

引用格式:张章,孟鹏,杨威,等.基于地震属性堆叠泛化集成学习的辫状河储层构型表征:以渤海湾盆地C-2油田为例[J].油气藏评价与开发,2025,15(1):64-72.

ZHANG Zhang, MENG Peng, YANG Wei, et al. Characterization of braided river reservoir architecture based on seismic attribute stacking ensemble learning: A case study of the C-2 oilfield in the Bohai Bay Basin[J]. Petroleum Reservoir Evaluation and Development, 2025, 15(1): 64-72.

DOI: 10.13809/j.cnki.cn32-1825/te.2025.01.008

基于地震属性堆叠泛化集成学习的辫状河储层构型表征

——以渤海湾盆地C-2油田为例

张章¹,孟鹏¹,杨威¹,张小龙¹,黄奇²,王浩然²

(1.中海石油(中国)有限公司天津分公司,天津 300459;2.武汉时代地智科技股份有限公司,湖北 武汉 430000)

摘要:C-2油田是位于渤海湾盆地的河流相海上油田,主要采用水平井开发,储层厚度薄、纵向多期砂体叠置、横向相变快,储层内部结构与连通关系复杂,受复杂的储层结构与井震资料的双重影响,稀疏井网条件下储层描述难度大,制约了油田精细挖潜效果,常规地震反演难以满足薄储层高分辨率预测与储层内部结构精细解剖的需要。针对研究油田辫状河储层结构特征,采用基于地震属性堆叠泛化集成学习的方法完成河流相复杂结构储层的预测,相较于单一的机器学习模型提高了预测精度。综合地质、地球物理与油藏动态等多维信息进行迭代优化,进一步降低地下储层预测与结构认识的不确定性,实现了研究区辫状河复杂结构储层的精细表征,为油田剩余油与潜力砂体精细挖潜提供了依据。研究表明:基于地震属性堆叠泛化集成学习的储层预测方法,不仅能有效提高地震纵向分辨率,同时具有较强的横向“相控”指示能力,预测结果包括砂体叠置关系与储层内部结构特征,更加适用于相变快、储层空间建筑结构复杂的陆相河流沉积体系储层预测与精细刻画,可为稀疏井网海上油田开发中后期河流相沉积储层构型精细表征提供借鉴。

关键词:机器学习;储层预测;辫状河;储层构型;水平井

中图分类号:TE122

文献标识码:A

Characterization of braided river reservoir architecture based on seismic attribute stacking ensemble learning: A case study of the C-2 oilfield in the Bohai Bay Basin

ZHANG Zhang¹, MENG Peng¹, YANG Wei¹, ZHANG Xiaolong¹, HUANG Qi², WANG Haoran²

(1. CNOOC(China) Limited Tianjin Branch, Tianjin 300459, China;

2. Wuhan Times GeoSmart Science and Technology Co., Ltd., Wuhan, Hubei 430000, China)

Abstract: The C-2 oilfield, located in the Bohai Bay Basin, is a fluvial-facies offshore oilfield primarily developed with horizontal wells. It is characterized by thin reservoir layers, vertically stacked multi-phase sandbodies, and rapid lateral facies transitions, leading to complex internal reservoir structures and connectivity. The combined effects of complex reservoir structures and well-seismic data make reservoir characterization challenging under sparse well patterns, hindering refined development. Conventional seismic inversion fails to meet the requirements for high-resolution prediction of thin reservoirs and detailed characterization of internal reservoir structures. To study the structural characteristics of braided river reservoirs in the oilfield, a stacking ensemble learning method based on seismic attributes was applied to predict the complex fluvial-facies reservoir structures. This approach significantly improved prediction accuracy compared to a single machine learning model. By integrating multi-dimensional information such as geology, geophysics, and reservoir dynamics, iterative optimization was conducted to further reduce the uncertainty in subsurface reservoir prediction and structural understanding. This enabled the precise characterization of the complex braided river reservoir structures in the study area, providing a basis for refined exploitation of remaining oil and potential sandbodies in the oilfield. The study demonstrates that the reservoir prediction method based on stacking ensemble learning not only enhances seismic vertical resolution, but also exhibits strong horizontal phase-control capabilities. The prediction results include sandbody stacking relationships and internal reservoir structures, making it more suitable for the prediction and fine characterization of continental fluvial sedimentary systems with rapid facies transitions and complex spatial architectural structures. This method can serve as a reference for the detailed characterization of fluvial-facies reservoir configurations during the middle and late development stages of offshore oilfields with sparse well patterns.

Keywords: machine learning; reservoir prediction; braided river; reservoir architecture; horizontal well

收稿日期:2024-06-25。

第一作者简介:张章(1985—),男,博士,高级工程师,主要从事油气田开发研究工作。地址:天津市滨海新区海川路2121号海洋石油大厦B座1223室,邮政编码:300459。E-mail:zhangzhang2@enooc.com.cn

