显低于交叉率,将发生变异的染色体基因位数所占全体染色体的基因总位数的初始概率设为0.01。与神经网络的训练持续时间相比,这一阶段需要的时间明显更少。

这3个阶段会循环迭代,直至权重(即个体)不断优化,达到损失函数设定的最小阈值。

1.2 具体步骤

地质条件约束的多属性智能融合储层预测方法分为3个部分(图3)。

1) 建立地震属性训练样本

通过井-震标定,整合深度域井上测井信息和时间域地震信息。采用广义谱分解技术^[34],对原始地震数据进行频谱分解,得到不同频段的地震属性(峰值频率为10~50 Hz)。把由频谱分解后的地震数据提取的均方根振幅属性、最大振幅属性和最小振幅属性与由测井解释获得的砂体厚度进行相关性分析,优选出相关性高的地震属性^[35](例如,本文选取16, 37和46 Hz这3种峰值频率地震数据的最小振幅属性),作为智能融合所用的训练数据集。

2) 地质条件约束的砂体识别与刻画

由于缺乏岩心数据,以井上砂体解释结论为出发点,依据高相关性(决定系数 $R^2 = 0.711$)的局部地震属性,以沉积模式为指导刻画出空间砂体(本文刻画的砂体为平均宽150 m、厚6 m的河道),空间砂体通过采样形成数据点(采样间距垂向为1 m、横向为25 m),作为智能融合的砂体属性标签,通过该方式可以引入高准确度的地质知识信息。

3) 智能融合

采用遗传-卷积神经网络算法融合优选出的3个地震属性,输入训练样本数据和融合数据标签,经过网络训练(设定阈值为0.85,迭代衰减率为0.01,最大迭代次数为20 000次)形成多地震属性与砂体解释结论的非线性网络模型,用于全区的储层预测。

2 应用实例

2.1 区域概况

埕岛油田位于渤海湾盆地的浅海海域,构造上处于渤中拗陷与济阳拗陷交汇处的埕北低凸起东南端,西南以埕北断层与埕北凹陷相邻,向北、向东倾覆于渤




图3 地质条件约束的多属性智能融合储层预测方法示意图

Fig. 3 Schematic illustration of the geologically constrained multi-attribute intelligent fusion method for reservoir prediction
(x , y 和 z 为三维空间坐标系中的三个互相垂直的坐标轴。)

中凹陷和桩东凹陷^[36-37]。埕北低凸起为潜山背景下发育起来的北西走向的潜山披覆构造带^[38](图4)。自下而上钻遇的地层依次为:古生界、中生界、古近系(沙河街组和东营组)、新近系(馆陶组和明化镇组)和第四系(平原组)^[39]。其中馆陶组上段为该区主力含油层系,

发育典型的曲流河沉积^[40]。

研究区位于埕岛油田中部,全区面积为10.75 km²,钻井的井距较大(200~500 m)且分布不均。三维地震数据覆盖全区,道间距为25 m,垂直采样间隔为1 ms。目的层地震纵波平均速度为2 164 m/s,主频为




图4 渤海湾盆地埕岛油田区域构造位置及地层综合柱状图

Fig. 4 Regional tectonic setting and composite stratigraphic column of the Chengdao oilfield, Bohai Bay Basin

a. 渤海湾盆地位置及构造单元划分; b. 埕岛油田位置; c. 中二区钻井分布; d. 地层综合柱状图

50 Hz,难以精确预测储层分布(图5)。因此,本文提出地质条件约束的多属性智能融合储层预测方法,用于有效地预测研究区目的层段储层分布,为后续油田的高效开采提供依据。

2.2 基于频谱分解的地震属性

原始地震资料难以精确预测储层分布,通过地震资料的分频处理,可以降低调谐现象的影响,从而减少地震解释的多解性^[41]。在Ricker子波(零相位子波)的情况下,地震垂向分辨率的极限通过瑞利准则(Rayleigh criterion)来确定^[42]:

$$h_{\max} = \frac{\lambda_d}{4} = \frac{VT}{4} = \frac{V}{4f_d} = \frac{V}{4(1.3f_p)} \quad (9)$$

式中: $h_{\max}$ 为垂向分辨率极限,m; λ_d 为主波长,m; V 为地层速度,m/s; T 为主周期,s; f_d 为Ricker子波的主频,Hz; f_p 为峰值频率,Hz。

