

基于 MLP-CNN 的固井质量智能评价方法

王正¹, 宋先知^{1,2*}, 李根生^{1,2}, 潘涛¹, 李臻¹, 祝兆鹏³

1 中国石油大学(北京)石油工程学院, 北京 102249

2 中国石油大学(北京)油气资源与工程全国重点实验室, 北京 102249

3 中国石油大学(北京)机械与储运工程学院, 北京 102249

* 通信作者, songxz@cup.edu.cn

收稿日期: 2023-12-04; 修回日期: 2024-03-11

国家自然科学基金委员会国家自然科学基金-国家杰出青年科学基金(52125401)资助

摘要 固井质量的好坏关系到油气井的产量和寿命, 目前最常用的方法是使用声幅—变密度测井进行评估, 但是解释过程复杂, 且与重大风险相关的决策需要根据固井解释结果做出。因此, 固井质量评价必须由经验丰富的专家进行解释, 耗时耗力。为了提高固井解释的效率, 本文基于 VGG、ResNet 等卷积神经网络对固井质量进行自动解释, 但是准确率不足。于是, 本文提出一种多层感知机和卷积神经网络并联的方法 (MLP-CNN), 声幅数据输入到多层感知机中, 变密度图输入卷积神经网络中; 针对变密度图存在不同尺度信息的特征(条纹的粗细、明暗、形状), 本文修改了卷积神经网络的结构, 设置了大小不同的卷积核, 提取不同尺度信息。本文使用了塔里木油田富源区块的 9000 个数据进行训练和验证, 结果表明, 相较于传统的 VGG、ResNet 等卷积网络, MLP 和 CNN 并联网络有效提高了固井质量识别的准确率, 评价精度为 90%, 并且相较于单一尺度卷积核, 多个大小不同卷积核的卷积神经网络算法更适合于固井变密度图像特征的提取, 本文修改了卷积神经网络部分结构, 建立的带有 3 个尺寸不同卷积核的 MLP-CNN 神经网络比单一卷积核的 MLP-CNN 模型提高了 5% 的准确率; 同时, 本文对比了 7 种网络的时间复杂度和空间复杂度, 结果表明, MLP-CNN 并联网络能有效避免大量的无效卷积, 节省了模型计算成本, 提高模型的计算效率。最后, 为了测试模型的迁移性, 本文使用塔里木油田满深和跃满区块的 6 万条数据进行了测试, 评价准确率达 89.16%, 迁移效果良好, 模型具有较强的鲁棒性。

关键词 固井质量评价; 深度学习; 卷积神经网络; 多层感知机; 图像特征提取

中图分类号: TE256; TP18

Intelligent evaluation method for cementing quality based on MLP-CNN

WANG Zheng¹, SONG Xianzhi^{1,2}, LI Gensheng^{1,2}, PAN Tao¹, LI Zhen¹, ZHU Zhaopeng³

1 College of Petroleum Engineering, China University of Petroleum-Beijing, Beijing 102249, China

2 State Key Laboratory of Oil and Gas Resources and Engineering, China University of Petroleum-Beijing, Beijing 102249, China

3 College of Mechanical and Storage Engineering, China University of Petroleum-Beijing, Beijing 102249, China

引用格式: 王正, 宋先知, 李根生, 潘涛, 李臻, 祝兆鹏. 基于 MLP-CNN 的固井质量智能评价方法. 石油科学通报, 2024, 09(05): 724-736
WANG Zheng, SONG Xianzhi, LI Gensheng, PAN Tao, LI Zhen, ZHU Zhaopeng. Intelligent evaluation method for cementing quality based on MLP-CNN. Petroleum Science Bulletin, 2024, 09(05): 724-736. doi: 10.3969/j.issn.2096-1693.2024.05.055

Received: 2023-12-04; Revised: 2024-03-11

Abstract The quality of cementing is crucial for the production efficiency and lifespan of oil and gas wells. Currently, the most widely used method is acoustic amplitude variable density logging for evaluation. However, the interpretation process is complex, and decisions related to major risks need to be made based on the results of cementing interpretation. Therefore, the evaluation of cementing quality must be undertaken by experienced experts, which is time-consuming and labor-intensive. In order to improve the efficiency of cementing interpretation, we used convolutional neural networks such as VGG and ResNet to automatically interpret cementing quality, but the accuracy was insufficient. Therefore, we propose a method of parallel connection between multi-layer perceptions and convolutional neural networks (MLP-CNN), where acoustic amplitude data is input into multi-layer perceptions and variable density logging images are input into convolutional neural networks; We modify the structure of convolutional neural networks by setting convolutional kernels of different sizes to extract information at different scales for features with varying density maps, such as the thickness, brightness, and shape of stripes. We used 9000 data from the Fuyuan block of the Tarim Oilfield for training and validation. The results showed that compared to traditional convolutional networks such as VGG and ResNet, the MLP and CNN parallel networks effectively improved the accuracy of cementing quality recognition, with an evaluation accuracy of 90%. Furthermore, compared to a single scale convolutional kernel, the convolutional neural network algorithm with multiple convolutional kernels of different sizes is more suitable for extracting features from variable density cementing images. We modified the structure of the convolutional neural network and established an MLP-CNN neural network with three convolutional kernels of different sizes, which improved the accuracy by 5% compared to the MLP-CNN model with a single convolutional kernel; meanwhile, we compared the time complexity and spatial complexity of seven networks. The findings revealed that the MLP-CNN parallel network efficiently mitigates a substantial number of ineffective convolutions, thereby reducing model computational costs and enhancing computational efficiency. Finally, in order to test the transferability of the model, we used 60000 data from the Manshen and Yueman blocks of the Tarim Oilfield for testing, and the evaluation accuracy reached 89%, indicating a satisfactory migration effect and robust performance of the model.