基金项目:中国海洋石油有限公司“十四五”重大科技项目“海上‘双高-双特高’水驱油田提高采收率油藏关键技术”(KJGC2021-0501)。

海上油田稀疏井网开发条件下通常采用井震结合的思路开展储层精细研究,然而,常规确定性地震反演难以满足薄储层高分辨率预测,复合河道砂体内部单河道砂体叠置与连通关系分析,储层内部结构精细解剖的需要。地质统计学高分辨率地震反演方法虽然具有较高纵向分辨率,但其结果模型中复合河道内部砂体叠置关系或储层内部相变区域被“粗化”,降低了地震作为井间预测的“相控”指示能力,不太适用于陆相复杂相变沉积结构特征的储层预测。因此,需要探索既能提高纵向分辨率,同时又能保持储层空间结构的储层预测方法,发挥地震横向分辨率的优势,为储层结构解剖提供依据。近年来,随着大数据、人工智能技术的发展,基于数据驱动的机器学习储层预测方法得到很多学者的重视,开展了大量应用研究并取得了较好的预测效果^[1-3]。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复杂非线性预测模型,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^[4-5]。常见的基于机器学习的储层预测方法主要是基于单一机器学习算法^[6-9],缺少对多类算法的融合,但河流相地下储层结构与砂体叠置关系异常复杂,因此,亟须探索多算法集成的方法在储层预测领域的应用,进一步提升机器学习储层预测方法的泛化能力。堆叠泛化集成学习算法结合了多个模型的预测结果,相较于单一的机器学习模型,具有准确率高,过拟合风险低等优点,能够提高纵向分辨率的同时,保持了储层内部空间结构,因此,研究基于地震属性堆叠泛化集成学习储层预测方法,融合地质模式、地球物理和油藏动态等多信息迭代验证与优化,实现陆相复杂结构储层精细表征。

1 研究区概况

研究区位于渤海西部海域沙垒田凸起东块,是古隆起背景上发育的一个小型潜山背斜构造,油田的主力含油层层系自上而下分别为明化镇组、馆陶组和东营组。明化镇组为曲流河沉积,馆陶组储层主要为辫状河沉积,发育富含砂岩的河道砂体,岩性剖面上显示为正韵律沉积特征;东营组为扇三角洲沉积,发育近源的分流河道砂体。目的层砂体叠置关系与连通关系复杂,单期次河道砂体厚度介于5~10 m。研究区地震资料主频50 Hz左右,地震视分辨率介于12~15 m。主力层馆陶组采用水平井天然能量开发,特高含水阶段剩余油分布情况复杂,需通过储层精细解剖指导油田剩余油挖潜。

2 基于堆叠泛化集成学习的地震属性融合

基于深度学习的储层预测方法思路通常通过机器学习方法建立地震响应和地质参数之间的复杂非线性预测模型,挖掘地震数据蕴含的大量信息,并通过数据驱动代替传统的经验驱动,使工作流程简化^[10]。由于薄互储层预测存在较大的多解性与不确定性,单一学习模型可能无法捕捉到所有的特征或关联,因此,研究采用基于地震属性堆叠泛化集成学习的方法开展稀疏井网条件下薄储层预测,结合多种学习模型的优势,进一步提高储层预测结果准确性。

2.1 堆叠泛化集成学习方法

堆叠泛化(Stacking)模型是一种集成学习方法,采用基学习器(也称基础模型)和元学习器(也称元模型或混合模型)2层架构,组合多个基学习器的预测结果,以提高模型的准确性和鲁棒性^[11-13]。Stacking模型的基本思想是通过训练1个元模型,来实现多个不同基础模型预测结果的最佳组合,将多个基础模型的预测结果作为元模型的输入,然后通过训练元模型生成最终的预测结果,再基于Stacking集成学习的地震属性融合模型结构如图1所示。

2.2 基于堆叠泛化集成学习的地震属性融合流程

2.2.1 样本构建

深度学习依靠数据驱动,不需要先验知识,直接从测井数据、地震数据中进行信息提取与模式学习^[5],因此,做好数据预处理、获取与地震数据相对应的测井曲线标签数据、构建深度学习框架是深度学习储层预测方法的关键^[14]。纵波阻抗是重要的岩石物理参数,能够综合反映储层的岩性与物性特征,研究区岩石物理特征分析结果显示(图2),纵波阻抗能有效区分储层与非储层,因此,选取通过密度与声波曲线计算得到的纵波阻抗曲线作为测井标签数据,再在数据预处理基础上,提取与岩性、物性相关的地震属性,包括90°相移、均方根值(RMS)振幅、“甜点”属性(反射强度/瞬时频率的均方根值)、振幅包络、瞬时频率、衰减等地震属性,并将特征数据与标签数据以相同的采样率进行重采样。选取研究区30口井作为训练集数据,目的层井段长度在500 m左右,重采样间隔为1 m,然后通过计算不同地震属性与纵波阻抗标签数据的相关系数来优先敏感地震属性,开展井旁地震道各种地震属性与测井纵波阻抗的相关性分析。分析