埕岛油田中二区目的层段垂向分辨率为10.82 m,大多数砂体厚度低于地震垂向分辨率,这使得地震解释存在很大的不确定性。采用广义谱分解的方法,将研究区原始地震数据(峰值频率为39 Hz,频宽为15~50 Hz)分解成为3个不同频宽的地震属性(图6):①峰值频率为16 Hz(频宽为11~24 Hz);②峰值频率为37 Hz(频宽为19~46 Hz);③峰值频率为46 Hz(频宽

为28~55 Hz)。使用公式(9)可以计算出3个地震体的垂向分辨率,分别为26.01,11.24和9.05 m。

图7分析了不同频率的均方根振幅属性、最大振幅属性和最小振幅属性与砂体厚度的相关性,结果表明这些单一的地震属性与砂体厚度的相关性低,只能反映地质体某些方面的特征,具有明显的多解性与局限性,难以直接用于高精度储层预测。但是,部分散点可见较高的相关性(图7红色圈部分),不同主频的地震资料可识别不同厚度砂体,如薄层砂体(厚度1~4 m)与峰值频率为46 Hz的地震属性相关性较好($R^2 = 0.559 \sim 0.621$)(图7a—c);厚层砂体(厚度8~15 m)与峰值频率为16 Hz的地震属性相关性较好($R^2 = 0.697 \sim 0.789$)(图7g—i)。因此,本文基于相关性分析结果,选取了16,37和46 Hz这3种峰值频率的地震数据体,以优选出的最小振幅属性作为遗传-卷积神经网络的输入数据集。

2.3 基于地质条件定义的数据标签

在遗传-卷积神经网络训练之前,需要定义数据标签来约束学习过程,使预测结果符合研究区地质特征。但地下储层的非均质性制约了砂体识别的精度,导致难以获取准确的砂体标签。埕岛油田中二区因缺乏岩心资料这一关键的直接识别证据,进一步增加了砂体识别的难度,而伽马(GR)曲线与砂体有很强的相




图5 埕岛油田中二区原始地震数据经过90°相位转换的剖面(a)及地震频谱分析(b)

Fig. 5 Seismic section after 90° phase rotation for Block Zhong-2, Chengdao oilfield (a) and the corresponding seismic spectral analysis for the extracted data (b)

(剖面位置见图4c。)




图6 埕岛油田中二区频谱分解结果

Fig. 6 Spectral decomposition results for the Block Zhong-2, Chengdao oilfield

a_1 - a_2 , b_1 - b_2 , c_1 - c_2 . 分别为峰值频率16, 37和46 Hz的地震属性; a_1 - c_1 . 经90°相位转换的剖面(剖面位置见图4c); a_2 - c_2 . 地震频谱分析




图7 埕岛油田中二区由不同频率地震体提取的均方根振幅、最大振幅和最小振幅属性与砂体厚度的相关性

Fig. 7 Correlation analysis between sandbody thickness and seismic attributes extracted from volumes of diverse frequencies, Block Zhong-2 Chengdao oilfield

a—c, d—f, g—i. 分别为46 Hz, 37 Hz, 16 Hz峰值频率

关性(图8),可作为可靠的识别参数。

通过分析研究区测井曲线与地震响应之间的关系,建立了研究区井-震识别图版(图9),以满足地震剖面砂体的精细识别。河道主体在测井上表现为GR曲线低值,呈钟形或箱形分布,内部有较多的轻微回返;在地震上呈现透镜状,中-强振幅,连续性好。河道边部在测井上表现为钟形和指形GR曲线;在地震上表现为中-弱振幅,横向变化快。泥岩在测井上表现为自然电位(SP)曲线贴近泥岩基线,常呈直线分布,而GR曲线呈低幅度齿状;在地震上表现为低振幅、强连续性、横向稳定。

由于研究区井网稀疏,为降低井间预测的不确定性,本次研究对目的层段的原始地震属性进行属




图8 埕岛油田中二区砂体厚度与自然伽马测井值(GR)的相关性

Fig. 8 Correlation analysis between sandbody thickness and gamma-ray (GR) curves, Block Zhong-2, Chengdao oilfield




图9 埕岛油田中二区井-震识别图版

Fig. 9 Well-to-seismic identification template for the Block Zhong-2, Chengdao oilfield