Keywords cementing quality evaluation; deep learning; convolutional neural network; multi-layer perceptron; image feature extraction

doi: 10.3969/j.issn.2096-1693.2024.05.055

0 引言

固井作业就是用合适的设备、工艺及固井工作液将井内下入的套管串与地层或外层套管之间的环形空间进行有效的封固。它是大多数油井在钻完井施工阶段进行的一项非常常见的作业，是衔接钻井工程和采油工程的关键工程，固井的成败，不仅关系到一口井的前期钻井工程的成败，而且固井质量的好坏也会对油气井的后期生产产生较大影响。若固井质量不好，不仅对后续的钻进、试油带来困难，而且对油井的生产寿命影响极大^[1]。

为了确保固井作业成功，必须对水泥环质量进行测试。到目前为止，唯一能够确定固井水泥环胶结质量的方法是压力测试^[2]。但是有现场经验表明，压力测试可能会造成水泥环损坏^[3]。目前，声幅—变密度测井是当前评估固井质量的主要方法。然而，通过声幅—变密度测井对固井质量进行解释过程复杂^[4]，必须由训练有素的专家进行人工解释，这也造成固井解释需要消耗大量的专家人力。同时，下一步的油气井开发会取决于固井质量的评估结果，因此固井解释必须在较短时间内尽快完成^[5]，人工解释速度慢，效率

低下，亟需一种高效精准的固井质量智能评价方法。

近年来人工智能算法快速发展，在图像识别和大数据分析上具有很大的优势，国内外很多学者应用了机器学习算法在井筒质量解释领域，并取得了良好的效果^[6-8]。2018年，Onalo^[9]等人使用神经网络从裸眼测井资料中获取信息，重建裸眼声波测井资料。2018年，Belozero^[10]等人利用神经网络从测井数据中识别油藏位置。2019年，Gkortsas^[11]等人使用支持向量机和神经网络自动识别超声波波形特征，该特征可以预测套管井中环形材料纵波速度的额外信息。2020年，Deepak Kumar Voleti^[12]等人建立了不同的机器学习算法，如基于声幅、变密度测井数据和超声成像数据的随机森林和神经网络进行预测，输出固井质量预测结果。2021年，Santos^[13]等人使用高斯过程回归算法进行训练，基于CBL和VDL测井数据，生成新的特征曲线，以此准确评价固井质量。2021年，郑双进^[14]等人提出一种基于GA-SVR算法的固井质量预测方法，可在固井施工前对井筒质量进行超前预测。2022年，宋先知^[15]等人构建了LSTM-BP串联神经网络实时计算地层孔隙压力。2022年，Fang^[16]等人建立了带有多个卷积核的卷积神经网络识别变密度图像，输出

固井质量, 解释准确率高达 90%。2023 年, Wang^[17] 等人出了面向测井变密度图像的 Wasserstein 距离生成对抗网络, 扩充变密度图像数据集。

本文充分分析了声幅和变密度测井的数据特征, 提出一种基于多层感知机和卷积神经网络的固井质量自动解释方法, 基于训练好的神经网络, 输入声幅测井数据和变密度图像数据, 同时输出第一界面和第二界面的固井质量。使用本方法, 实现了对固井水泥环第一和第二界面的精准评估, 大大提高固井质量评估的准确率和效率。

1 神经网络原理

1.1 神经元与多层感知机 (MLP)

神经网络中最基本的单元是神经元。1943 年, Mcculloch 和 Pitts^[18] 受生物学中神经系统的启发, 将其抽象为简单的数学模型, 其结构如图 1 所示, 神经元接收其他神经元的输入信号 x_i , 通过权重 w_i 加权后计算总输入并与阈值 b 进行比较, 通过激活函数 f 计算后产生神经元的总输出。其正向传播过程为:

$$y = f\left(\sum_{i=1}^n w_i x_i - b\right) \quad (1)$$

多层感知机 (Multi-layer Perceptions, 以下简称 MLP) 是神经元逐层以非循环的方式连接而成的结构, 神经元层按功能分为输入层、隐藏层和输出层, 如图 2 所示, 神经元层与层之间为全连接形式。1984 年, Rumelhart^[19] 等人提出误差反向传播神经网络, 按误差反向传播算法训练的多层前馈网络, 也是其应用最广泛的模型之一。




图 1 M-P 神经元模型
Fig. 1 M-P neuron model

1.2 卷积神经网络 (CNN)

卷积神经网络 (Convolutional Neural Networks, 以下简称 CNN) 是一种具有卷积运算和深度结构特征的前馈神经网络, 被广泛应用于图像识别, 常见的 CNN 模型结构如图 3 所示。卷积神经网络适合执行多维数据的处理, 隐藏层包括卷积层、池化层、和全连接层, 输出层根据模型的需要确定^[20]。相比 MLP, CNN 具有局部感知、子采样和权值共享三点优势^[21]。

2 固井质量解释原理

钻井后, 井筒中下入测井仪器进行测井数据采集, 采集的数据包括各种不同的物理参数, 然后进行测井




图 2 带有四层神经元的多层感知机
Fig. 2 A multi-layer perceptron with four layers of neurons

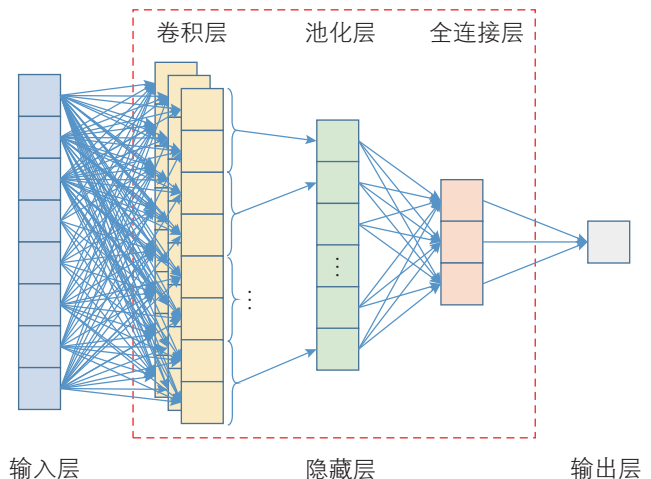


图 3 卷积神经网络结构
Fig. 3 Convolutional neural network structure

处理与解释工作^[22]，在这个过程中需要测井分析专家结合地质知识以及自身经验，将测井数据转换为地质信息，以便对井筒周围的地质情况得到准确的认知。

2.1 声幅—变密度测井资料解释

声波变密度测井属于声波测井的一种，其原理是利用水泥和泥浆(或水)其声阻抗的较大差异对沿套管轴向传播的声波的衰减影响来反映水泥与套管间、套管与地层的胶结质量^[23]。

