

基于小波变换的卷积神经网络岩相预测*

黄勇波, 韩长城[†], 魏亚涛, 周彦旭, 蒋鑫, 李佳璇, 张裕奇

(新疆大学 地质与矿业工程学院 新疆中亚造山带大陆动力学与成矿预测自治区重点实验室, 新疆 乌鲁木齐 830017)

摘要: 岩相分析是寻找优质储层的基础, 但对于无井区域或受限于井间复杂的地质条件, 传统技术难以快速、准确识别岩相类型及其空间展布. 故通过深度学习实现对岩相的高效识别, 提出一种加入连续小波变换(CWT)的卷积神经网络(CNN)岩相识别方法. 将该方法应用于准噶尔盆地征沙村地区克拉玛依组, 主要步骤包括: 依据岩心和测井特征划分典型岩相, 基于合成记录的井震匹配对测井岩相与叠后地震资料进行匹配, 利用Morlet小波变换将匹配的地震波转化为时频谱图, 生成不同岩相的时频谱图数据集, 并构建CNN模型进行训练、测试与验证. 在层位约束条件下, 研究不同岩相的平面展布. 结果表明: Morlet小波结合CNN的模型可实现较高识别精度, X2盲井的4种岩相识别率均超过85%, 显著提升了岩相识别的效率和精度.

关键词: 岩相预测; 卷积神经网络; 连续小波变换; 叠后地震资料; 时频谱图; 克拉玛依组

DOI: 10.13568/j.cnki.651094.651316.2024.12.13.0001

中图分类号: TU521.3 **文献标识码:** A **文章编号:** 2096-7675(2025)03-0300-012

引文格式: 黄勇波, 韩长城, 魏亚涛, 周彦旭, 蒋鑫, 李佳璇, 张裕奇. 基于小波变换的卷积神经网络岩相预测[J]. 新疆大学学报(自然科学版中英文), 2025, 42(3): 300-311.

英文引文格式: HUANG Yongbo, HAN Changcheng, WEI Yatao, ZHOU Yanxu, JIANG Xin, LI Jiaxuan, ZHANG Yuqi. Lithofacies prediction based on wavelet transform and convolutional neural networks[J]. Journal of Xinjiang University(Natural Science Edition in Chinese and English), 2025, 42(3): 300-311.

Lithofacies Prediction Based on Wavelet Transform and Convolutional Neural Networks

HUANG Yongbo, HAN Changcheng, WEI Yatao, ZHOU Yanxu,
JIANG Xin, LI Jiaxuan, ZHANG Yuqi

(Xinjiang Key Laboratory of Geodynamic Processes and Metallogenic Prognosis of the Central Asian Orogenic Belt,
School of Geology and Mining Engineering, Xinjiang University, Urumqi Xinjiang 830017, China)

Abstract: Lithofacies analysis serves as the foundation for identifying high-quality reservoirs. However, in areas devoid of well data or constrained by complex inter-well geological conditions, traditional techniques struggle to rapidly and accurately recognize lithofacies types and their spatial distribution. This paper proposes a convolutional neural network(CNN)-based lithofacies identification method integrated with continuous wavelet transform(CWT), achieving efficient lithofacies recognition through deep learning. Applied to the Karamay formation in the Zhengshacun area of the Junggar Basin, the methodology involves: classifying typical lithofacies based on core and logging characteristics, performing synthetic record-based well-to-seismic matching to align logging lithofacies with post-stack seismic data, converting the matched seismic waveforms into time-frequency spectrum maps using Morlet wavelet transform, generating a time-frequency spectrum dataset for different lithofacies, and constructing and training a CNN model for validation. Under horizon constraints, the planar distribution of various lithofacies is investigated. Results demonstrate that the Morlet-CNN model achieves high identification accuracy, with recognition rates exceeding 85% for 4 lithofacies types in blind well X2, significantly enhancing both the efficiency and accuracy of lithofacies identification.

Key words: lithofacies prediction; convolutional neural network; continuous wavelet transform; post-stack seismic data; time-frequency spectrogram; Karamay formation

* 收稿日期: 2024-12-13

基金项目: 新疆维吾尔自治区天山英才计划“准噶尔盆地西北缘油-铀同盆共生体系及铀矿富集机制研究”(2023TSYCCX0009).

作者简介: 黄勇波(2000—), 男, 硕士生, 从事地质资源与地质工程的研究, E-mail: 2630059912@qq.com.

† 通讯作者: 韩长城(1984—), 男, 博士, 教授, 主要从事石油地质的研究, E-mail: hanchangchen@126.com.

0 引言

岩相分析是地层对比、沉积环境分析及油气藏特征描绘过程中不可或缺的关键环节. 然而, 由于井数据在地理空间上的局限性, 其所能提供的岩相信息极为有限, 尤其是针对无井覆盖区域, 准确预测岩相成为研究的重点、难点. 在此背景下, 地震数据作为岩相预测的重要工具, 其重要性不言而喻. 然而, 地震数据与岩相之间复杂的非线性关系, 使得直接通过地震数据准确识别岩相成为一项极具挑战的任务.