性提取(图 10a), 优选出与砂体厚度相关性最好的均方根振幅属性(图 10b), 并结合原始地震数据与遗传反演剖面(图 10c, d), 进行砂体平面与垂向表征。在测井解释和地震解释的基础上, 将砂体数据标记为三维空间上的一组点, 作为标签数据。此外, 研究区发育曲流河沉积, 曲流河砂体平面上呈现弯曲的条带状, 剖面上呈现不对称的透镜状, 将此类形态先验知识作为约束条件引入标签(图 11), 从而降低预测的不确定性。本次研究采用 Petrel 软件绘制河道砂体(图 12a), 以连续地质体平均等间距采样点为离散点, 将其转化为三维空间上的点集(图 12b), 经过重采样处理以匹配地震数据。泥岩标签的定义也采用与砂岩相同的流程, 最终利用标记的点集与地震属性进行学习。


2.4 研究区储层预测

本次使用 90 口井作为训练数据集, 10 口井作为测试集(其中包含 1 口水平井), 对 Ng₁₊₂ 砂层组(馆陶组 1+2 砂层组)进行储层预测。遗传-卷积神经网络设定

的参数如下: 一个 3 × 3 × 3 卷积核的中值滤波器, 隐藏层由 3 个卷积层组成, 网络深度设置为 3(对应 3 个地震属性), 设定阈值为 0.85, 迭代衰减率为 0.01, 最大迭代次数为 20 000 次。时窗值越接近真实地震小波(主频 50 Hz), 预测结果越好。为此, 将主测线方向与联络测线方向的半范围均设为 1, 重采样参数设为 3, 垂直范围设为 50。为提高遗传-卷积神经网络的计算速度, 使用上、下层面控制训练范围, 通过多轮迭代将地震属性转化为网络模型。

将预训练的网络模型应用于实际的储层预测。平面上的储层预测结果(图 13a)相比于根据原始地震数据提取的属性(图 10a)所预测的河道连续性更好, 形态和边界更为清晰, 且噪点数量更少。对预测的平面属性与砂体厚度进行相关性分析(图 13b), R² 达到 0.865, 较原始地震属性(R² = 0.711)得到了明显提升。

采用阈值截断的方式由网络模型的属性值得到岩相模型。最终的预测结果(图 14b)与原始地震数据(图 14a)有很强的相关性, 预测结果与井上厚层砂体完

图10 埕岛油田中二区 Ng_{1+2}^{1-2} 小层砂体的垂向表征Fig. 10 Vertical characterization of sandbodies in sublayer Ng_{1+2}^{1-2} , Block Zhong-2, Chengdao oilfield

a. 均方根振幅属性值平面分布; b. 均方根振幅与砂体厚度相关性分析; c. 原始地震砂体垂向表征; d. 遗传反演砂体垂向表征

GR. 自然伽马测井值

(剖面位置见10a)






图11 数据标签定义示意图

Fig. 11 Schematic diagram of data label definitions

图12 埕岛油田中二区 Ng_{1+2}^{1-2} 小层砂体刻画结果Fig. 12 Delineation of sandbodies in sublayer Ng_{1+2}^{1-2} , Block Zhong-2, Chengdao oilfield

a. 砂体解释; b. 砂体采样标记点

(GR为自然伽马测井值; x, y 和 z 为三维空间坐标系中的3个互相垂直的坐标轴。)图13 埕岛油田中二区 Ng_{1+2}^{1-2} 小层平面储层预测结果(a)及其与砂体厚度相关性分析(b)Fig. 13 Planar reservoir prediction results (a) and correlation analysis (b) for sublayer Ng_{1+2}^{1-2} , Block Zhong-2, Chengdao oilfield

全吻合,而与薄层砂体则部分吻合。结合研究区地质模式及测井数据对目的层段进行构型解剖(图14c)。剖面的预测结果虽然存在一些噪点且与薄层砂体只有部分吻合,但仍与解剖结果表现出高度的一致性。

对局部选取的砂体与剖面预测结果进行视觉相似性对比是不准确的,因此采用网格定量对比的方式计算预测准确率。以0.125 m为一个单位,将预测结果采样到井上,与井上测井岩相解释结论进行差值计算,统计预测正确的频数并计算占比,得到剖面预测的正确率。