声幅—变密度测井原理如图 4，声波幅度测井(CBL)源距 3 ft， R_1 接收套管波^[24]，变密度测井源距 5 ft， R_2 接收套管波、水泥环波、地层波和直达波^[25]。根据 CBL 的幅值，采用相对幅度法评价第一胶结面的胶结质量：相对幅度小于 20%，胶结良好，相对幅度介于 20%~40%，胶结质量中等，相对幅度大于 40%，胶结质量差。第二界面只能定性评价，套管波越强，第一界面胶结越差，套管波越弱，第一界面胶结质量越好；地层波越强、越连续，表明第二界面的胶结质量越好；地层波越弱、越不连续，第二界面的胶结质量越差，为了更直观的看出不同固井质量的变密度图像，本文根

据测井实例总结，图像特征大体分为 6 类，见表 1。

2.2 人工智能解释方法

由于变密度图像的特殊性，变密度图像是明暗间的条带，并非确定的数值，条带的形状，明暗程度




图 4 声幅—变密度测井原理

Fig. 4 Principle of sound amplitude variable density logging

表 1 固井质量解释实例

Table 1 Example of cementing quality interpretation

变密度图像特征	变密度图像实例	固井质量评价结果
套管波弱，地层波强		第一界面胶结中等，第二界面胶结良好
套管波无显示，地层波强		第一界面胶结良好，第二界面胶结良好
套管波强，地层波微弱，几乎不显示		如果声幅为最大值，则为自由套管；非最大值，第一界面胶结差，第二界面无法判断
套管波弱，地层波不明显		第一界面胶结良好，第二界面胶结中等至差
套管波明显，地层波有显示		第一界面胶结差，第二界面胶结好
明显 V 字型		套管接箍

完全取决于评价者的主观感受,因此评价结果掺杂了评价人的主观性,不同的测井解释专家可能会得出不同的结论。

为了减小人工解释时的主观性,测井公司通常会采用多个测井解释人员协作,共同对同一个测井结果进行解释分析,得出更准确的结果,但是这也进一步增加了时间,消耗更多的人力。因此,准确且高效地评价固井质量是一个非常困难的问题,建立一个测井声幅—变密度的自动解释模型,将大大提高固井质量识别的准确率和效率。

基于声幅—变密度测井曲线进行固井质量评价,与一般的图像分类任务非常相似,在分类任务中,对变密度图像进行分割,输入到卷积神经网络中进行训练,声幅数据输入到多层感知机中训练,通过此方式对固井质量进行分类判别。相关学者已经对图像分类的算法进行了大量的研究,目前图像识别最好的方法是基于卷积神经网络^[26-28]。因此,本文模型的主要部分也是基于卷积神经网络来完成分类任务的,但是,从表1中可以看出,固井质量评价存在多解性,单纯依靠变密度图,无法准确判别,还需要加入声幅数据作为新的特征。于是,本文将声幅数据输入MLP中,变密度图像输入到CNN中,建立基于MLP—CNN组合网络的固井质量智能评价方法,设计结构简图见图5。

同时,本文考虑到测井变密度图像并非单纯的图像识别任务^[29],在进行变密度评价时,需要整合图像的整体与局部特征,即固井质量的评价结果不仅基于单个条带的明暗特征,还要参考所有条带的形状、疏密程度,故本文改进了模型的卷积神经网络部分,设置了大小不同的滤波器,提取图像中不同尺度的信息,如图6,建立了多维度特征提取的卷积神经网络,可

进一步提高模型的准确性。

3 模型搭建与参数设置

3.1 数据集

本文采用的数据集是塔里木油田公司的富源区块两口井的数据,数据总长度达9000 m,包括磁定位、声幅、变密度测井曲线,以及两口井的固井解释结果。声幅测井数据最小长度为0.125 m,MLP模型输入是一个长度为8的向量(1 m的声幅数据)。卷积神经网络需要以一致的分辨率输入数据,本文把变密度图像分割成1 m长的深度段,作为CNN模型的输入。