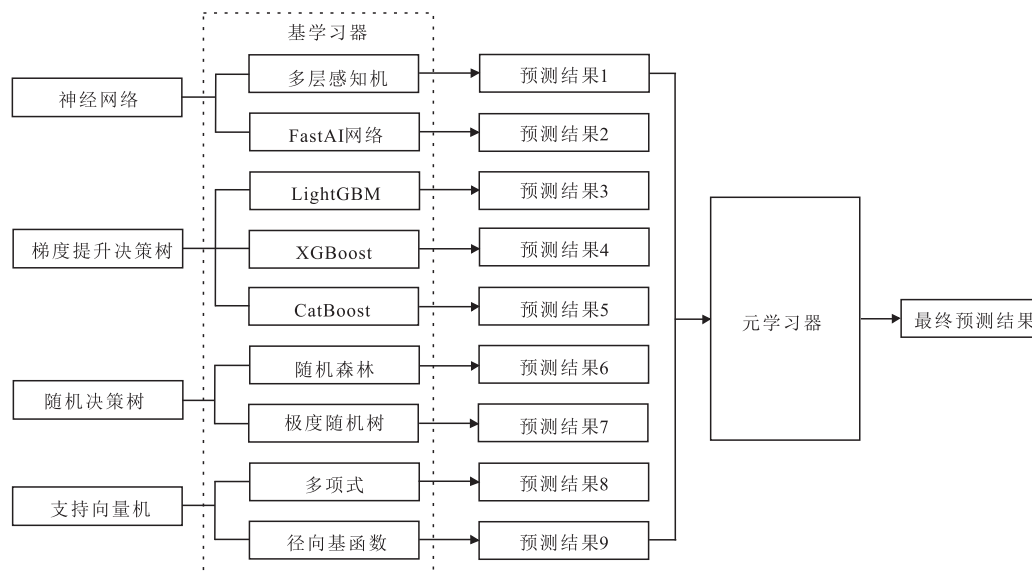


图1 堆叠泛化集成学习模型结构

Fig. 1 Stacking ensemble learning model structure

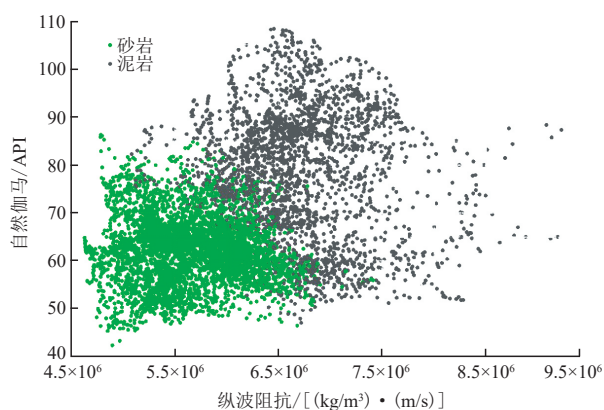


图2 渤海湾盆地研究区岩石物性分析

Fig. 2 Petrophysical property analysis of the study area in the Bohai Bay Basin

结果显示:纵波阻抗与 90° 相移、RMS振幅、“甜点”属性相关性较好,相关系数均大于0.6(表1),因此,选取地震 90° 相移数据体、RMS振幅、“甜点”属性3种地震属性作为特征数据构成样本集进行训练与预测。

2.2.2 基础模型训练与预测

考虑研究区域复杂的储层结构特征及海上稀疏井网开发条件,结合不同机器学习模型的模型特点和优势,对不同模型在储层预测方向的应用效果进行对比分析,选取泛化效果较好的机器学习模型作为研究的基学习器。结合地震属性数据特点,并尽量保证算法间的多元化,通常选择原理差异性较大的多个基础模型,并通过后验标签数据实际值与模型预测值的误差进行评价优选,选取了多层感知机、FastAI网络、LightGBM、XGBoost、CatBoost、

表1 地震属性与纵波阻抗相关性分析

Table 1 Correlation analysis between seismic attributes and P-wave impedance

参数	90° 相移	RMS振幅	甜点属性	振幅包络	瞬时频率	衰减	纵波阻抗
90° 相移	1.00	0.87	0.88	0.75	0.24	0.08	0.77
RMS振幅	0.87	1.00	0.97	0.96	0.13	0.08	0.70
甜点属性	0.88	0.97	1.00	0.92	0.35	0.10	0.68
振幅包络	0.75	0.96	0.92	1.00	0.12	0.08	0.58
瞬时频率	0.24	0.13	0.35	0.12	1.00	0.10	0.12
衰减	0.08	0.08	0.1	0.08	0.1	1.00	0.07
纵波阻抗	0.77	0.70	0.68	0.58	0.12	0.07	1.00

随机森林、极度随机树、多项式和径向基函数9种机器学习算法训练多个基础模型,这些模型包括不同超参数的深度神经网络、梯度提升决策树、随机森林、支持向量机等。沿井抽取井旁地震属性数据作为特征数据,纵波阻抗测井曲线作为标签数据,作为各基学习器的训练样本进行训练,每个模型单独使用所有的训练集数据进行训练,并使用交叉验证来评估每个模型的性能,以确保模型没有过度拟合并且具有泛化的预测能力。将训练完成的基础模型对测试集进行预测,将基础模型的预测结果作为下一层模型的训练集数据,每个基础模型的预测结果是1个元特征。

2.2.3 元模型训练与预测

元学习器(元模型或混合模型)结合上个阶段预测得

到的元特征数据(基于不同机器学习器得到的预测结果)和原始标签数据为样本数据进行模型训练与预测,并输出最终的Stacking模型预测结果,实现多个不同的基础模型的预测结果的最佳组合,以得到更准确的储层预测结果。本次结合上个阶段基础模型预测得到的9个元特征数据和原始标签数据为样本数据,分别采用神经网络、随机森林、线性回归3种模型作为第二层混合模型进行模型训练与预测。

2.2.4 模型检验评估

在Stacking模型构建过程中,为了评价模型性能,确定最佳预测模型,采用后验标签数据实际值与模型预测值的均方根误差作为评价指标,均方根误差越小,说明模型的预测能力越强,准确性越高。分别统计计算基础模型与混合模型预测值与实际值的均方根误差,结果显示混合模型相较于基础模型的预测均方根误差明显降低(表2),能够有效提高模型的预测精度。