本次研究中作为训练数据的90口井,其在 Ng_{1+2} 砂

层组的采样点共计63 265个,有87.72%(55 499/63 265)的采样点与测井岩相解释吻合。由于训练数据包含了部分测井岩相解释数据,所以这部分预测结果并不完全准确。因此,采用10口测试井对预测结果进行评价,有86.11%(6 224/7 228)的采样点与测井岩相解释吻合。测试井包含一口水平井(22FC-P2井),其水平段可验证反演结果在空间上的连续性和横向变化规律是否与研究区地质认识相符,通过计算发现有88.96%(3 271/3 677)的采样点与井上测井岩相解释结果吻合。高精度预测结果证明了此方法的有效性。




图 14 埕岛油田中二区 Ng_{1+2} 砂层组地震数据、预测结果及构型剖面之间的吻合情况(剖面位置见图 4c)

Fig. 14 Spatial consistency among seismic data, prediction results, and architectural profiles for the Ng_{1+2} sand group, Block Zhong-2, Chengdao oilfield (see Fig. 4c for the section location)

a. 原始地震数据经 90° 相位转换剖面; b. a 图视域的预测结果剖面; c. 构型解剖结果剖面

2.5 不同机器学习方法的储层预测结果

选取BP神经网络、支持向量机和随机森林算法,使用与前文一致的训练数据集和测试集进行多属性智能融合储层预测(图 15),统计平面上和剖面上的预测效果,并与地质条件约束的多属性智能融合储层预测方法所得结果进行比较。BP神经网络、支持向量机和随机森林算法所得结果与砂体厚度的 R^2 分别为

0.737,0.766和0.801(图 16),在剖面上采样点与测井岩相解释吻合率分别为 72.57%,75.33%和 79.66%(表 1)。将这 3 种机器学习方法的预测结果与地质条件约束的多属性智能融合储层预测方法的预测结果进行比较,结果表明地质条件约束的多属性智能融合储层预测方法效果更好。

在地震储层预测的实际应用中,机器学习算法的预测精度受限于其模型原理,其局限性主要表现为空




图 15 埕岛油田中二区不同机器学习方法储层平面预测结果

Fig. 15 Planar prediction results obtained using various machine learning methods for the Block Zhong-2, Chengdao oilfield
a. BP神经网络;b. 支持向量机;c. 随机森林




图 16 埕岛油田中二区不同机器学习方法的储层平面预测结果与砂体厚度的相关性

Fig. 16 Correlation between sandbody thickness and planar prediction results from various machine learning methods , Block Zhong-2, Chengdao oilfield
a. BP神经网络;b. 支持向量机;c. 随机森林

表 1 埕岛油田中二区不同机器学习方法在剖面上的预测结果对比

Table 1 Section-based prediction results obtained using various machine learning methods, Block Zhong-2, Chengdao oilfield

井类型(样本量)	预测结果采样点与测井岩相解释吻合率		
	BP神经网络	支持向量机	随机森林
训练数据井(90口)	80.27%(50781/63265)	82.18%(51989/63265)	84.87%(53695/63265)
测试井(10口)	72.57%(5245/7228)	75.33%(5445/7228)	79.66%(5758/7228)
水平井(22FC-P2井)	72.83%(2678/3677)	75.28%(2768/3677)	78.35%(2881/3677)

注:(50781/63265)代表(吻合采样点个数/全部采样点个数)。

间噪点与薄层砂体识别误差。①空间噪点的产生主要源于算法对数据噪声与空间关系的处理方式。BP神经网络在学习过程中容易过度拟合地震数据本身存在的局部噪声,从而产生随机噪点;支持向量机决策边界的形成高度依赖支持向量的分布特征,少量异常样本可能被识别为支持向量,在空间维度上表现为孤立的错误分类点(即噪点);随机森林算法将各地震道视为独立样本进行预测,没有考虑储层空间的连续性,导致预测结果在相邻地震道之间出现明显的不连续性,呈现类似“椒盐噪声”的空间跳跃现象。②薄层砂体的识别误差则与算法对局部微弱特征的敏感度密切相关。BP网络在特征提取时缺乏显式的多尺度感知机制,难以有效捕捉与薄层相关的微弱信号特征,进而限制了薄层砂体的识别;支持向量机的核心参数(如核函数)通常以最大化整体分类精度为目标进行优化,这种全局优化策略会降低模型对薄层等局部微弱特征的判别敏感性;随机森林算法集成决策遵循多数投票原则,薄层砂体微弱的地震响应易被强反射背景所掩盖,在多数投票的原则上受到主导类别的抑制,从而导致薄层漏识别或识别结果不准。