近年来, 机器学习技术的快速发展为岩相预测提供了新的思路, 其通过知识与数据融合驱动, 利用人工智能技术, 实现对岩相的高精度、高效率识别^[1]. 机器学习不仅能够深入挖掘并理解地震数据与岩相之间的潜在关系, 还能基于有限的训练样本, 实现岩相类型的准确预测. 岩相类型的识别对于判断储层质量和寻找优质储层位置至关重要^[2-6], 提高岩相预测结果的分辨率和准确性一直是寻找油气藏储层的一个关键问题. 识别和分类岩石中岩相的传统方法是基于光学显微镜或更先进的扫描电子显微镜下的薄片鉴定^[7-8]. 尽管这些传统方法是定量和直接的, 但耗时较长, 且很难获得研究区所有的岩心样品. 此外, 这些结果在很大程度上取决于研究者的经验^[9]. 测井包含地层条件下储层矿物成分、孔隙度、渗透率、流体饱和度等重要信息, 交会图法或多元统计^[10]是利用这些信息低成本识别岩相的其他方法, 其需要开展全面统计分析, 工作量较大. 2017年以来, 基于深度学习的的海震数据解释逐渐成为学术界的重要研究方向, 涵盖构造解释^[11-12]、地震相分析^[13-15]、测井相分类^[16-17]和储层预测^[18]等领域. 卷积神经网络是一种功能强大的图像处理技术, 与其他方法相比, 其提供了更高的精度和更少的时耗, 该方法已广泛用于地质野外制图^[19]、地表环境识别^[20]以及地震图像分类和检测^[21]. 频谱分解技术可以将地质体从时间域转为频率域, 从而更好地确定储层形态特征^[22]. 刘俊等^[23-24]采用频谱分解方法得到离散能量体, 通过对分频剖面与属性进行分析来预测储层“甜点”, 为储层预测提供了新的思路. 小波变换是一种具有多分辨功能的时频分析方法, 在石油勘探、岩相图像处理等领域均有广泛应用^[25-29]. 何田素等^[30]利用基于小波变换的神经网络对岩心图像进行去噪研究, 该方法相较于其他去噪方法, 取得了更好的去噪效果, 且使得岩心图像的视觉效果更清晰. 赵金泉等^[31]提出了一种基于连续小波变换 (Continuous Wavelet Transform, CWT) 的卷积神经网络 (Convolutional Neural Network, CNN) 地震噪声压制方法, 数值实验表明该方法比常规滤波方法具有更好的噪声压制效果, 验证了CWT与CNN结合的可行性. 本文采用一种新的岩相类型直接预测方法, 将CWT与CNN充分结合, 通过CWT将一维地震波信息变换为信息更丰富的二维时频谱图, 通过CNN的独特结构提取图像特征. 结合两者的优势, 实现地下岩相类型的高效、精准识别, 为后续确定沉积相边界、储层质量评价及勘探目标优选等关键环节提供了技术支撑.

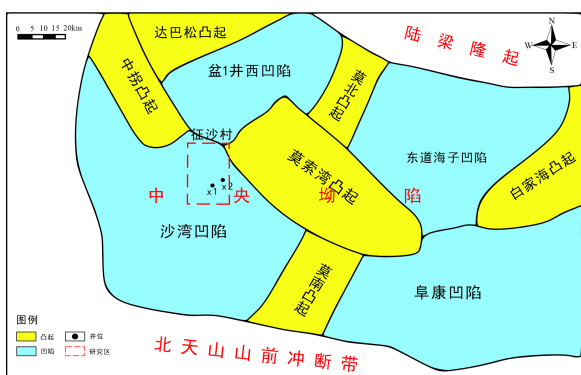


图 1 准噶尔盆地中沙村地区构造位置



图 2 研究区中生界主要地层综合柱状图

1 地质概况

选取准噶尔盆地中部约200 km²叠后地震覆盖区作为研究区, 如图1所示. 构造位置处于莫索湾凸起和中拐凸起的接合部, 北侧毗邻盆1井西凹陷, 南部为沙湾凹陷^[32-33], 为断裂切割的低幅度鼻状构造. 图2为研究区侏罗系与三叠系地层概况, 中生界地层自下而上分别为二叠系下乌尔禾组 and 上乌尔禾组, 三叠系百口泉组、克拉玛依组和白碱滩组, 侏罗系八道湾组和三工河组, 其中: 下乌尔禾组发育厚度大于200 m的烃源岩^[34-35], 生烃强度大, 是烃源岩发育层系; 克拉玛依组作为其上覆地层, 具备优越的油源条件, 且自身发育大规模砂体, 厚

度横向变化较为稳定,纵向呈现储-盖组合分布格局,展现出超深层良好的勘探潜力. 本文将克拉玛依组作为目的层进行岩相研究. 研究区钻遇目的层埋藏深(6 000 m以下)且钻遇井少,超深层井控低,地震资料分辨率低. 基于模型的反演受井控程度影响较大,随机性强,无法准确识别岩相类型、划分岩相边界.

2 岩相发育特征

克拉玛依组岩性多样,主要由泥岩、粉砂岩、细砂岩和砾岩组成. 这些岩性分布与古气候和古水文条件密切相关,揭示了区域古环境的演变,反映了不同沉积环境下的物理化学性质. 岩相类型划分方面,为更好明确研究区及周边地区的沉积环境与沉积微相边界,本文与传统岩相类型划分有所不同,不依据单一岩性划分岩相,而是按照岩相组合的形式将克拉玛依组分为4种岩相类型:含砂泥岩相、砂泥互层岩相、细粒含泥砂岩相和中细粒含砂砾岩相. 这些岩相的变化可反映水流动力、沉积环境及物质来源的差异. 上部沉积为湖相环境,主要发育含砂泥岩相和砂泥互层岩相. 湖相沉积的特点是较平缓的水流和低能量条件,故细粒物质沉积占主导,时频谱图显示低频信息为主,沉积物均匀、粒度细且沉积环境稳定. 下部沉积为辫状河三角洲环境,主要由细粒含泥砂岩相和中细粒含砂砾岩相组成,反映出较强水流和高能量条件. 辫状河三角洲的时频谱图则呈现低频能量较高且高频信息丰富的特点,沉积物粒度较粗且空间分布复杂,水流的变动促使颗粒交替沉积形成层理结构. 高频信息与较粗的沉积物(如砂岩和砾岩)及不均匀的沉积过程密切相关,揭示了该区域水动力强烈的沉积环境特征,如图3所示.

