

# 基于 CNN-SVM 和集成学习的 固井质量评价方法

肖红, 钱祎鸣

(东北石油大学 计算机与信息技术学院, 黑龙江 大庆 163318)

**摘要:** 为解决固井质量评价问题, 提出一种基于 CNN-SVM 和集成学习的固井质量评价方法. 首先, 针对 DenseNet 模型采取缩减网络层数、增加多尺度卷积层、嵌入卷积注意力模块等改进措施, 以提高模型的训练速度和评价准确率; 其次, 利用 InceptionV1 模块和扩张卷积构建一个模型复杂度相对较小且评价准确率相对较高的 Inception-DCNN 模型; 再次, 优选 3 个经典的卷积神经网络模型 (ResNet50, MobileNetV3-Small, GhostNet), 利用卷积神经网络强大的特征提取能力及支持向量机的结构风险最小化能力, 将上述模型分别与支持向量机组合成新的 CNN-SVM 模型, 以提升模型的泛化能力; 最后, 采用 Bagging 方式将 5 个新的 CNN-SVM 模型集成为一个强学习器, 从而提升评价结果的准确度, 增强模型的抗干扰能力. 实验结果表明, 该方法对测试集中的 3 类评价样本的准确率为 97.69%, 与单个模型和其他方法相比提升了 1~9 个百分点, 验证了采用基于 CNN-SVM 和集成学习的方法进行固井质量评价是切实可行的.

**关键词:** 固井质量评价; 扇区水泥胶结测井; 集成学习; 卷积神经网络; 支持向量机

**中图分类号:** TP391 **文献标志码:** A **文章编号:** 1671-5489(2024)04-0960-11

## Cementing Quality Evaluation Method Based on CNN-SVM and Integrated Learning

XIAO Hong, QIAN Yiming

(School of Computer and Information Technology, Northeast Petroleum University,  
Daqing 163318, Heilongjiang Province, China)

**Abstract:** In order to solve the problem of cementing quality evaluation, we proposed a cementing quality evaluation method based on CNN-SVM and integrated learning. Firstly, the method adopted improvement measures such as reducing the number of network layers, adding multi-scale convolutional layers, and embedding convolutional attention modules for the DenseNet model to improve the training speed and evaluation accuracy of the model. Secondly, the InceptionV1 module and dilated convolution were used to construct an Inception-DCNN model with relatively small model complexity and relatively high evaluation accuracy. Thirdly, three classic convolutional neural network models (ResNet50, MobileNetV3-Small and GhostNet) were selected. By utilizing the powerful feature extraction capabilities of convolutional neural networks and the structural risk

收稿日期: 2023-07-05.

**第一作者简介:** 肖红(1979—), 女, 汉族, 博士, 副教授, 从事智能优化算法的研究, E-mail: xh\_daqing@126.com. **通信作者简介:** 钱祎鸣(1999—), 女, 汉族, 硕士研究生, 从事智能应用技术的研究, E-mail: 1031701181@qq.com.

**基金项目:** 黑龙江省自然科学基金(批准号: LH2019F004).

minimization capabilities of support vector machines, the above models were combined with a support vector machine to synthesize a new CNN-SVM model to improve the generalization ability of the model. Finally, the Bagging method was used to integrate the five new CNN-SVM models into a strong learner, thereby improving the accuracy of the evaluation results and enhancing the anti-interference ability of the model. The experimental results show that the accuracy of the method for 3 types of evaluation samples in the test set is 97.69%, which is 1—9 percentage points higher than that of a single model and other methods, thus verifying the feasibility of using methods based on CNN-SVM and ensemble learning for cementing quality evaluation.

**Keywords:** cementing quality evaluation; sector cement cement logging; integrated learning; convolutional neural network; support vector machine

固井作业是钻井工程中不可或缺的一部分,也是油气井建设的重要环节之一<sup>[1-2]</sup>.固井质量的好坏对油田的经济效益、油气资源的开发进度以及后续的钻井工程、完井工程都有重要影响.因此,固井质量不仅是钻井施工的关键,也是油田勘探开发的必要前提,使得对固井质量资料评价的精度要求逐渐提高<sup>[3]</sup>.