本文提出的地质条件约束的多属性智能融合储层预测方法,将地质认识以标签的形式融入神经网络的训练框架,使预测结果符合地质规律,提升薄层砂体识别能力。同时,该方法利用卷积神经网络的特征提取优势约束遗传算法的搜索方向,抑制模型训练和预测中的随机不稳定性,消除数据分布偏移引发的噪点,从而提升预测精度。

3 结论与认识

1) 地质条件约束的多属性智能融合储层预测方法,可以综合不同频段的地震属性优势信息。其采用遗传-卷积神经网络算法,并以局部准确的储层分布作为训练标签,使最终储层预测结果符合实际地下砂体分布。

2) 在埕岛油田的实际应用中,地质条件约束的多属性智能融合储层预测方法在平面上和剖面上的预测结果显著高于BP神经网络、支持向量机和随机森林算法。该方法在平面上清晰刻画了砂体边界,增强了砂体空间展布的连续性;在剖面上,则与储层构型解剖结果高度一致,充分证明了该方法能有效支撑地下储层空间的准确刻画。

3) 地质条件约束的多属性智能融合储层预测方法克服了传统方法对大量样本数据的依赖,能够有效

应对海上井网稀疏条件下曲流河相储层砂体预测的难题,具有重要的推广价值,对提升油气储层预测水平具有积极的推动作用。

参 考 文 献

- [1] 陈刚. 导航金字塔分解技术在储层地震预测中的应用研究[J]. 中国石油勘探, 2021, 26(5): 125-131.
CHEN Gang. Application of steerable pyramid decomposition technology in reservoir seismic prediction [J]. China Petroleum Exploration, 2021, 26(5): 125-131.
- [2] 岳大力, 胡光义, 李伟, 等. 井震结合的曲流河储层构型表征方法及其应用——以秦皇岛32-6油田为例[J]. 中国海上油气, 2018, 30(1): 99-109.
YUE Dali, HU Guangyi, LI Wei, et al. Meandering fluvial reservoir architecture characterization method and application by combining well logging and seismic data: A case study of QHD32-6 oilfield [J]. China Offshore Oil and Gas, 2018, 30(1): 99-109.
- [3] 曹丹平, 印兴耀, 梁锴. 基于单程波正演模拟的多尺度地震资料特征分析[J]. 地球物理学进展, 2010, 25(4): 1306-1312.
CAO Danping, YIN Xingyao, LIANG Kai. Characteristics analysis of multiscale seismic data based on forward modeling of one-way waves [J]. Progress in Geophysics, 2010, 25(4): 1306-1312.
- [4] 岳大力, 李伟, 王军, 等. 基于分频融合地震属性的曲流带预测与点坝识别: 以渤海湾盆地埕岛油田馆陶组为例[J]. 古地理学报, 2018, 20(6): 941-950.
YUE Dali, LI Wei, WANG Jun, et al. Prediction of meandering belt and point-bar recognition based on spectral-decomposed and fused seismic attributes: A case study of the Guantao Formation, Chengdao Oilfield, Bohai Bay Basin [J]. Journal of Palaeogeography (Chinese Edition), 2018, 20(6): 941-950.
- [5] 董鑫旭, 周兴海, 李昆, 等. 海上稀疏井区高精度地层格架约束下的地震沉积学刻画——以东海盆地西湖凹陷中央背斜带X区块古近系花港组为例[J]. 石油与天然气地质, 2024, 45(1): 293-308.
DONG Xinxu, ZHOU Xinghai, LI Kun, et al. Seismic sedimentological characterization of an offshore area with sparse well control under the constraint of a high-resolution stratigraphic framework: A case study of the Paleogene Huagang Formation in Block X of the central anticlinal zone in the Xihu [J]. Oil & Gas Geology, 2024, 45(1): 293-308.
- [6] 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.
- [7] 葛家旺, 陈聪, 刘培, 等. 人工智能驱动的陆架砂体地震沉积