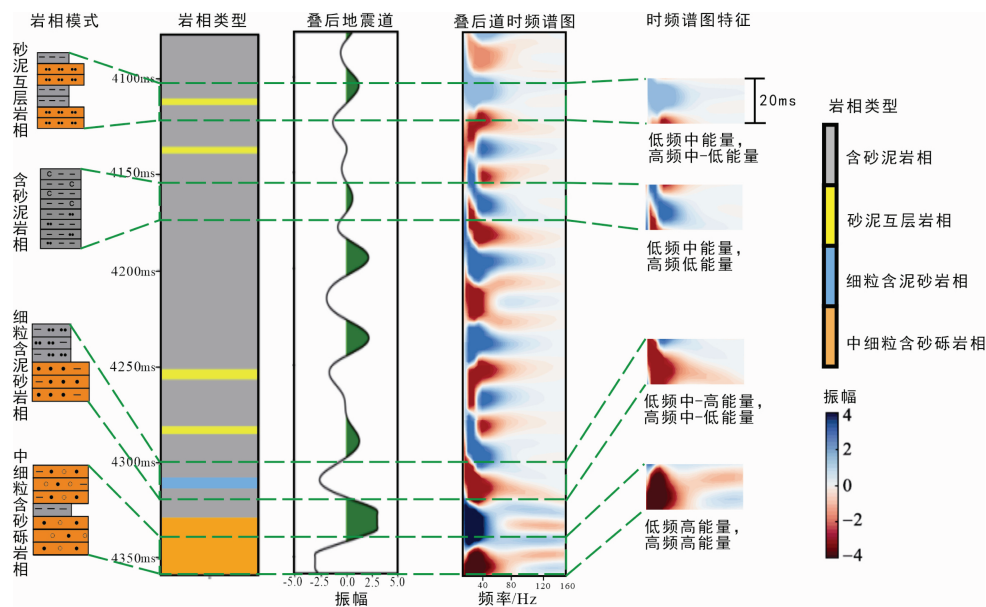


图3 研究区岩相频谱特征图

3 深度学习岩相预测模型搭建

构建深度学习岩相预测模型过程中,数据的准备与预处理是基础性工作,而深度学习反演框架是决定模型性能的关键因素.

3.1 数据预处理

3.1.1 井震数据匹配

由于测井数据通常以深度为表现形式,而地震数据则为时间域形式,通过建立时间-深度关系,将深度域的测井数据转换为时间域形式,可以确保测井数据与地震数据的匹配. 这种转换可以消除两者之间的误差,最大程度保证数据的匹配性. 为进一步减少测井数据与地震数据的分辨率偏差,采用重采样技术统一采样率至1 ms. 通过这种方式,测井数据的分辨率得到提升,避免了因采样率不同带来的数据不一致问题. 重采样不仅提高数据的分辨率,还可通过插值方法保证数据的连续性,增强了数据的可靠性. 这一处理步骤为后续深度学习模型,尤其是神经网络提取岩相特征提供了高质量的数据基础. X2为验证机器学习模型预测准确性的盲井,图4展示了X2盲井在完成时深对齐和重采样处理后的测井数据与地震数据.

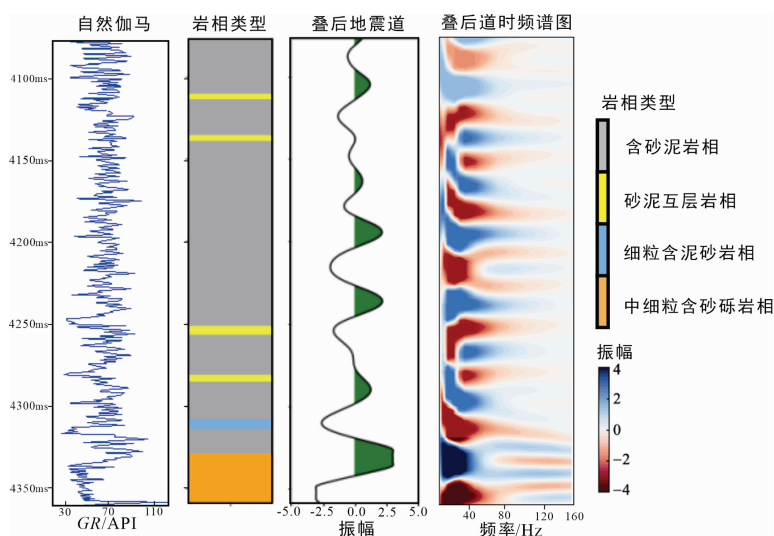


图 4 X2盲井井震匹配模式图

3.1.2 时频谱图转换

频谱分解技术能够将复杂的地震信号分解为不同频率成分组合而成的时频谱图, 该方法已在地震反演中得到广泛应用. 因为地震信号中的高频成分对地下薄层反射特征变化敏感^[36], 故基于频谱分析的岩相类型预测在地震资料处理中具有显著优势, 尤其在识别厚度较小的岩相类型时表现突出^[37]. 所预测的岩相类型粒度越粗、厚度越大, 频谱图中高频能量值越高, 反之亦然. 使用频谱分解后的时频谱图作为CNN输入, 有助于从数据中进行特征提取. 声波通常被转换为时频谱以用于卷积运算, 进行特征提取^[38]. 本文采用Morlet连续小波变换进行频谱分解^[39]. Morlet小波在地震信号分析中通过频谱分解, 提供含有时间和频率信息的高分辨率时频谱图, 其频率与时间分辨率互为制约, 较高频率信息提供更好的时间分辨率, 低频率信息则用于提升频率分辨率. 通过调整尺度, 小波变换能在不同时频尺度上精细分析信号, 揭示信号的能量分布与瞬时频率变化. 与傅里叶变换相比, 小波变换更适用于分析非平稳信号, 为地震预测与地质勘探提供精准分析工具. 图4展示了X2盲井旁叠后地震道经过小波变换频谱分解后的时频谱图.

3.1.3 滑动时窗采样

构建深度学习模型的训练数据集时, 首先将测井数据与井旁地震波形及其时频谱数据在时深和采样率上进行精确匹配. 图5展示了两种采样方法: “点-点” 对应与 “点-窗” 匹配. 由于测井数据中每个时间深度点与其在特定时间窗口内的邻近数据点存在关联, 故通过 “点-窗” 匹配采样策略, 结合合理的采样时间步长、时间窗口大小和时频谱图频率范围, 有效优化地震数据与测井数据的配准精度, 可提升CNN模型的训练效果^[18]. 该策略通过可重叠滑动时窗对地震数据进行分段采样, 捕捉细微变化, 避免传统固定步长方法的不足, 从而增强时频谱图的细节表现力. 此外, 合理设置时频范围去除噪声, 可使时频分析更贴近实际数据特征. 如图5所示, 将该步骤生成的时频谱图作为神经网络输入, 能提取时变特性和频率成分, 帮助网络自动学习局部特征并融合全局信息, 实现高效模式识别与预测.