2.3 预测结果效果对比分析

基于堆叠泛化集成学习的储层预测方法是一种基于数据驱动的机器学习智能预测方法,同时,通过混合堆叠泛化集成学习相比单一机器学习模型能够更有效地提高模型的预测精度,结果更加忠实于数据本身;相较于地质统计学反演,该方法不追求极致的纵向分辨率,仅在提高一定纵向分辨率的基础上具有较强的横向“相控”指示能力,预测结果保持了储层空间结构特征,更加适用于相变快、内部结构复杂的陆相河流沉积体系储层预测与精细研究。地质统计学反演相比基于机器学习的储层预测具有更高的纵向分辨率,但其结果的模型痕迹较严重,复

合河道内部砂体叠置关系或储层内部相变区域被“粗化”,降低了地震作为井间预测的“相控”能力。如基于堆叠泛化集成学习的储层预测与地质统计学反演结果对比剖面(图3)所示,预测结果显示G4砂体发育2个辫流带。过井W1井和W2井剖面对比显示,常规稀疏脉冲反演方法的分辨率较低(图3a);地质统计学反演结果在纵向上拥有更高的分辨率(图3b),但模型化严重,不利于储层内部复杂结构关系预测与刻画;基于堆叠泛化集成学习的储层预测结果纵向分辨率介于前二者之间(图3c),相较于地质统计学反演,虽然牺牲一定的纵向分辨率,但横向“相控”指示作用更加突出,预测结果反映了W1井和W2井间发育2个辫流带之间的泛滥平原泥质沉积。过W1井在G4砂体测井解释为水层,水层顶深1380m,W2井G4砂体钻遇5.7m油层,油水界面1384m,分析认为辫流带间泛滥平原泥侧向遮挡形成2套独立油水系统,预测结果与动态认识相吻合。

3 基于堆叠泛化集成学习属性融合的四级构型单元精细刻画

储层构型是指不同级次储层构成单元的形态、规模、方向及其叠置关系^[15]。研究区馆陶组主要发育辫状河沉积,按照MIALL^[16-17]的划分方案,复合河道带为六级构型单元,单一辫流带为五级构型单元,心滩坝、辫状河道、废弃河道为四级构型单元,心滩内增生体及淤落层为三级构型单元。由于海上油田井网稀疏,地震资料纵向分辨率不足,因此,重点开展四级构型单元精细刻画。

以渤海湾盆地C-2油田馆陶组G3砂体为例,在基于堆叠泛化集成学习储层预测基础上,采用“沉积模式指导、地质规模约束、构型单元细分、井间地震趋势、水平井与动态资料后验”多信息融合迭代优化的储层构型精细表征思路,实现辫状河复杂内部结构精细表征。首先,完成研究区精细等时地层格架建立,通过精细划分与对比完成复合河道垂向分期。然后,以井点硬数据为中心,地质知识库规模为约束,利用构型单元细分辅助判断构型单元边界,井间则利用基于数据驱动的堆叠泛化集成学习储层预测结果作为井间趋势,分析井点沉积微相或构型单元。综合上述:多信息完成不同构型单元边界的平面侧向划界,再利用水平井丰富的横向信息和动态资料来验证与修正结果,进一步降低地下储层预测与结构认识的不确定性。

3.1 地质知识库约束

部分学者基于现代沉积和野外露头大量实测数据,总结了一系列构型单元规模的经验公式,可为储层构型

表2 机器学习模型误差评估对比

Table 2 Error evaluation comparison of machine learning models

模型层次	模型类别	模型名称	预测均方根误差	
基础模型	神经网络	多层感知机	5.91	
		FastAI网络	9.29	
		LightGBM	3.16	
	梯度提升决策树	XGBoost	3.76	
		CatBoost	7.52	
		随机决策树	随机森林	3.35
			极度随机树	3.13
	支持向量机		多项式核函数	8.77
			径向基函数	8.65
混合模型	神经网络	多层感知机	2.31	
	随机决策树	随机森林	2.17	
	多项式拟合	线性回归	2.89	