- 学表征——以珠江口盆地惠州凹陷新近系珠江组主力砂体为例[J]. 石油与天然气地质, 2025, 46(3): 860–875.
- GE Jiawang, CHEN Cong, LIU Pei, et al. AI-driven seismic sedimentological characterization of shelf sand bodies: A case study on the Neogene Zhujiang Formation, Huizhou Sag, Pearl River Mouth Basin [J]. Oil & Gas Geology, 2025, 46 (3) : 860–875.
- [8] 刘磊, 李伟, 杜玉山, 等. 基于Stacking集成学习的分频地震属性融合储层预测方法[J]. 石油地球物理勘探, 2024, 59 (1): 12–22.
- LIU Lei, LI Wei, DU Yushan, et al. Reservoir prediction method of fusing frequency-decomposed seismic attributes using Stacking ensemble learning [J]. Oil Geophysical Prospecting, 2024, 59 (1): 12–22.
- [9] 蔡义峰, 熊婷, 姚卫江, 等. 地震多属性分析技术在薄层砂体预测中的应用[J]. 石油地球物理勘探, 2017, 52(增刊2): 140–145.
- CAI Yifeng, XIONG Ting, YAO Weijiang, et al. Thin sandstone prediction with seismic multi-attribute analysis [J]. Oil Geophysical Prospecting, 2017, 52(S2): 140–145.
- [10] LI Wei, YUE Dali, WU Shenghe, et al. Characterizing meander belts and point bars in fluvial reservoirs by combining spectral decomposition and genetic inversion [J]. Marine and Petroleum Geology, 2019, 105: 168–184.
- [11] LI Wei, YUE Dali, WANG Wenfeng, et al. Fusing multiple frequency-decomposed seismic attributes with machine learning for thickness prediction and sedimentary facies interpretation in fluvial reservoirs [J]. Journal of Petroleum Science and Engineering, 2019, 177: 1087–1102.
- [12] 李洪辉, 岳大力, 李伟, 等. 基于分频智能反演的曲流河点坝与废弃河道识别[J]. 石油地球物理勘探, 2023, 58(2): 358–368.
- LI Honghui, YUE Dali, LI Wei, et al. Identification of point bar and abandoned channel of meandering river by spectral decomposition inversion based on machine learning [J]. Oil Geophysical Prospecting, 2023, 58(2): 358–368.
- [13] 马玉彬, 刘仕友, 曹丹平, 等. 基于贝叶斯优化的随机森林在储层预测的应用[J]. 地球物理学报, 2025, 68(8): 3247–3257.
- MA Yubin, LIU Shiyou, CAO Danping, et al. Application of random forest algorithm based on Bayesian optimization for reservoir prediction[J]. Chinese Journal of Geophysics, 2025, 68 (8): 3247–3257.
- [14] 曲志鹏, 王芳芳, 张云银, 等. 基于关联规则与随机森林的地震多属性砂体厚度预测[J]. 地质科技通报, 2021, 40(3): 211–218.
- QU Zhipeng, WANG Fangfang, ZHANG Yunyin, et al. Thickness prediction of seismic multi-attributes sand based on association rules and random forests [J]. Bulletin of Geological Science and Technology, 2021, 40(3): 211–218.
- [15] 陈芋潜, 文晓涛, 何健, 等. 基于极限学习机的裂缝带预测[J]. 石油物探, 2021, 60(1): 149–156, 174.
- CHEN Qianshu, WEN Xiaotao, HE Jian, et al. Prediction of a fracture zone using an extreme learning machine [J]. Geophysical Prospecting for Petroleum, 2021, 60(1): 149–156, 174.
- [16] 王猛, 董宇, 蔡军, 等. 基于BP神经网络的储层渗透率预测及质量评价方法[J]. 地球物理学进展, 2023, 38(1): 321–327.
- WANG Meng, DONG Yu, CAI Jun, et al. Method for reservoir permeability prediction and quality evaluation based on BP neural network [J]. Progress in Geophysics, 2023, 38(1): 321–327.
- [17] 徐颖晋, 庞振宇. 基于改进支持向量机的致密砂岩储层参数预测研究[J]. 现代电子技术, 2024, 47(5): 132–138.
- XU Yingjin, PANG Zhenyu. Research on tight sandstone reservoir parameter prediction based on improved support vector machine [J]. Modern Electronics Technique, 2024, 47 (5) : 132–138.
- [18] 宋建国, 杨璐, 高强山, 等. 强容噪性随机森林算法在地震储层预测中的应用[J]. 石油地球物理勘探, 2018, 53(5): 954–960.
- SONG Jianguo, YANG Lu, GAO Qiangshan, et al. Strong tolerance random forest algorithm in seismic reservoir prediction [J]. Oil Geophysical Prospecting, 2018, 53(5): 954–960.
- [19] 宋建国, 高强山, 李哲. 随机森林回归在地震储层预测中的应用[J]. 石油地球物理勘探, 2016, 51(6): 1202–1211.
- SONG Jianguo, GAO Qiangshan, LI Zhe. Application of random forests for regression to seismic reservoir prediction [J]. Oil Geophysical Prospecting, 2016, 51(6): 1202–1211.
- [20] 刘学艺, 李平, 郜传厚. 极限学习机的快速留一交叉验证算法[J]. 上海交通大学学报, 2011, 45(8): 1140–1145.
- LIU Xueyi, LI Ping, GAO Chuanhou. Fast leave-one-out cross-validation algorithm for extreme learning machine [J]. Journal of Shanghai Jiaotong University, 2011, 45(8): 1140–1145.
- [21] 张宪国, 吴啸啸, 黄德榕, 等. 极限学习机驱动的地震多属性融合识别曲流带单一点坝[J]. 石油地球物理勘探, 2021, 56 (6): 1340–1350.
- ZHANG Xiangguo, WU Xiaoxiao, HUANG Derong, et al. Single point bar interpretation in meandering belt with extreme learning machine driven multiple seismic attributes fusion [J]. Oil Geophysical Prospecting, 2021, 56(6): 1340–1350.
- [22] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508–2515, 2565.
- LI Yandong, HAO Zongbo, LEI Hang. Survey of convolutional neural network [J]. Journal of Computer Applications, 2016, 36 (9): 2508–2515, 2565.
- [23] XIE Pengfei, HOU Jiagen, DUAN Dongping, et al. A novel genetic inversion workflow based on spectral decomposition and convolutional neural networks for sand prediction in Xihu Sag of East China Sea [J]. Geoenergy Science and Engineering, 2023, 231(Part B): 212331.
- [24] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks [C]//Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics. Cambridge: JMLR, 2011: 315–323.
- [25] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学