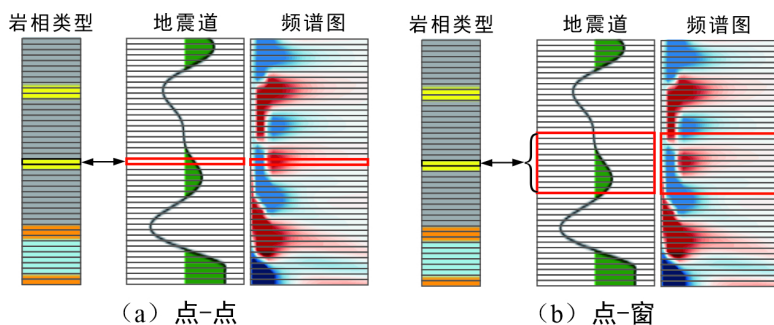


图 5 采样方法模式图

3.2 CNN

CNN在地震反演中逐渐成为主流方法,其通过自动提取地震数据中的空间和时间特征,减少对人工设计特征的依赖. CNN由输入层、隐含层和输出层组成,隐含层通常包含卷积层和池化层,能够提取局部特征并降低维度. 激活函数(如ReLU)增强了网络的非线性表达能力. 最终, CNN将处理后的特征映射转化为地下介质的物理属性或结构预测,可显著提高地震反演的精度和效率,尤其适用于复杂非线性问题的处理. 网络表示如下:

$$y = f(Wx + b), \quad (1)$$

式中: x 为输入特征向量; W 和 b 分别为权重矩阵和偏置向量; f 为激活函数; y 为网络的输出.

CNN与传统神经网络的不同之处在于引入了卷积层,其在网络中扮演关键角色,负责从输入数据中提取特征. 卷积层特别适用于处理具有空间层次结构和局部相关性的数据,如地震图像或波形记录. 经卷积层使用滤波器进行特征提取的输出结果被称为特征图,即:

$$Q_j = f\left(\sum_{i=1}^I O_i * w_{i,j}\right), \quad j = 1, 2, \dots, N, \quad (2)$$

式中: O_i 表示第 i 个输入图; I 表示输入图层数; Q_j 表示第 j 个特征图; N 表示滤波器数量; $w_{i,j}$ 表示滤波器. 通过权重矩阵连接 O_i 和 Q_j ,滤波器在卷积操作中对输入图进行加权求和,生成特征图. 权重矩阵在CNN中发挥映射与连接作用,提取有效特征以提升模型性能. 滤波器按照预定的步长在输入图 O_i 上滑动并执行卷积操作,从而生成一组特征图 Q_j . I 、 j 作为索引或标识符,可根据具体任务需求进行指定. 卷积层内配置的滤波器数量直接决定最终生成的特征图数量,这一过程体现了特征提取的核心机制. 特征提取可视为对输入图实施的一种变换操作,旨在强化并凸显输入图中特定的、对于后续处理或分类任务至关重要的特征. 不同的滤波器通过不同的权重配置,能够从输入图中捕捉多样化的特征模式. 理论上,增加滤波器的数量能够提升模型捕捉复杂特征的能力,从而可能提高模型的性能. 然而,滤波器数量的无限制增长也会带来显著的负面影响,包括增加模型计算复杂度、内存占用以及训练过程中的过拟合风险,进而加重模型的训练负担. 实际应用中,由于输入图本身蕴含的有效特征数量有限,故需要通过实验确定一个最优的滤波器数量.

激活函数使用ReLU函数^[40]:

$$f(x) = \max(0, x). \quad (3)$$

该激活函数可有效缓解梯度消失问题,从而提高模型的训练效率和稳定性. 本文的岩相类型预测任务为多分类问题. 针对这种多分类任务,输出层常采用Softmax函数. Softmax函数能够生成归一化的概率分布,并通过选择该分布中概率值最大的类别作为最终分类结果,实现岩相类型的准确预测与输出. Softmax函数如下所示:

$$s_j^L = w_j^L y^{L-1}, \quad j = 1, 2, \dots, M, \quad (4)$$

$$y_j^L = \frac{e^{s_j^L}}{\sum_{m=1}^M e^{s_m^L}}, \quad j = 1, 2, \dots, M, \quad (5)$$

式中: y_j^L 表示模型输出的第 j 类后验概率; s_j^L 表示输入向量 L 的第 j 个元素; M 为类别总数.

多分类问题的训练过程可采用交叉熵函数作为损失函数^[41],即:

$$\min_{W,b} \varepsilon(g, y^L) = - \sum_{j=1}^M g_j \lg(y_j^L), \quad (6)$$

式中: ε 为损失函数; g 为真实标签; y^L 为Softmax函数输出的后验概率. 训练过程中,采用随机梯度下降(Stochastic Gradient Descent, SGD)算法最小化目标损失函数. 通过明确定义的损失函数与SGD的协同作用,可有效调整和优化神经网络中的权重与偏差,进而提升模型的性能与泛化能力. 这一过程是深度学习中权重学习与偏差调整的核心机制,对于实现网络参数的精确调整与高效学习至关重要. 训练更新方式如下:

$$(W, b) \leftarrow (W, b) - \eta \frac{\partial \varepsilon}{\partial (W, b)}, \quad (7)$$

式中: W 为模型学习的权重; b 为模型学习的偏差; η 为学习率. SGD优化神经网络的过程中, 权重与偏差的更新是基于每个单独样本或一小批量样本的误差计算来执行的. 小批量训练策略在每次迭代中利用多个样本的误差信息指导权重与偏差的更新, 相较于单样本更新, 此方法能够增强稳定性, 有助于减少训练过程中的波动, 使得学习过程更为平稳与高效. 使用SGD时, 学习率会随训练过程的进行而调整, 从而提高训练的稳定性 and 效率. Dropout技术通过在训练过程中随机丢弃一部分神经元, 防止神经网络过度依赖特定神经元, 增强模型的泛化能力, 避免过拟合^[42]. 前向传播时, 被丢弃的神经元输出为0; 反向传播时, 仅更新剩余神经元的梯度. 测试阶段, 所有神经元均参与计算, 但输出被适当缩放以补偿丢弃过程. Dropout通过增加模型的鲁棒性和泛化能力, 广泛应用于深度神经网络中, 尤其是在处理复杂数据集时表现突出.