参照表1中的声幅—变密度测井图响应特征,制定了固井质量训练集标注方法,见表2,重新为数据集标注训练标签。

3.2 模型搭建

神经网络的输入为大小、分辨率完全相同的测井变密度图像,对于图像类的数据,卷积神经网络进行

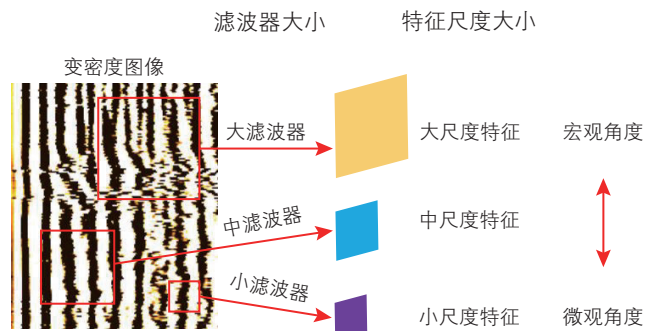


图6 多尺度特征提取网络设计思路

Fig. 6 Design ideas for multi-scale feature extraction network

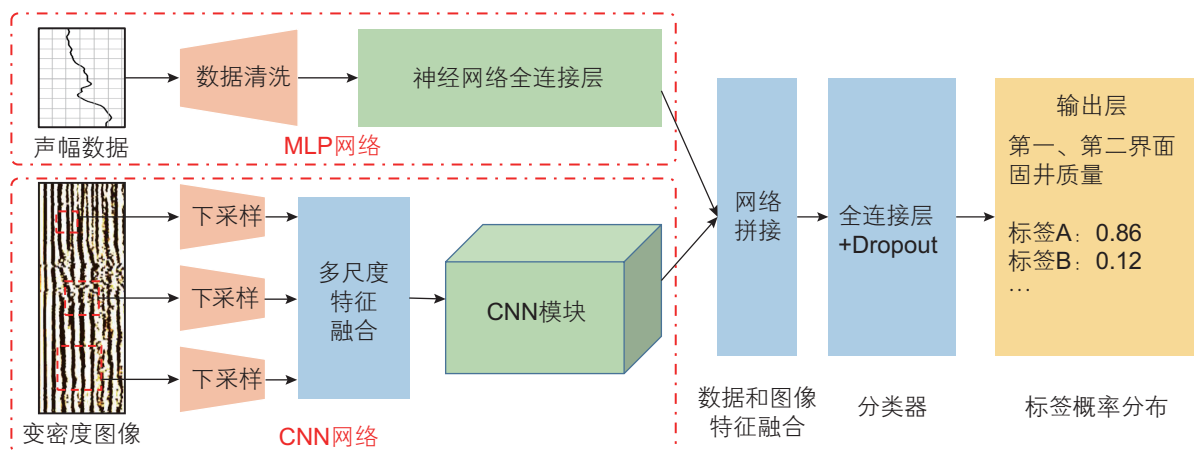


图5 MLP-CNN组合网络的结构设计简图

Fig. 5 Structural Design Diagram of MLP-CNN Combination Network

识别已经被证明是非常有效的^[30]，经典的卷积神经网络具有卷积层、池化层，然后是加密层，仅增加层数或者卷积核个数，能够提高图像识别的准确率，但是可能也会导致过拟合问题^[31]，本文网络设置遵循Chollet^[32]的建议，每次卷积后采用最大池化，最大池化后进行批量标准化操作。网络结构见表3，其中

表 2 固井质量训练集标注方法

Table 2 Annotation Method for Cementing Quality Training Set

声幅特征	变密度特征	第一界面	第二界面
最大值	套管波强，地层波微弱	自由套管	自由套管
高，但非最大值	套管波强，数量多，地层波弱，出现波浪形	差	差
最低	套管波弱，地层波强	良好	良好
低	套管波弱，地层波有显示	良好	中
低	套管波弱，地层波微弱	良好	差
低	套管波、地层波都弱	中	差
中等	套管波强，地层波有显示	中	中

表 3 MLP-CNN 网络结构

Table 3 MLP-CNN Network Structure

神经网络	层属性	参数设置	激活函数
CNN	卷积层 1	滤波器数：128，核大小：5×5，步长：1×1	ReLU
	卷积层 2	滤波器数：128，核大小：3×3，步长：1×1	ReLU
	卷积层 3	滤波器数：128，核大小：1×1，步长：1×1	ReLU
	最大池化层 1	池大小 3×3，步长：2×2	\
	卷积层 4	滤波器数：64，核大小：3×3，步长：1×1	ReLU
	卷积层 5	滤波器数：64，核大小：3×3，步长：1×1	ReLU
	最大池化层 2	池大小 2×2，步长：2×2	\
	卷积层 6	滤波器数：64，核大小：3×3，步长：1×1	ReLU
	卷积层 7	滤波器数：64，核大小：3×3，步长：1×1	ReLU
	最大池化层 3	池大小 2×2，步长：2×2	\
	卷积层 8	滤波器数：128，核大小：3×3，步长：1×1	ReLU
	卷积层 9	滤波器数：128，核大小：3×3，步长：1×1	ReLU
	最大池化层 4	池大小 2×2，步长：2×2	\
	卷积层 10	滤波器数：256，核大小：3×3，步长：1×1	ReLU
	卷积层 11	滤波器数：256，核大小：3×3，步长：1×1	ReLU
	最大池化层 5	池大小 2×2，步长：2×2	\
	卷积层 12	滤波器数：512，核大小：3×3，步长：1×1	ReLU
	卷积层 13	滤波器数：512，核大小：3×3，步长：1×1	ReLU
	全局平均池化	\	\
MLP	全连接层 1	神经元数量：1024	
	全连接层 2	神经元数量：1024，丢弃概率：0.5	ReLU
	全连接层 3	神经元数量：512，丢弃概率：0.5	ReLU
	全连接层 4	神经元数量：256，丢弃概率：0.5	ReLU
	全连接层 5	神经元数量：14	Softmax
	全连接层 1	神经元数量：8	ReLU
	全连接层 2	神经元数量：64	ReLU
	全连接层 3	神经元数量：256	ReLU
	全连接层 4	神经元数量：512	ReLU
	全连接层 5	神经元数量：1024	ReLU

CNN网络中的全连接层1与MLP中的全连接层5进行了网络拼接。

3.3 模型度量标准

衡量模型分类性能指标主要包括分类准确率(又称分类精度)、召回率与查准率等^[33]。本文主要采用这3个指标对所提方法进行评价。图7为混淆矩阵图。

为此,分类准确率 ACC 可用公式(2)进行表征:

$$ACC = \frac{TP + TN}{TP + FP + TN + FN} \quad (2)$$

召回率 R 可用公式(3)进行表征:

$$R = \frac{TP}{TP + FN} \quad (3)$$

查准率 P 可用公式(4)进行表征:

$$P = \frac{TP}{TP + FP} \quad (4)$$

		预测标签 Predicted label	
		√	×
实际标签 Actual label	√	TP	FN
	×	FP	TN

注: TP 真阳性; FN 假阴性; FP 假阳性; TN 真阴性。

图7 混淆矩阵

Fig. 7 Confusion matrix

3.4 实验环境及参数设置

本实验均在同一环境配置的计算机上完成,用于实验的计算机配置为Windows11、96G内存, NVidia RTX3000 6G显存GPU, 基于TensorFlow方法实现, 损失函数选择交叉熵损失(Cross entropy loss), 最大epoch设置为100, 学习率设置为0.0001, batch size为16, 本文使用Adam作为训练阶段优化器^[34]。