- 报, 2017, 40(6): 1229-1251.
- ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [26] 国嘉, 王瑞敏, 王家海, 等. 基于遗传算法的神经网络学习方法[J]. 计算机与数字工程, 2004, 32(5): 98-101.
- GUO Jia, WANG Ruimin, WANG Jiahai, et al. Method of neural networks study based on genetic algorithms [J]. Computer & Digital Engineering, 2004, 32(5): 98-101.
- [27] 马晓敏, 王新. 基于遗传算法的BP神经网络改进[J]. 云南大学学报(自然科学版), 2013, 35(增刊2): 34-38.
- MA Xiaomin, WANG Xin. An improved BP neural network algorithm based on genetic algorithm [J]. Journal of Yunnan University (Natural Sciences Edition), 2013, 35(S2): 34-38.
- [28] 王丽敏, 乔玲玲, 魏霖静. 结合遗传算法的优化卷积神经网络学习方法[J]. 计算机工程与设计, 2017, 38(7): 1945-1950.
- WANG Limin, QIAO Lingling, WEI Linjing. Optimal convolutional neural networks learning method combined with genetic algorithm[J]. Computer Engineering and Design, 2017, 38(7): 1945-1950.
- [29] 李彦霖, 蔡满春, 芦天亮, 等. 遗传算法优化CNN的网站指纹攻击方法[J]. 信息安全, 2021, 21(9): 59-66.
- LI Yanlin, CAI Manchun, LU Tianliang, et al. A website fingerprinting attack method via convolutional neural network optimized by genetic algorithm [J]. Netinfo Security, 2021, 21(9): 59-66.
- [30] JIANG Shen, JI Zipeng, ZHU Guanghui, et al. Operation-level early stopping for robustifying differentiable NAS[C]//OH A, T. NAUMANN T, GLOBERSON A, et al. Advances in Neural Information Processing Systems 36. Red Hook: Curran Associates, Inc., 2023: 70983-71007.
- [31] 罗长寿, 左强, 李保国. 基于遗传算法的人工神经网络模型在冬小麦根系分布预报中的应用[J]. 应用生态学报, 2004, 15(2): 354-356.
- LUO Changshou, ZUO Qiang, LI Baoguo. Application of artificial neural network based on the genetic algorithm in predicting the root distribution of winter wheat [J]. Chinese Journal of Applied Ecology, 2004, 15(2): 354-356.
- [32] 刘东, 姜宸一, 张亮亮, 等. 基于GA-CNN的农业旱灾恢复力及影响因素[J]. 南水北调与水利科技(中英文), 2024, 22(4): 672-683.
- LIU Dong, JIANG Chenyi, ZHANG Liangliang, et al. Agricultural drought resilience and influencing factors based on optimized convolutional neural network of genetic algorithm [J]. South-to-North Water Transfers and Water Science & Technology, 2024, 22(4): 672-683.
- [33] 王宗生, 邵建华, 王鹏云, 等. 一种基于GACNN改进的室内可见光指纹定位算法[J]. 激光杂志, 2023, 44(1): 158-163.
- WANG Zongsheng, SHAO Jianhua, WANG Pengyun, et al. An indoor visible light fingerprint localization algorithm based on GACNN's improvement[J]. Laser Journal, 2023, 44(1): 158-163.