3.3 深度学习反演框架

图6展示了基于CNN和CWT的地震反演模型框架, 旨在利用时频谱图进行特征提取与分类. 首先, 通过CWT对地震数据进行时频分析, 生成时频谱图, 提取具有地质特征的时频信息. 然后, 将这些时频图像输入CNN进行特征学习. CNN设置64个卷积核提取多尺度特征, 并通过全连接层进行分类决策. 为防止过拟合, 采用ReLU激活函数和Dropout技术增强网络的非线性拟合能力和泛化能力. 训练过程中使用SGD, 结合小批量训练和自动调整学习率, 提高模型收敛的稳定性. 交叉熵损失函数用于评估分类误差, Softmax函数输出类别概率分布. 该模型在TensorFlow框架下实现, 利用了该框架高效的计算能力提升训练效率. 数据预处理和分析采用Python 3.6及相关工具包(如Scikit-learn、Obspy等). Scikit-learn用于特征选择与评估, Obspy则用于地震数据的处理和读取. 该模型为地震反演提供了一种新的技术方案, 具有广泛的应用前景.

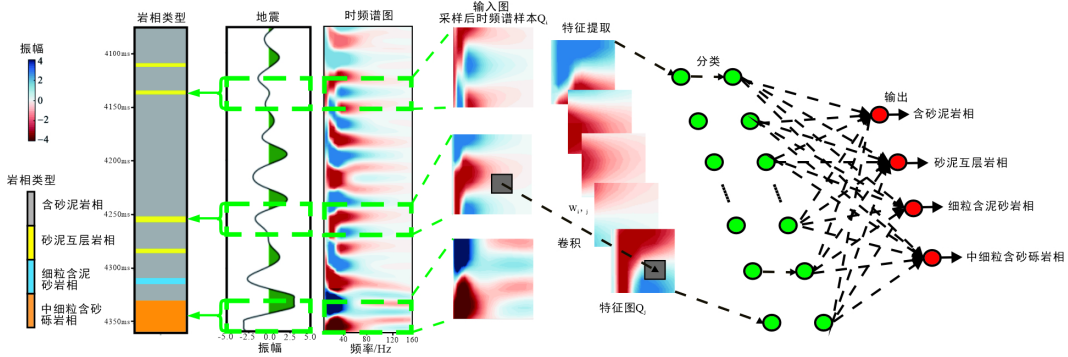


图 6 基于CNN和CWT的深度学习模型架构




图 7 基于深度学习的岩相预测策略模式图

4 岩相类型预测应用

4.1 深度学习预测岩相类型思路

深度学习岩相预测方法能够从数据中自动学习岩相预测模式, 省去传统岩石物理分析等繁琐步骤. 制定以

下岩相预测思路:以叠后地震数据和测井岩相为训练数据,建立叠后深度学习地震反演模型,预测岩相展布,进而在测井解释岩性结果的约束下,预测不同岩相类型,如图7所示。

叠后深度学习反演岩相类型分为两步:1)建立样本数据集,对研究区内的2口井提取样本并进行连续小波变换、滑动时窗采样,共形成339个时频谱图样本数据集。如图8所示,研究区目的层地震信号主频为22 Hz,主要频率分布范围为10~50 Hz。2)为充分保留高频段可能蕴含的高能量岩相信息,在时频谱分析中,将输入频率范围扩展至10~160 Hz。由于所划分岩相类型厚度在时间域的范围为5~20 ms,因此将采样窗口设置为20 ms。




图8 克拉玛依组地震资料频率范围

数据集通常分为训练集、验证集和测试集,分别用于模型训练、调优和评估。X2作为测试盲井,其数据单独提取用于性能评估,避免模型在训练阶段接触到该数据。为有效评估模型的性能和鲁棒性,训练集和验证集按7:3比例随机分配,确保数据分布均衡、减少偏差。经统计,砂泥互层岩相、细粒含泥砂岩相和细粒含泥砂岩相标签样本的比例为所有样品的4.52%、13.55%和16.87%,与含砂泥岩相相比差距较大。因此,为平衡训练集、验证集中4种岩相样本比例,将占比少的岩相样本进行2倍过采样,扩充样本至458个,如表1所示。利用训练数据进行模型训练,适度优化参数,得到岩相预测叠后深度学习反演模型。最终,利用X2盲井验证深度学习反演岩相类型预测效果,并利用层位约束研究岩相在剖面及平面的展布特征。

表1 数据集不同岩相类型样本数量及比例

岩相标签	岩相类型	样本数	占比/%
0	含砂泥岩相	220	48.03
1	砂泥互层岩相	30	6.55
2	细粒含泥砂岩相	92	20.09
3	中细粒含砂砾岩相	116	25.33
	统计	458	100

4.2 评价指标

采用损失-准确率(Loss-Accuracy)函数曲线评价神经网络模型数据集拟合程度的优劣。如图9所示,训练数据集和验证数据集的损失率曲线、准确率曲线随着训练次数的增多,呈逐渐接近的趋势,表明构建的神经网络模型数据拟合性能较好。




图9 神经网络模型数据拟合程度评价曲线

在多分类任务中, F1-score是综合评估模型表现的重要指标^[17]. F1-score一般通过宏平均、加权平均或微平均的方式计算, 分别适用于不同的数据分布情况. 宏平均对各类别赋予相等权重, 加权平均则根据类别样本数加权, 而微平均通过合并所有类别的预测结果计算整体表现. F1-score在处理类别不平衡任务时尤为重要, 是优化模型表现的关键指标. 宏平均F1-score的计算方式如下:

$$P = \frac{TP}{TP + FP}, \tag{8}$$

$$R = \frac{TP}{TP + FN}, \tag{9}$$

$$F1\text{-score} = 2 \times \frac{P \times R}{P + R}, \tag{10}$$

式中: TP 表示真正例数, 即模型正确地将正类预测为正类的数量; FP 表示假正例数, 即模型错误地将负类预测为正类的数量, 也称误报; FN 表示假反例数, 即模型错误地将正类预测为负类的数量, 亦称漏报.

4.3 岩相预测结果

通过测试X2盲井的预测结果分析深度学习对4种不同岩相类型的预测性能. 深度学习模型的输出是经过CNN全连接层进行分类后的不同岩相类型. 由图10可知, 深度学习预测岩相类型结果分布与测井岩相类型分布基本吻合. 深度学习模型对于上部薄层的砂泥互层岩相类型也能较准确地预测.