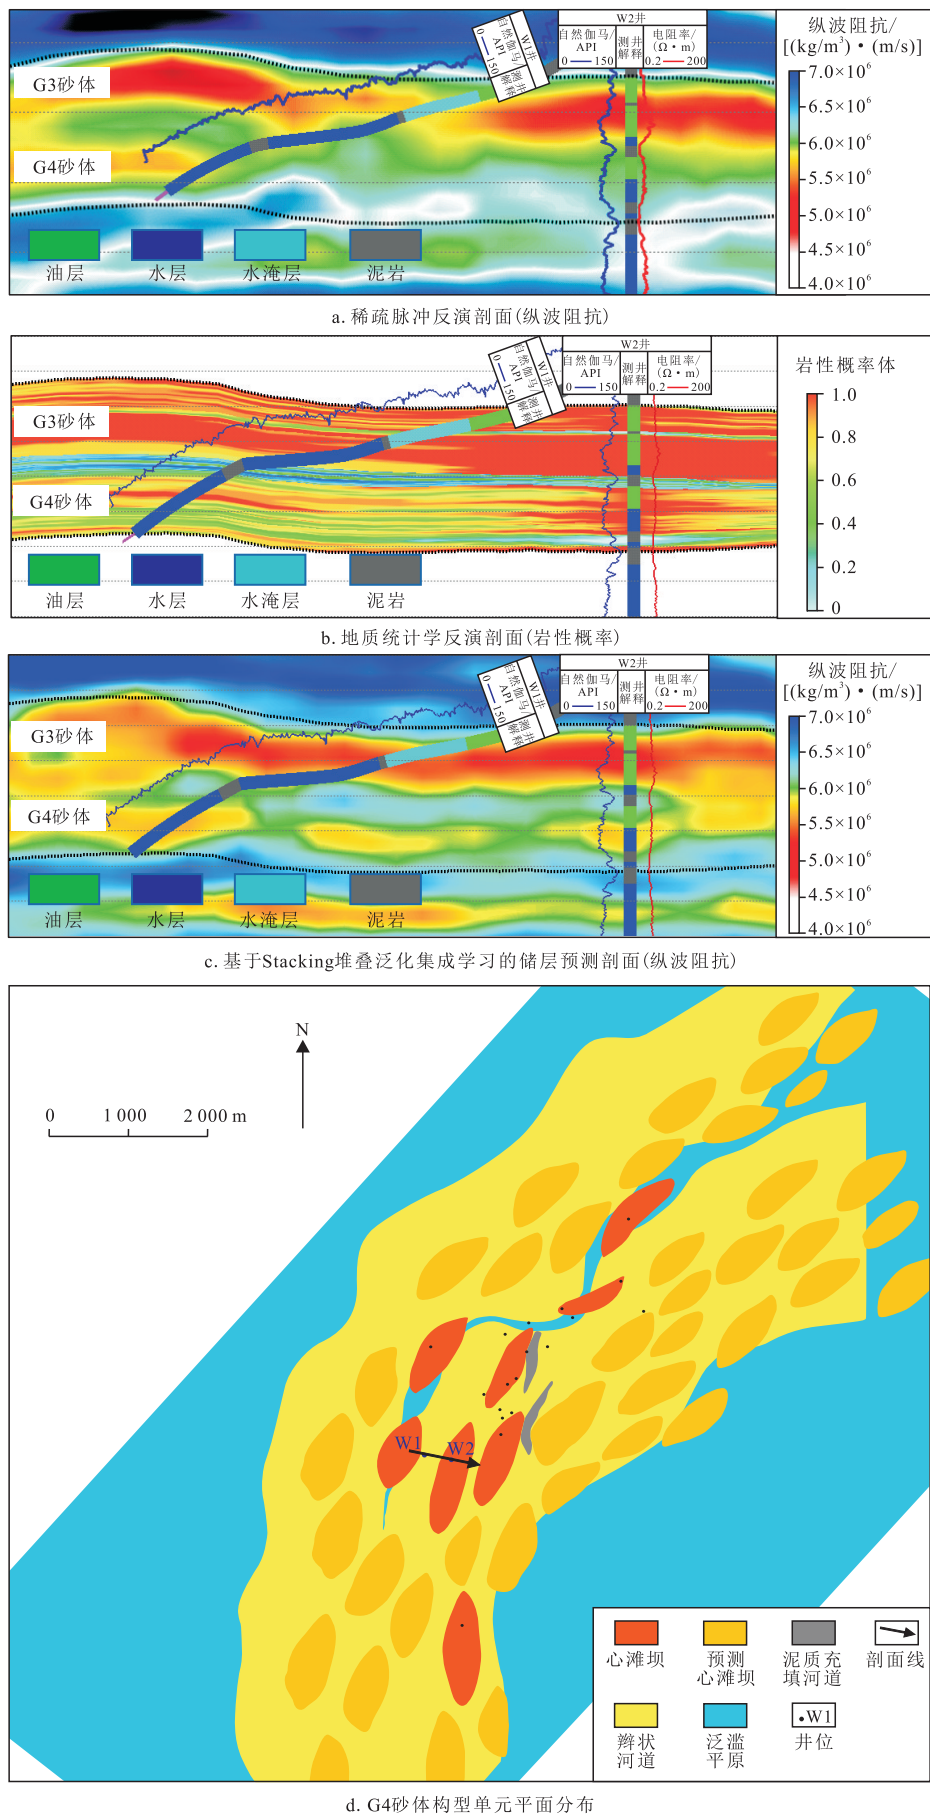


图3 基于堆叠泛化集成学习的储层预测与地质统计学反演结果对比剖面

Fig. 3 Comparison of cross-section profiles of reservoir prediction based on stacking ensemble learning and geostatistical inversion results

研究提供规模约束^[18]。在高分辨率层序地层学理论指导下,通过精细划分与对比完成复合河道垂向分期,研究区馆陶组G3砂体纵向发育2期复合河道砂体,在垂向分期基础上,开展单期次复合河道砂体内部结构侧向划界。在沉积模式指导下,分析井点沉积微相或构型单元类型,综合考虑砂体厚度、测井曲线形态等识别特征,以地质知识库规模为约束,辅助进行井点间的构型侧向划界。以井点为中心,向井周搜索扫描,相邻井钻遇心滩坝且井距小于地质知识库规模,则为同一心滩坝单元,超过地质知识库规模则为不同心滩坝单元。以主力砂体G3-1单砂体为例,其单期心滩坝砂体厚度介于6~10 m,压实校正得到河道满岸深度介于6.7~11.1 m,采用单河道满岸深度与心滩坝宽度、心滩坝宽度与心滩坝长度的式(1)、式(2)^[19],计算得到心滩坝宽度介于170~350 m,心滩坝长度介于700~1 400 m。

$$W_p = 11.413h_d^{1.4182} \quad (1)$$

$$L_p = 4.9517W_p^{0.9576} \quad (2)$$

式(1)一式(2)中: W_p 为心滩坝宽度,单位m; h_d 为河道满岸深度,单位m; L_p 为心滩坝长度,单位m。

在上述构型单元规模约束下对目的层不同级次构型单元进行侧向划界。如图4所示,A21井到A6井顺物源方向距离为450 m,砂体厚度、测井曲线特征相似,井距小于心滩坝长度规模,分析认为属于同一个心滩坝,以此类推,完成基于井点硬数据的构型单元划分。