4 模型结果与讨论

4.1 模型结果

为了评估本文提出的MLP-CNN方法的分类性能, 本文进行了数据实验, 经过85次迭代, MLP-CNN分类精度可达95%, 如图8。同时本文对比了目前图像识别领域中常用的VGG-16、VGG-19、ResNet-18、ResNet-34、AlexNet卷积网络, 表4给出了MLP-CNN和一些成熟的卷积神经网络的对比结果。

为了详细分析模型对每一类别的查准率和召回率, 本文给出了模型在塔里木油田富源区块数据集的结果混淆矩阵, 如图9所示, 图中标签A代表自由套管(第一、第二界面未胶结); 标签B代表第一、第二界面胶结差; 标签C代表第一、第二界面胶结良好; 标签D代表第一界面胶结良好, 第二界面胶结中等; 标签E代表第一界面胶结良好, 第二界面胶结差; 标签F代表第一界面胶结中等, 第二界面胶结差; 标签G代表第一、第二界面胶结中等。

图9中主对角线显示的是识别正确的数目, 其余

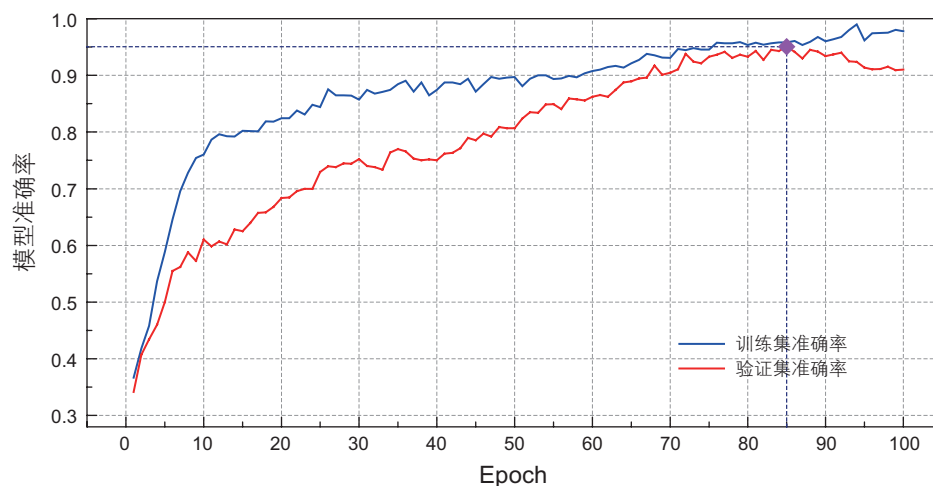


图8 MLP-CNN训练结果

Fig. 8 Training results of MLP-CNN

表 4 MLP-CNN与常用卷积网络性能比较

Table 4 Performance comparison between MLP-CNN and commonly used convolutional networks

方法	准确率ACC	召回率R	查准率P
VGG-16	87.48	86.22	92.19
VGG-19	85.44	84.81	87.96
ResNet-18	81.00	81.00	81.30
ResNet-34	83.85	83.74	86.26
AlexNet	81.93	82.14	81.26
单一卷积核的MLP-CNN	90.00	89.54	93.72
3个不同大小卷积核MLP-CNN	95.00	95.10	94.93




图 9 富源区块固井质量的分类混淆矩阵

Fig. 9 Classification confusion matrix for cementing quality in Fuyuan block

区域是识别错误的数目。可以看出 3300 个验证数据中，3135 个数据是识别正确的，165 个数据是识别错误的，观察查准率和召回率可以看出绝大部分的查准率和召回率在 90% 以上，结果证明本模型对各个分类结果都有较好的分类效果。

4.2 网络结构对比

为了证明具有多个大小不同的滤波器的卷积神经网络效果更好，本文将 VGG-16、VGG-19、ResNet-18、ResNet-34、AlexNet 卷积网络与本文的卷积神经网络进行了对比，使用时间复杂度、空间复杂度两个指标进行对比。

①时间复杂度

时间复杂度，即模型的运算次数，可用 FLOPs 衡量，也就是浮点运算次数 (Floating-point Operations)，时间复杂度决定了模型的训练/预测时间。如果复杂度过高，则会导致模型训练和预测耗费大量时间，既无法快速的验证想法和改善模型，也无法做到快速的预测，单个卷积层的时间复杂度计算公式如下：

$$\text{Time} \sim O(M^2 \cdot K^2 \cdot C_{in} \cdot C_{out}) \quad (5)$$

式中， M 为每个卷积核输出特征图的边长； K 为每个卷积核的边长； C_{in} 为每个卷积核的通道数，即输入通道数，也即上一层的输出通道数； C_{out} 为本卷积层具有的卷积核个数，也即输出通道数。可见，每个卷积核的时间复杂度由输出特征图面积 M^2 、卷积核面积 K^2 、输入通道数 C_{in} 和输出通道数 C_{out} 完全决定的。其中，输

出特征尺寸本身又由输入矩阵尺寸 X 、卷积核尺寸 K 、填充 Padding 、步长 Stride ，4个参数决定的，表示如下：

$$M = \frac{(X - K + 2 \times \text{Padding})}{\text{Stride}} + 1 \quad (6)$$

卷积神经网络整体的时间复杂度是所有卷积层的时间复杂度累加，计算公式如下：

$$\text{Time} \sim O\left(\sum_{l=1}^D M_l^2 \cdot K_l^2 \cdot C_{l-1} \cdot C_l\right) \quad (7)$$