图 10 X2盲井岩相预测结果对比

图11为岩相类型预测模型的混淆矩阵. 行代表测井真实岩相, 每行中的数据表示真实岩相被预测的岩相类别分布, 列代表神经网络模型预测岩相, 每列中的数据表示实测岩相被预测为该类的比例分布; 如图11第2行中的0.915, 表示91.5%实测岩相为1的样品被预测为类别1. 经式(10)计算得到神经网络模型F1-score值, 如表2所示, 每种岩相类型F1-score值均在0.85以上, 表明模型对4种岩相预测的准确性较好, 具有实用价值.




图 11 神经网络模型岩相预测混淆矩阵

表 2 4种岩相类型F1-score值

岩相类型标签	岩相类型	F1-score值
0	含砂泥岩相	0.97
1	砂泥互层岩相	0.92
2	细粒含泥砂岩相	0.86
3	中细粒含砂砾岩相	0.87

图12为叠后深度学习预测岩相剖面,基于该方法预测的岩相剖面与X1取心井的实际测井岩相吻合率高,表明该预测模型在复杂地层条件下也能展现出良好的性能.通过观察预测剖面,发现 T_2k_1 段发育中细粒含砂砾岩相与细粒含泥砂岩相,其中中细粒含砂砾岩相厚度大、连续性好,具备成为储层的基础条件.这体现了高能环境下的沉积作用,如河道或三角洲前缘的沉积环境. T_2k_2 与 T_2k_3 段发育大量砂泥互层岩相与含砂泥岩相,含砂泥岩相分布范围较广,主要位于剖面中上部,表现为连续性良好的条带状沉积以及泥质物质含量较高且夹杂砂质的沉积环境.这与前期取得的地质认识相吻合,也反映出模型预测岩相性能的准确性较高.图13为过X1取心井的常规波阻抗剖面,与图12进行对比,发现常规波阻抗反演剖面分辨率受地震数据频带限制,垂向分辨率不足,导致预测岩相分辨率低,故深度学习模型对于 T_2k_2 、 T_2k_3 的薄层砂岩相预测效果差,且与实际测井岩相吻合率低.深度学习预测岩相通过小波变换提取地震数据不同岩相特征,可以识别5 m左右较薄的砂泥互层岩相,分辨率高,预测岩相与实际测井岩相吻合率高.




图 12 深度学习预测X1取心井岩相类型剖面

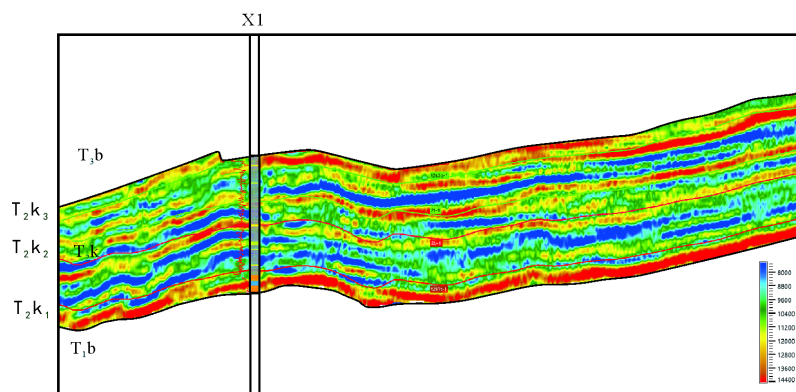


图 13 过X1取心井波阻抗反演剖面

图14为根据地震层位对深度学习模型预测岩相体进行切片得到的岩相平面图.图15为克拉玛依组3个层段的均方根振幅属性平面图. T_2k_1 波阻抗平面整体呈现红色和黄色,表明波阻抗值较高,以粒度较大的砂岩、砾岩沉积为主; T_2k_2 、 T_2k_3 波阻抗平面呈现黄色和绿色,表明波阻抗值相对较低,以粒度较细的砂岩和泥岩沉积为主.对比图14、图15可知,深度学习得到的岩相边界平面图分辨率更高,常规波阻抗方法对于分布范围较小的薄层不连续岩相边界划分不明确.由于研究区井位数量较少,常规波阻抗反演方法需要依赖大量井位数据进行井控约束,才能保证结果的准确性,而深度学习通过前期的盲井验证与实际岩相对比,已验证其预测结果的准确性,同时该方法不需要常规方法前期繁琐的岩石物理分析步骤,提高了工作效率,可直接得到岩相边界特征,为后期井位部署与储层“甜点”识别提供依据.




图 14 (a) T_2k_1 预测岩相平面图; (b) T_2k_2 预测岩相平面图; (c) T_2k_3 预测岩相平面图




图 15 (a) T_2k_1 均方根振幅属性; (b) T_2k_2 均方根振幅属性; (c) T_2k_3 均方根振幅属性

5 结论

1) 本文通过结合CNN与CWT技术,深度挖掘地震数据蕴含的高低频特征信息,进而提高岩相预测的精度.所提方法利用神经网络的自动学习能力,构建岩相预测模型,直接得到岩相类型结果,且不需要岩石物理分析,不受主观性的影响,提高分辨率的同时可减少大量的统计分析工作.

2) 将新方法成功应用于准噶尔盆地征沙村地区,制定了测井岩性、地震资料以及沉积环境多重约束的岩相类型预测方法.深度学习的预测结果表明,预测岩相与实际测井岩相具有良好的一致性.通过F1-score计算方法评价,发现4种岩相的预测准确率均达到85%以上,验证了预测的高准确性.这一方法不仅在岩相预测中表现优异,还能够识别“甜点位”,为有利岩相分布预测提供参考.深度学习模型的成功应用可推广至其他类似区域,推动油气勘探中沉积环境与岩性分布的精确预测,为勘探决策提供科学依据.