- [34] 李楠, 刘志峰, 杨东升, 等. 地震属性综合分析技术在河道精细刻画中的应用[J]. 中国海上油气, 2020, 32(1): 66-73.
- LI Nan, LIU Zhifeng, YANG Dongsheng, et al. Application of comprehensive seismic attributes analysis technology in fine channel characterization [J]. China Offshore Oil and Gas, 2020, 32(1): 66-73.
- [35] 李伟, 岳大力, 胡光义, 等. 分段地震属性优选及砂体预测方法——秦皇岛32-6油田北区实例[J]. 石油地球物理勘探, 2017, 52(1): 121-130.
- LI Wei, YUE Dali, HU Guangyi, et al. Frequency-segmented seismic attribute optimization and sandbody distribution prediction: An example in North Block, Qinghuangdao 32-6 Oilfield [J]. Oil Geophysical Prospecting, 2017, 52(1): 121-130.
- [36] 刘丽. 埕岛油田馆陶组曲流河砂体叠置模式[J]. 岩性油气藏, 2019, 31(1): 40-48.
- LIU Li. Sandbody superimposed pattern of meandering river facies of Guantao Formation in Chengdao Oilfield [J]. Lithologic Reservoirs, 2019, 31(1): 40-48.
- [37] 杨凤丽, 印兴耀, 吴国忱. 埕岛油田河流相储层地震描述方法[J]. 石油学报, 1999, 20(4): 24-28.
- YANG Fengli, YIN Xingyao, WU Guochen. A study on seismic description method of the fluvial facies reservoir in Chengdao Oilfield [J]. Acta Petrolei Sinica, 1999, 20(4): 24-28.
- [38] 束青林, 张本华, 高喜龙, 等. 埕岛极浅海油田高速高效开发调整关键技术[J]. 油气地质与采收率, 2020, 27(3): 1-12.
- SHU Qinglin, ZHANG Benhua, GAO Xilong, et al. Key technologies of high-speed and high-efficiency development and adjustment of Chengdao shallower sea oilfield [J]. Petroleum Geology and Recovery Efficiency, 2020, 27(3): 1-12.
- [39] 高喜龙. 渤海湾盆地埕岛油田前寒武系基底构造及储层特征[J]. 石油天然气学报, 2012, 34(1): 45-49.
- GAO Xilong. Precambrian base structure and reservoir characteristics of Chengdao Oilfield in Bohai Bay Basin [J]. Journal of Oil and Gas Technology, 2012, 34(1): 45-49.
- [40] 张善文, 才巨宏, 吴洪波. 埕岛地区馆上段储层地震岩性学研究[J]. 石油地球物理勘探, 1994, 29(增刊2): 123-128, 237.
- ZHANG Shanwen, CAI Juhong, WU Hongbo. Seismic lithology study of the Guanshang Member reservoir in the Chengdao area [J]. Oil Geophysical Prospecting, 1994, 29(S2): 123-128, 237.
- [41] 黄捍东, 张如伟, 郭迎春. 地震信号的小波分频处理[J]. 石油天然气学报, 2008, 30(3): 87-91.
- HUANG Handong, ZHANG Ruwei, GUO Yingchun. Wavelet frequency-division process for seismic signals [J]. Journal of Oil and Gas Technology, 2008, 30(3): 87-91.
- [42] RICKER N. Wavelet contraction, wavelet expansion, and the control of seismic resolution [J]. Geophysics, 1953, 18(4): 769-792.

(编辑 许诺)