式中， D 为神经网络所具有的卷积核数，即网络的深度； l 为神经网络的第 l 个卷积层； C_l 为神经网络的第 l 个卷积层的输出通道数 C_{out} ，即该层的卷积核个数；对于第 l 个卷积层而言，其输入通道数 C_{in} 就是第 $l-1$ 个卷

积层的输出通道数。

②空间复杂度

空间复杂度决定了模型的参数数量。由于维度诅咒的限制，模型的参数越多，训练模型所需的数据量就越大，而现实生活中的数据集通常不会太大，这会导致模型的训练更容易过拟合。空间复杂度计算公式如下：

$$\text{Space} \sim O\left(\sum_{l=1}^D K_l^2 \cdot C_{l-1} \cdot C_l + \sum_{l=1}^D M^2 \cdot C_l\right) \quad (8)$$

总参数量只与卷积核的尺寸 K 、通道数 C 、层数 D 相关，而与输入数据的大小无关。经过计算各个算法的时间和空间复杂度计算结果见表5和图10a、b。

从图10可以看出，本文提出的MLP-CNN模型时

表5 不同算法时间和空间复杂度

Table 5 Time and Space Complexity of Different Algorithms

算法	时间复杂度	空间复杂度
3个不同大小卷积核的MLP-CNN	10 726 558 523	10 227 169
单一卷积核的MLP-CNN	8 436 854 546	7 028 227
VGG-16	23 499 914 770	66 174 019
VGG-19	28 389 152 786	71 483 715
ResNet-34	13 026 470 802	25 060 867
AlexNet	11 821 927 282	111 089 351
ResNet-18	9 894 478 866	13 683 075

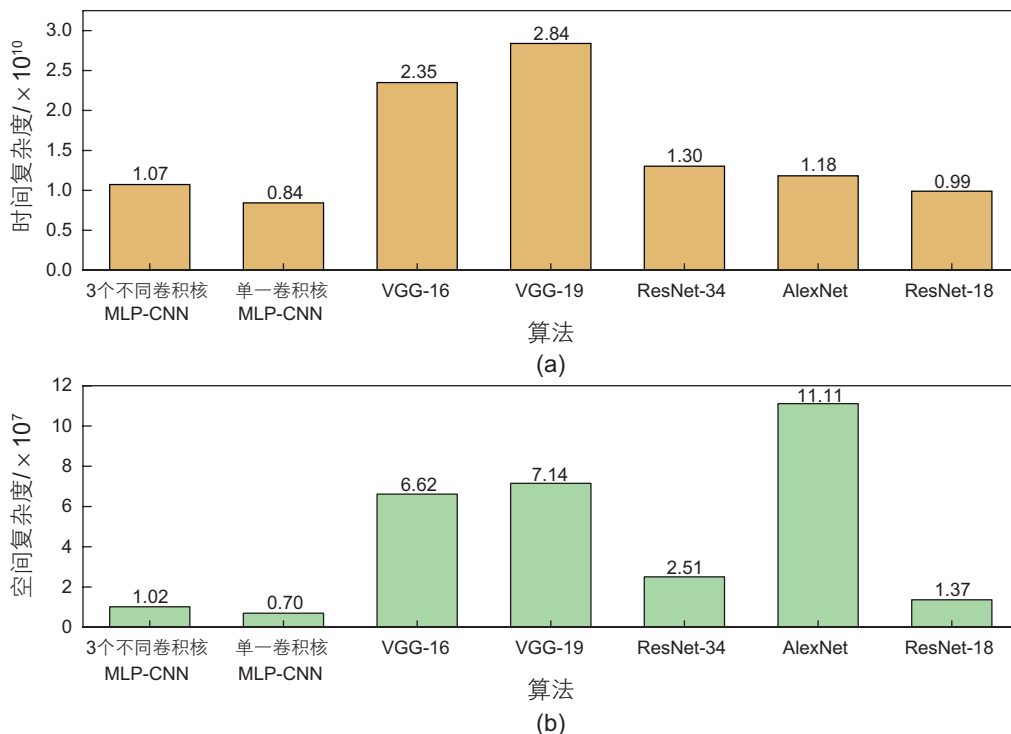


图10 不同算法时间和空间复杂度

Fig. 10 Time and spatial complexity of different algorithms

间复杂度和空间复杂度相对较低，有利于降低计算成本和运算的时间成本。

4.3 模型迁移效果

本文 4.1 的结果是采用塔里木油田富源区块的两口井的数据进行训练和验证，为了测试模型的迁移效果，本文把在富源区块的训练好的 MLP-CNN 模型直接应用于塔里木油田满深和跃满区块的 8 口井进行测试，

数据量和测试结果见表 6，满深、跃满区块固井质量分类混淆矩阵见图 11 和图 12。

从图 11 和图 12 中可以看出，经过迁移测试后，满深区块的识别准确率为 89.02%，跃满区块为 89.57%，总体识别准确率为 89.16%，在两个区块中单一分类的查准率和召回率均大于 85%，说明本文提出的 MLP-CNN 模型对各个分类均有较好的识别效果，模型的迁移效果良好。

表 6 满深和跃满区块测试结果

Table 6 Test results of Manshen and Yueman block

区块	井名	样本总量	识别正确的样本数	准确率 ACC
满深	满深 2	7420	6481	87.34
	满深 3	7580	6917	91.25
	满深 4	7420	6735	90.77
	满深 5	7632	6553	85.86
	满深 20	7292	6556	89.91
	满深 301	7552	6726	89.06
	跃满	跃满 23	7429	6688
	跃满 251	7508	6691	89.12
	总计	59833	53347	89.16