参考文献:

- [1] 张国印,林承焰,王志章,等.知识与数据融合驱动的油气藏智能表征及研究进展[J].地球物理学进展,2024,39(1):119-140. ZHANG G Y, LIN C Y, WANG Z Z, et al. Hybrid knowledge-driven and data-driven intelligent reservoir characterization and its research progress[J]. Progress in Geophysics, 2024, 39(1): 119-140. (in Chinese)
- [2] 孙龙德,邹才能,朱如凯,等.中国深层油气形成、分布与潜力分析[J].石油勘探与开发,2013,40(6):641-649. SUN L D, ZOU C N, ZHU R K, et al. Formation, distribution and potential of deep hydrocarbon resources in China[J]. Petroleum Exploration and Development, 2013, 40(6): 641-649. (in Chinese)
- [3] 匡立春,支东明,王小军,等.新疆地区含油气盆地深层-超深层成藏组合与勘探方向[J].中国石油勘探,2021,26(4):1-16. KUANG L C, ZHI D M, WANG X J, et al. Oil and gas accumulation assemblages in deep to ultra-deep formations and exploration targets of petroliferous basins in Xinjiang region[J]. China Petroleum Exploration, 2021, 26(4): 1-16. (in Chinese)
- [4] 李阳,薛兆杰,程喆,等.中国深层油气勘探开发进展与发展方向[J].中国石油勘探,2020,25(1):45-57. LI Y, XUE Z J, CHENG Z, et al. Progress and development directions of deep oil and gas exploration and development in China[J]. China Petroleum Exploration, 2020, 25(1): 45-57. (in Chinese)
- [5] 郭旭升,胡东风,黄仁春,等.四川盆地深层-超深层天然气勘探进展与展望[J].天然气工业,2020,40(5):1-14. GUO X S, HU D F, HUANG R C, et al. Deep and ultra-deep natural gas exploration in the Sichuan Basin: Progress and prospect[J]. Natural Gas Industry, 2020, 40(5): 1-14. (in Chinese)
- [6] FORD G L, PYLES D R. A hierarchical approach for evaluating fluvial systems: Architectural analysis and sequential evolution of the high net-sand content, middle Wasatch Formation, Uinta Basin, Utah[J]. AAPG Bulletin, 2014, 98(7): 1273-1304.

- [7] 刘宗堡, 赵容生, 闫力, 等. 海-塔盆地塔南凹陷南屯组一段沉积体系特征[J]. 石油与天然气地质, 2013, 34(6): 743-750.
LIU Z B, ZHAO R S, YAN L, et al. Depositional system characteristics of the first member of the Nantun formation in Tanan sag, the Hai-Ta Basin[J]. Oil & Gas Geology, 2013, 34(6): 743-750. (in Chinese)
- [8] 杨磊, 张健飞, 江喻. 川东北地区须家河组砂岩储层特征[J]. 石油地质与工程, 2010, 24(5): 9-12.
YANG L, ZHANG J F, JIANG Y. Characteristics of Xujiache Fm sandstone reservoir in Northeast region of Sichuan Basin[J]. Petroleum Geology and Engineering, 2010, 24(5): 9-12. (in Chinese)
- [9] 李曙光, 徐天吉, 甘其刚, 等. 频率域小波变换变频处理在川西地震勘探中的应用[J]. 石油物探, 2010, 49(5): 500-503.
LI S G, XU T J, GAN Q G, et al. Application of frequency division processing on frequency-domain wavelet transform in deep Chuanxi Depression[J]. Geophysical Prospecting for Petroleum, 2010, 49(5): 500-503. (in Chinese)
- [10] 郑见中. 辽河拗陷兴隆台潜山带中生界储层测井评价方法[J]. 石油地质与工程, 2019, 33(6): 29-33.
ZHENG J Z. Logging evaluation method of Mesozoic reservoir in Xinglongtai buried hill belt of Liaohe depression[J]. Petroleum Geology and Engineering, 2019, 33(6): 29-33. (in Chinese)
- [11] OZKAN A, CUMELLA S P, MILLIKEN K L, et al. Prediction of lithofacies and reservoir quality using well logs, Late Cretaceous Williams Fork Formation, Mamm Creek field, Piceance Basin, Colorado[J]. AAPG Bulletin, 2011, 95(10): 1699-1723.
- [12] AHMAD A B, TSUJI T. Machine learning for automatic slump identification from 3D seismic data at convergent plate margins[J]. Marine and Petroleum Geology, 2021, 133: 105290.
- [13] WU X M, LIANG L M, SHI Y Z, et al. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation[J]. Geophysics, 2019, 84(3): IM35-IM45.
- [14] QI J, LIN T F, ZHAO T, et al. Semisupervised multiattribute seismic facies analysis[J]. Interpretation, 2016, 4(1): SB91-SB106.
- [15] QIAN F, YIN M, LIU X Y, et al. Unsupervised seismic facies analysis via deep convolutional autoencoders[J]. Geophysics, 2018, 83(3): A39-A43.
- [16] ZHAO T, ZHANG J, LI F Y, et al. Characterizing a turbidite system in Canterbury Basin, New Zealand, using seismic attributes and distance-preserving self-organizing maps[J]. Interpretation, 2016, 4(1): SB79-SB89.
- [17] ALLEN D B, PRANTER M J. Geologically constrained electrofacies classification of fluvial deposits: An example from the Cretaceous Mesaverde Group, Uinta and Piceance Basins[J]. AAPG Bulletin, 2016, 100(12): 1775-1801.
- [18] 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 G Y, WANG Z Z, LIN C Y, 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. (in Chinese)
- [19] QI L S, CARR T R. Neural network prediction of carbonate lithofacies from well logs, Big Bow and Sand Arroyo Creek fields, Southwest Kansas[J]. Computers & Geosciences, 2006, 32(7): 947-964.
- [20] SANG X J, XUE L F, RAN X J, et al. Intelligent high-resolution geological mapping based on SLIC-CNN[J]. ISPRS International Journal of Geo-Information, 2020, 9(2): 99.
- [21] ZHOU K Q, MING D P, LYU X W, et al. CNN-based land cover classification combining stratified segmentation and fusion of point cloud and very high-spatial resolution remote sensing image data[J]. Remote Sensing, 2019, 11(17): 2065.
- [22] 杨海涛, 朱仕军, 文中平, 等. 基于S-变换的谱分解效果分析[J]. 石油天然气学报, 2009, 31(5): 267-270.
YANG H T, ZHU S J, WEN Z P, et al. Analysis of spectral decomposition effect based on S-transform[J]. Journal of Oil and Gas Technology, 2009, 31(5): 267-270. (in Chinese)
- [23] 刘俊, 吴淑玉, 陈建文, 等. 北黄海碎屑岩薄砂体储层识别技术及其应用[J]. 地球物理学进展, 2017, 32(3): 1384-1392.
LIU J, WU S Y, CHEN J W, et al. Classic thin sandbody reservoir identification technique and its application in the North Yellow Sea Basin[J]. Progress in Geophysics, 2017, 32(3): 1384-1392. (in Chinese)
- [24] 刘俊, 吴淑玉, 肖国林, 等. 频谱分解在北黄海东部拗陷下白垩统储层预测的应用[J]. 海洋地质与第四纪地质, 2015, 35(4): 95-103.
LIU J, WU S Y, XIAO G L, et al. The application of spectral decomposition technology to the Lower Cretaceous reservoirs prediction in eastern depression of the North Yellow Sea[J]. Marine Geology & Quaternary Geology, 2015, 35(4): 95-103. (in Chinese)