3.2 构型单元细分

在储层构型研究中,测井曲线形态具有重要的指相意义,不同的测井曲线代表不同的沉积环境。但往往相邻的同一构型单元内部测井曲线也存在“钟形”“箱形”“钟形与箱形组合”等多种形态,由于受到水动力强弱、河床地貌等因素影响^[20],构型单元内部沉积动力微环境进一步分化,坝核向坝缘粒度减小,典型的箱型韵律一般发育在坝核,坝缘的曲线特征一般表现为下部箱型上部钟型组合特征。如图5所示,在馆陶组G3-1砂体中A21S1井与A2井均钻遇心滩坝坝核,两井之间A9井钻遇坝缘,说明A21S1井与A2井均钻遇的心滩坝分属2个不同的心滩坝。因此通过构型单元细分及细分构型单元的平面组合模式可以进一步辅助识别构型单元边界。

3.3 地震井间趋势控制

上述基于井点硬数据的构型单元识别与划分是相对确定性的,可以作为构型单元结构的基础框架,而井间构型单元的边界是影响储层精细刻画与油藏流体渗流的关键,因此,采用由粗到细、由确定到不确定的“层次分析,

模式拟合”的思路,利用基于地震属性堆叠泛化集成学习的储层预测结果作为井间趋势控制,结合古水流方向,采用“以井点为中心、砂体厚度定位、不连续界面定边、构型规模约束”的原则识别与圈定心滩坝。在前述井点构型识别与划分框架基础上,利用心滩坝相对于辫状河道或废弃河道厚度大、平面砂厚图呈透镜状等特征将心滩坝与辫状河道或废弃河道区分开来,并通过平面地层切片与地震预测剖面平剖结合识别不连续界面,在构型单元定量规模约束下,融合上述多信息迭代优化完成辫状河构型单元侧向划界(图6)。

4 水平井与动态资料验证与优化

研究区为主要采用水平井网开发的海上油田,为充分发挥水平井丰富的横向信息优势,利用水平井探边资料或相邻过路井标定水平井测井相^[21-22],总结不同构型单元水平段测井响应特征,因此,利用水平井测井响应与沿井地震响应特征进一步验证与优化构型单元界面,结合动态资料,明确储层内部横向构型单元空间展布特征,提高储层构型预测的可靠性。A18H井水平段末端基于堆叠泛化集成学习属性融合的储层预测纵波阻抗剖面上为不连续的泥质高阻特征,测井响应特征显示钻遇泥质充填废弃河道(图7)。A18H井2004年投产,生产动态资料显示生产效果较好,含水缓慢上升,累产油 42×10^4 t,为该砂体单井累产油量最高的油井,分析认为泥质充填河道侧向遮挡一定程度抑制了边水或次生边水锥进速度。因此,基于堆叠泛化集成学习属性融合的储层预测与水平井资料、生产动态分析结果吻合性较好,提高了储层预测与构型表征的可靠性。

5 结论与认识

1) 将基于堆叠泛化集成学习地震属性融合的方法应用于渤海湾盆地C-2油田储层预测中,预测结果表明堆叠泛化集成学习算法结合了多种机器学习模型的优势,相较于单一的机器学习模型预测误差明显降低,能够有效提高模型的预测精度。

2) 基于数据驱动的机器学习储层预测结果更加忠实于数据本身,在提高一定的纵向分辨率的基础上,同时具备更高的横向“相控”指示能力,预测结果保持了储层空间结构特征,更加适用于相变快、内部结构复杂的陆相河流沉积体系储层预测,有利于井震结合开展复合河道砂体叠置关系分析与储层内部结构精细解剖。

3) 受限于地震资料分辨率、预测结果的多解性、稀疏井网条件等多重影响因素,储层预测结果仍存在较大




图4 基于地质知识库约束的连井构型单元对比剖面 Fig. 4 Comparison of cross-section profiles of connected well architectural units based on geological knowledge base constraints




图5 基于构型单元细分的连井构型单元对比剖面 Fig. 5 Comparison of cross-section profiles of connected well architectural units based on subdivision of architectural units

的不确定性,因此,在基于地震属性堆叠泛化集成学习的储层预测基础上,建立了基于“沉积模式指导、地质规模约束、构型单元细分、井间地震趋势、水平井与动态资料后验”多信息融合迭代优化的储层构型精细表征思路,实

现了辫状河复杂内部结构精细表征,动静态结果显示进一步降低了稀疏井网条件下地下储层预测与结构认识的不确定性,对稀疏井网海上油田开发中后期河流相沉积储层构型精细表征具有一定借鉴意义。