图 11 满深区块固井质量的分类混淆矩阵

Fig. 11 Classification confusion matrix for cementing quality in ManShen block

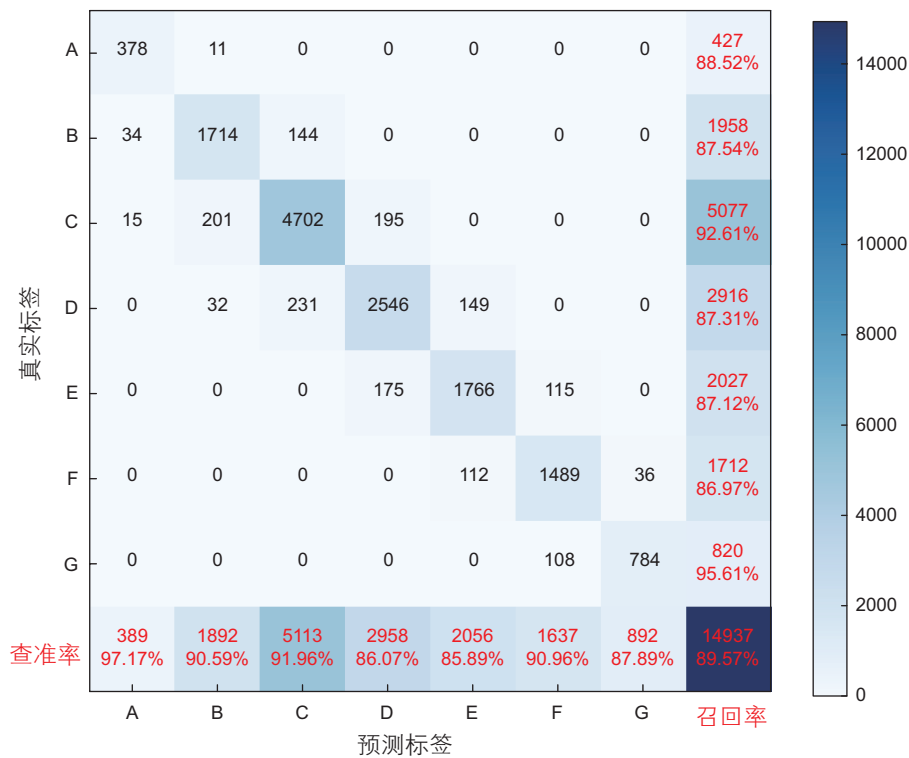


图 12 跃满区块固井质量的分类混淆矩阵

Fig. 12 Classification confusion matrix for cementing quality in YueMan block

5 结论

(1) 本文利用多层感知机和卷积神经网络建立了一个固井质量自动评价模型, 通过将声幅数据输入多层感知机、变密度图像输入到卷积神经网络中, 模型自动评价出当前井段的固井质量, 经测试, 模型在同区块井的解释准确率可达到 95%, 跨区块测试地准确率高达 89.16%, 且针对每一种分类均可做到较为准确的识别, 可满足现场工程需求。

(2) 本文参考人工解释变密度图的方法, 修改了卷积神经网络结构。本文提出了一种多尺度感知卷积神

经网络, 在模型中设置了不同尺寸的卷积核, 以便提取图像不同尺度的特征, 与带有单一卷积核的 MLP-CNN 相比, 多个卷积核的 MLP-CNN 能提高模型精度 5%。

(3) 本文从时间复杂度和空间负责度两个角度, 对比了本文建立的 MLP-CNN 模型和 VGG 等 6 种传统的卷积神经网络模型, 结果表明, MLP-CNN 神经网络模型采取的多个并联通道, 避免了大量的无效卷积操作, 时间和空间复杂度相对较低, 有利于降低计算成本和计算时间, 为固井质量解释评价提供了一种智能化的快速方法。

参考文献

- [1] RAVI K, WEBER L. Drill-Cutting removal in a horizontal wellbore for cementing[C]// IADC /SPE Drilling Conference. OnePetro. 1996.
- [2] VIGGEN E M, MERCIU I A, LOVSTAKKEN L, et al. Automatic interpretation of cement evaluation logs from cased boreholes using supervised deep neural networks[J]. Journal of Petroleum Science and Engineering, 2020, 195: 107539.
- [3] 刘奎, 丁士东, 周仕明, 等. 套管内压周期变化水泥环应力计算与失效分析[J]. 石油机械, 2021, 49(5): 1-8. [LIU K, DING S D, ZHOU S M, et al. Stress calculation and failure analysis of cement sheath with periodic changes in internal pressure of casing[J]. Petroleum Machinery, 2021, 49(5): 1-8.]
- [4] BENGE G. Cement evaluation—A risky business[J]. SPE Drilling & Completion, 2015, 30(4): 322-326.
- [5] 张永超. 低密度水泥胶结质量 CBL/VDL 测井评价研究[D]. 大庆: 东北石油大学, 2022. [ZHANG Y C. Research on CBL/VDL