- [25] CHAI X T, NIE W H, LIN K, et al. An open-source package for deep-learning-based seismic facies classification : Benchmarking experiments on the SEG 2020 open data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4507719.
- [26] 张华, 潘冬明, 张兴岩. 二维小波变换在去除面波干扰中的应用[J]. *石油物探*, 2007, 46(2): 147-150.
ZHANG H, PAN D M, ZHANG X Y. Application of 2-D wavelet transformation in eliminating surface wave interference[J]. *Geophysical Prospecting for Petroleum*, 2007, 46(2): 147-150. (in Chinese)
- [27] 王西文, 高静怀, 李幼铭. 高分辨地震资料处理中导数小波函数的构造[J]. *石油物探*, 2000, 39(2): 64-71+76.
WANG X W, GAO J H, LI Y M. Construction of derivative wavelet function in high resolution seismic data processing[J]. *Geophysical Prospecting for Petroleum*, 2000, 39(2): 64-71+76. (in Chinese)
- [28] 彭才, 朱仕军, 孙建库, 等. 小波变换域K-L变换及其去噪效果分析[J]. *石油物探*, 2007, 46(2): 112-114.
PENG C, ZHU S J, SUN J K, et al. K-L transformation in wavelet conversion domain and the analysis of de-noise effect[J]. *Geophysical Prospecting for Petroleum*, 2007, 46(2): 112-114. (in Chinese)
- [29] 张利军, 鲁文豪, 张建东, 等. 基于深度学习的镜下岩石、矿物薄片识别[J]. *地学前缘*, 2024, 31(3): 498-510.
ZHANG L J, LU W H, ZHANG J D, et al. Rock and mineral thin section identification based on deep learning[J]. *Earth Science Frontiers*, 2024, 31(3): 498-510. (in Chinese)
- [30] 何田素, 李玮, 盖京明, 等. 基于小波去噪神经网络在数字岩心的应用[J]. *科学技术与工程*, 2025, 25(1): 270-277.
HE T S, LI W, GAI J M, et al. Application of wavelet denoising neural network in digital core[J]. *Science Technology and Engineering*, 2025, 25(1): 270-277. (in Chinese)
- [31] 赵金泉, 尤加春, 魏俊廷, 等. 基于CWT-CNN的地震噪声压制研究[J]. *石油物探*, 2023, 62(3): 395-405.
ZHAO J Q, YOU J C, WEI J T, et al. Seismic noise suppression based on CWT-CNN[J]. *Geophysical Prospecting for Petroleum*, 2023, 62(3): 395-405. (in Chinese)
- [32] ZHANG J Y, AMBROSE W, XIE W. Applying convolutional neural networks to identify lithofacies of large-n cores from the Permian Basin and Gulf of Mexico: The importance of the quantity and quality of training data[J]. *Marine and Petroleum Geology*, 2021, 133: 105307.
- [33] 李忠新, 王玮. 征沙村地区三工河组低渗透砂岩储层孔隙结构研究[J]. *科学技术与工程*, 2016, 16(30): 200-204+215.
LI Z X, WANG W. Study on pore structure of low-permeability sandstone reservoirs of the Sangonghe formation of Zhengshacun region[J]. *Science Technology and Engineering*, 2016, 16(30): 200-204+215. (in Chinese)
- [34] 刘惠民, 张关龙, 范婕, 等. 准噶尔盆地腹部征沙村地区征10井的勘探发现与启示[J]. *石油与天然气地质*, 2023, 44(5): 1118-1128.
LIU H M, ZHANG G L, FAN J, et al. Exploration discoveries and implications of well Zheng 10 in the Zhengshacun area of the Junggar Basin[J]. *Oil & Gas Geology*, 2023, 44(5): 1118-1128. (in Chinese)
- [35] LI B C, HE D X, LI M J, et al. Biomarkers and carbon isotope of monomer hydrocarbon in application for oil-source correlation and migration in the Moxizhuang-Yongjin block, Junggar Basin, NW China[J]. *ACS Omega*, 2022, 7(50): 47317-47329.
- [36] STEEGHS P, DRIJKONINGEN G. Seismic sequence analysis and attribute extraction using quadratic time-frequency representations[J]. *Geophysics*, 2001, 66(6): 1947-1959.
- [37] CHAKRABORTY A, OKAYA D. Frequency-time decomposition of seismic data using wavelet-based methods[J]. *Geophysics*, 1995, 60(6): 1906-1916.
- [38] ABDEL-HAMID O, MOHAMED A R, JIANG H, et al. Convolutional neural networks for speech recognition[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2014, 22(10): 1533-1545.
- [39] LIN J, QU L S. Feature extraction based on Morlet wavelet and its application for mechanical fault diagnosis[J]. *Journal of Sound and Vibration*, 2000, 234(1): 135-148.
- [40] NAIR V, HINTON G E. Rectified linear units improve restricted Boltzmann machines[EB/OL]. (2010-06-21)[2024-10-15]. <https://icml.cc/Conferences/2010/papers/432.pdf>.
- [41] KLINE D M, BERARDI V L. Revisiting squared-error and cross-entropy functions for training neural network classifiers[J]. *Neural Computing & Applications*, 2005, 14(4): 310-318.
- [42] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout : Prevent NN from overfitting[J]. *Journal of Machine Learning Research*, 2014, 15: 1929-1958.