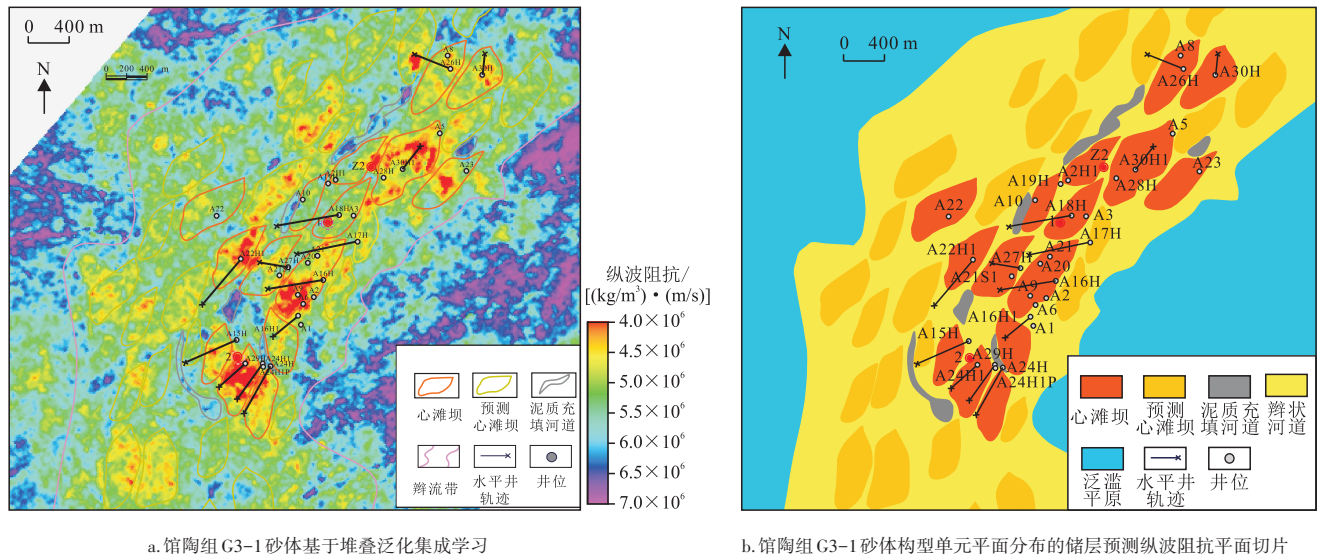


图6 C-2油田馆陶组G3-1砂体基于堆叠泛化集成学习属性融合的四级构型单元平面刻画

Fig. 6 Planar characterization of four-level architectural units of the G3-1 sandbody in the Guantao Formation of the C-2 oilfield based on stacking ensemble learning

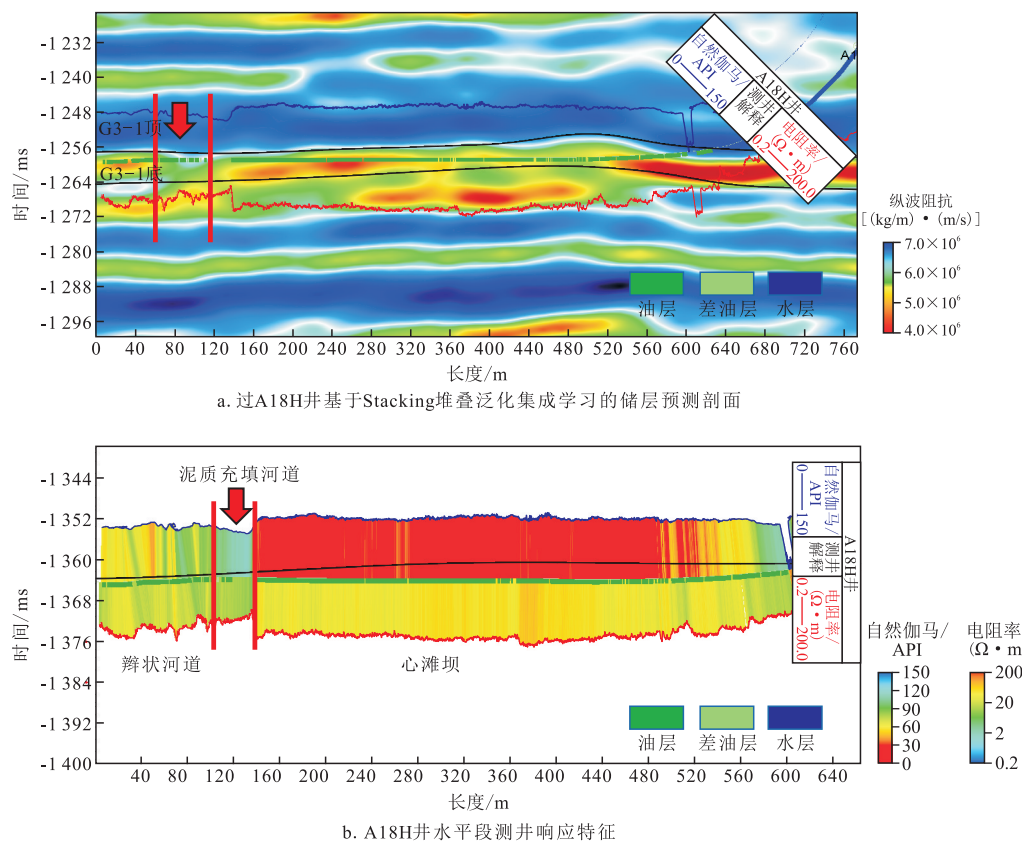


图7 利用水平井、动态资料验证与优化构型单元平面展布

Fig. 7 Planar distribution of the architecture units using horizontal wells, dynamic data validation and optimization