- logging evaluation of low-density cement bonding quality[D] Daqing: Northeast University of Petroleum, 2022]
- [6] LI G S, SONG X Z, TIAN S C, et al. Intelligent drilling and completion: A review[J]. *Engineering*, 2022, 18: 33–48.
- [7] 李根生, 宋先知, 田守增. 智能钻井技术研究现状及发展趋势[J]. *石油钻探技术*, 2020, 48(1): 1–8. [LI G S, SONG X Z, TIAN S C. Research status and development trends of intelligent drilling technology [J]. *Petroleum Drilling Technology*, 2020, 48 (1): 1–8]
- [8] 邹文波. 人工智能研究现状及其在测井领域的应用[J]. *测井技术*, 2020, 44(4): 6. [ZOU W B. The current research status of artificial intelligence and its application in the field of well logging[J]. *Logging Technology*, 2020, 44 (4): 6]
- [9] ONALO D, ADEDIGBA S, KHAN F, et al. Data driven model for sonic well log prediction[J]. *Journal of Petroleum science & Engineering*, 2018, 170: 1022–1037
- [10] BELOZEROV B, BUKHANOV N, EGOROV D, et al. Automatic well log analysis across priobskoe field using machine learning methods[C]//SPE Russian Petroleum Technology Conference. OnePetro. 2018.
- [11] GKORTSAS V, BOSE S, ZEROUG S. Machine learning for the automated detection of diagnosis-revealing features on leaky flexural wave imager data[C]// 45th Annual Review of Rrogress in Quantitative Nondestructive Evaluation. AIP conference Proceedings. 2019.
- [12] VOLETI D K, REDDICHARLA N, GUNTUPALLI S, et al. Smart way for consistent cement bond evaluation and reducing human bias using machine learning[C]// Abu Dhabi International Petroleum Exhibition & Conference. OnePetro. 2020.
- [13] SANTOS L, TALEGHANI D. Machine learning framework to generate synthetic cement evaluation logs for wellbore integrity analysis[C]// 55th U. S. Rock Mechanics/Geomechanics Symposium. OnePetro. 2021.
- [14] 郑双进, 程霖, 龙震宇, 等. 基于 GA-SVR 算法的顺北区块固井质量预测[J]. *石油钻采工艺*, 2021, 43(4): 467–473. [ZHENG S J, CHENG L, LONG Z Y, et al. Prediction of cementing quality in Shunbei block based on GA-SVR algorithm[J]. *Petroleum Drilling and Production Technology*, 2021, 43(4): 467–473.]
- [15] 宋先知, 姚学喆, 李根生, 等. 基于 LSTM-BP 神经网络的地层孔隙压力计算方法[J]. *石油科学通报*, 2022, 7(1): 12–23. [SONG X Z, YAO X Z, LI G S, et al. A method for calculating formation pore pressure based on LSTM-BP neural network[J]. *Petroleum Science Bulletin*, 2022, 7(1): 12–23.]
- [16] FANG C F, WANG Z, SONG X Z, et al. A novel cementing quality evaluation method based on convolutional neural network[J]. *Applied Sciences*, 2022, 12(21): 10997.
- [17] WANG Z, SONG X Z, LI Z, et al. A data augmentation method of variable density logging image based on GAN[C]// 57th U. S. Rock Mechanics/Geomechanics Symposium. OnePetro. 2023.
- [18] MCCULLOCH W S, PITTS W. A logical calculus of the ideas immanent in nervous activity[J]. *The Bulletin of Mathematical Biophysics*, 1943, 5(4): 115–133.
- [19] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back propagating errors[J]. *Nature*, 1986, 323(6088): 533–536.
- [20] ZHANG H Y, YU L, CHEN Y S, et al. Fast complex-valued CNN for radar jamming signal recognition[J]. *Remote Sensing*, 2021, 13(15): 2867.
- [21] 廖广志, 李远征, 肖立志, 等. 利用卷积神经网络模型预测致密储层微观孔隙结构[J]. *石油科学通报*, 2020, 5(1): 13. [LIAO G Z, LI Y Z, XIAO L Z, et al. Using convolutional neural network models to predict the microscopic pore structure of tight reservoirs [J]. *Petroleum Science Bulletin*, 2020, 5(1): 13.]
- [22] 姬铜芝, 刘正锋, 王子荣, 等. 固井声幅-变密度测井的影响因素分析[J]. *测井技术*, 2002, 26(6): 486–489. [JI T Z, LIU Z F, WANG Z R, et al. Analysis of influencing factors on amplitude variable density logging in cementing sound[J]. *Logging Technology*, 2002, 26(6): 486–489.]
- [23] 潜晓晨. 固井质量评价测井影响因素分析[J]. *西部探矿工程*, 2023, 35(11): 92–94. [QIAN X C. Analysis of factors influencing well cementing quality evaluation and logging[J]. *Western Exploration Engineering*, 2023, 35(11): 92–94.]
- [24] 陈清业. 声幅-变密度测井定量评价固井质量方法研究及应用[D]. 武汉: 中国地质大学(武汉), 2006. [CHEN Q Y. Research and application of quantitative evaluation method for cementing quality using acoustic amplitude variable density logging[D]. Wuhan: China University of Geosciences (Wuhan), 2006.]
- [25] 张明昌. 固井工艺技术[M]. 北京: 中国石化出版社, 2007: 287–289. [ZHANG M C. Well cementing technology[M]. Beijing: China Petrochemical Press, 2007: 287–289.]
- [26] SHELHAMER E, LONG J, DARREL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2017, 39(4): 640–651.
- [27] CHRISTIAN S, VINCENT V, SERGEY I, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. IEEE Xplore. 2016.
- [28] CHRISTIAN S, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. IEEE Xplore. 2015.
- [29] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 38–39. [ZHOU Z H. Machine learning[M]. Beijing: Tsinghua University Press,

- 2016: 38–39.]
- [30] 卢宏涛, 张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31(1): 17. [LU H T, ZHANG Q C. A review of the application research of deep convolutional neural networks in computer vision[J]. Data Collection and Processing, 2016, 31(1): 17]
- [31] 任义丽, 罗路. 卷积神经网络过拟合问题研究[J]. 信息系统工程, 2019, 5: 104. [REN Y L, LUO L. Research on overfitting problem in convolutional neural networks[J]. Information Systems Engineering, 2019, 5: 140–142.]
- [32] CHOLLET F. Deep Learning with Python[M]. Greenwich: Manning, 2021: 99–101.
- [33] BIRD J J, BARNES C M, MANSO L J, et al. Fruit quality and defect image classification with conditional GAN data augmentation[J]. Scientia Horticulturae, 2022, 293: 110684.
- [34] 武中原, 张欣, 张春雷, 等. 基于 LSTM 循环神经网络的岩性识别方法[J]. 岩性油气藏, 2021, 33(3): 120–128. [WU Z Y, ZHANG X, ZHANG C L, et al. Lithology identification based on LSTM recurrent neural network[J]. Lithologic Reservoirs, 2021, 33(3): 120–128.]

(编辑 杨雅露)