参考文献

- [1] 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.
- [2] 赵鹏飞,刘财,冯晖,等.基于神经网络的随机地震反演方法[J].地球物理学报,2019,62(3):1172-1180.
ZHAO Pengfei, LIU Cai, FENG Xuan, et al. Stochastic seismic inversion based on neural network[J]. Chinese Journal of Geophysics, 2019, 62(3): 1172-1180.
- [3] 程冰洁,徐天吉,罗诗艺,等.基于机器学习的深层页岩有利储集层预测方法及实践[J].石油勘探与开发,2022,49(5):1-11.
CHENG Bingjie, XU Tianji, LUO Shiyi, et al. Method and practice of deep favorable shale reservoir prediction based on machine learning [J]. Petroleum Exploration and Development, 2022, 49(5): 1-11.
- [4] 安鹏,曹丹平,赵宝银,等.基于LSTM循环神经网络的储层物性参数预测方法研究[J].地球物理学进展,2019,34(5):1849-1858.
AN Peng, CAO Danping, ZHAO Baoyin, et al. Reservoir physical parameters prediction based on LSTM recurrent neural network[J]. Progress in Geophysics, 2019, 34(5): 1849-1858.
- [5] 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.
- [6] LI W, YUE D L, WANG W F, 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.
- [7] 张宇航,时保宏,张曰静,等.机器学习方法在浅层滩坝相薄储层孔隙度预测中的应用:以准噶尔盆地车排子地区白垩系为例[J].沉积学报,2023,41(5):1559-1567.
ZHANG Yuhang, SHI Baohong, ZHANG Yuejing, et al. Application of Machine Learning for Porosity Estimation of Beach and Bar Sand Bodies in a Lacustrine Basin: A case study of the Lower Cretaceous strata in Chepaizi area, Junggar Basin, NW China[J]. Acta Sedimentologica Sinica, 2023, 41(5): 1559-1567.
- [8] 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(Suppl. 2): 140-145.
- [9] 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.
- [10] 史长林,魏莉,张剑,等.基于机器学习的储层预测方法[J].油气地质与采收率,2022,29(1):90-97.
SHI Changlin, WEI Li, ZHANG Jian, et al. Reservoir prediction method based on machine learning[J]. Petroleum Geology and Recovery Efficiency, 2022, 29(1): 90-97.
- [11] YANG R X, SUN C Y, XU L. Prediction of photovoltaic power generation based on stacking model fusion[J]. Computer System Application, 2020, 29(5): 36-45.
- [12] 曹志民,丁璐,韩建.基于Stacking集成学习的声波时差测井曲线复原研究[J].化工自动化及仪表,2024,51(3):470-476.
CAO Zhimin, DING Lu, HAN Jian. Research on acoustic moveout logging curves restoration based on stacking ensemble learning[J]. Control and Instruments in Chemical Industry, 2024, 51(3): 470-476.
- [13] WOLPERT D H. Stacked generalization[J]. Neural Networks, 1992, 5(2): 241-259.
- [14] 钱玉贵.机器学习技术在致密砂岩储层预测中的应用:以川西坳陷新场须家河组为例[J].油气藏评价与开发,2023,13(5):600-607.
QIAN Yugui. Application of machine deep learning technology in tight sandstones reservoir prediction: A case study of Xujiahe Formation in Xinchang, western Sichuan Depression[J]. Petroleum Reservoir Evaluation and Development, 2023, 13(5): 600-607.
- [15] 吴胜和,岳大力,刘建民,等.地下古河道储层构型的层次建模研究[J].中国科学(地球科学),2008,38(增刊1):111-121.
WU Shenghe, YUE Dali, LIU Jianmin, et al. Hierarchy modeling of subsurface palaeochannel reservoir architecture[J]. Scientia Sinica (Terrae): Earth Sciences, 2008, 38(Suppl. 1): 111-121.
- [16] MIALL A D. Architectural-element analysis: A new method of facies analysis applied to fluvial deposits[J]. Earth-Science Reviews, 1985, 22(4): 261-308.
- [17] MIALL A D. The geology of fluvial deposits: sedimentary facies, basin analysis and petroleum geology[M]. Berlin: Springer, 1996.
- [18] 侯东梅,赵秀娟,汪巍,等.地下曲流河点坝砂体规模定量表征研究[J].油气藏评价与开发,2018,8(3):7-11.
HOU Dongmei, ZHAO Xiujuan, WANG Wei, et al. Quantitative characterization research for point bar sand body of subsurface meandering river environment: Taking Minghua Formation of Bohai C Oilfield as an Instance[J]. Petroleum Reservoir Evaluation and Development, 2018, 8(3): 7-11.
- [19] KELLY S. Scaling and hierarchy in braided rivers and their deposits: Examples and implications for reservoir modeling[M]. UK: Blackwell Publishing, 2006.
- [20] 陈薪凯,刘景彦,陈程,等.主要构型要素细分下的曲流河单砂体识别[J].沉积学报,2019,38(1):205-217.
CHEN Xinkai, LIU Jingyan, CHEN Cheng, et al. The identification of single sand body in meandering river deposits based on the subdivision of main architecture[J]. Acta Sedimentologica Sinica, 2019, 38(1): 205-217.
- [21] 徐中波,汪利兵,申春生,等.渤海蓬莱19-3油田新近系明下段曲流河储层构型表征[J].岩性油气藏,2023,35(5):100-107.
XU Zhongbo, WANG Libing, SHEN Chunsheng, et al. Architecture characterization of meandering river reservoirs of lower Minghuazhen Formation of Neogene in Penglai 19-3 oilfield, Bohai Sea[J]. Lithologic Reservoirs, 2023, 35(5): 100-107.
- [22] 权勃,侯东梅,牟松茹,等.基于水平井信息的辫状河储层构型单元空间展布研究[J].中国海上油气,2020,32(4):96-103.
QUAN Bo, HOU Dongmei, MOU Songru, et al. Study on configuration unit spatial distribution of braided river reservoirs based on horizontal well information[J]. China Offshore Oil and Gas, 2020, 32(4): 96-103.

(编辑 余聪)