目前,评价固井质量的方法主要包括压力测试、声幅变密度测井(CBL/VDL)和扇区水泥胶结测井(sectoral cement cementation logging, SBT).压力测试在经济可行性方面存在限制,实践经验表明,过高的压力可能导致水泥环被破坏,从而造成经济损失.声幅变密度测井克服了上述缺陷,但只能通过声幅和变密度两条曲线评价固井质量<sup>[4]</sup>,无法反映水泥环环向胶结的均匀性.而扇区水泥胶结测井消除了上述问题的影响,除具备常规声幅变密度测井的功能外,它还能清楚直观地显示扇区水泥成像图<sup>[5]</sup>.因此,扇区水泥胶结测井是目前评价固井质量的主要方法之一.但SBT评价固井质量是一个复杂的过程,通常需要石油领域专家根据多年的经验进行手动评价.随着测井资料的不断增多,难免会存在主观性强、速度慢、效率低等问题.因此,固井质量评价自动化研究备受关注.陈向军等<sup>[6]</sup>提出了用声能法评价固井质量,该方法效率高但精度不够;杜冬楠等<sup>[7]</sup>将影响评价结果的7个固井参数变量作为输入,用LM(levenberg-marquardt)优化的BP神经网络输出固井质量预测结果,但存在学习时间长、识别效率低和隐含层节点数不确定等缺点;Santos等<sup>[8]</sup>利用测井数据使用高斯过程回归算法生成新的特征曲线,并通过新曲线对固井质量进行评价;Liu等<sup>[9-10]</sup>将同一深度点的4个首波幅度作为固井质量的特征属性,用粒子群优化算法(PSO)和遗传算法(GA)对支持向量机(support vector machine, SVM)的参数进行优化,提出了基于PSO-SVM和GA-SVM的固井质量评价模型,但该方法存在耗时过长的问題;郑双进等<sup>[11]</sup>在对固井质量诸多影响因素分析的基础上,采用遗传算法对与支持向量机思路相反的支持向量回归(SVR)参数进行优化,提出了基于GA-SVR的固井质量预测模型,以影响因素的相关数据作为输入量对固井质量进行预测.但SVM依赖于手工特征提取,通常需要领域专家的知识 and 经验进行特征选择和提取.尚福华等<sup>[12]</sup>基于SBT测井,将同一深度点的首波幅度作为输入,采用带有非线性连接权的神经网络实现了对固井质量的评价;Voleti等<sup>[13]</sup>基于CBL/VDL测井,采用随机森林和神经网络实现了对固井质量的自动评价;Fang等<sup>[14]</sup>基于CBL/VDL测井,提出了一种具有不同大小内核的多尺度感知卷积神经网络,该网络用于提取和融合变密度波形图中不同尺度的信息,通过识别变密度波形图评价固井质量.传统卷积神经网络(convolutional neural networks, CNN)可自动从输入数据中提取特征,避免了手动特征提取的繁琐过程,并通过将提取的特征提供给Softmax分类器,完成分类任务.Softmax分类器与SVM分类器的分类能力相比,显然采用核函数实现特征映射的SVM更好.因此,研究者们又提出了在构建CNN时用SVM替换Softmax分类器的方法,该方法目前在故障诊断<sup>[15]</sup>、医学检测<sup>[16]</sup>、人体活动识别<sup>[17]</sup>等多领域应用广泛.

基于SBT测井所得的成像图评价固井质量本质上可归结为图像分类问题,而传统研究方法大多数只采用某一种网络模型,通过改变其中某些参数提升网络性能.但单一网络受其结构的限制,即使通过参数调整,性能仍很难超越其自身的极限.集成学习可综合各弱学习器的优势形成一个强学习

器,从而提升学习器的应用效果.在基于 SBT 测井成像图的固井质量评价领域,基于集成学习的评价方法目前尚未见文献报道.基于此,本文提出一种基于 CNN-SVM 和集成学习的固井质量自动化评价方法.该方法利用 SBT 测井得到的变幅度图(扇区水泥成像图)和变密度波形图作为输入,通过 CNN 自动提取测井成像图的数据特征,使用 SVM 进行分类,最终将 5 个训练好的 CNN-SVM 模型集成为一个强分类器,实现固井质量的自动评价.

# 1 CNN-SVM 模型

## 1.1 CNN 模型

### 1.1.1 改进的 DenseNet-121 模型

DenseNet 模型<sup>[18]</sup>是稠密连接网络,由密集连接块(dense block)和过渡层(transition layer)组成,具有高度的参数共享和特征重用<sup>[19]</sup>.DenseNet-121 模型包含 4 个密集连接块和 3 个过渡层,并以全局平均池化层和全连接层结尾.改进后的 DenseNet-121 网络模型架构如图 1 所示.经仿真实验验证,改进后的模型有效、可靠.改进措施如下:

1) 尽管该模型通过特征重用在很大程度上减少了参数量,但在减少网络层数的仿真测试中发现,网络层数的减少对固井质量的评价结果并没有较大影响,证明 DenseNet-121 网络存在特征冗余.因此,考虑到固井质量的数据特征较简单,并不需要更深的网络获取特征,为提升模型训练效率,本文将网络中 Dense Block 的瓶颈层数目由原来的 6,12,21,16 缩减为 3,6,8,4.

2) 考虑到特征提取时,不仅需要特征数据的小尺度信息(位置和颜色等级),还需要大尺度信息(形状和数目),本文在 Dense Block 结构前添加多尺度卷积层,通过 3 个不同大小的卷积核并行操作,同时检测成像图的大小尺度信息.

3) 将 CBAM(convolutional block attention module)<sup>[20]</sup>注意力机制模块嵌入到模型中的每个 Dense Block 中,通过赋予固井质量特征图中重要信息更大的权重,使 DenseNet 重视对评价有用的特征,从而提高固井质量评价的准确性.

### 1.1.2 Inception-DCNN

本文设计的 Inception-DCNN 模型结构如图 2 所示.网络中各层的含义解释如下.

1) 输入层.让输入层接收 SBT 测井所得的变幅度图和变密度波形图对应的特征向量,从而进行下一步的特征提取.

2) Block 块.引入扩张卷积(dilated convolution, DC)、批量归一化(batch normalization, BN)和 ReLU 激活函数提高模型的表达能力.DC 通过增加卷积核的感受野,使其能捕获更大范围的上下文信息,同时保持网络的计算复杂度相对较低.BN 可以利用小批量上的均值和方差调整上一卷积操作的输出,通过减少网络中间层的内部协变量偏移使网络层之间的分布更稳定<sup>[21]</sup>,从而加速训练过程,增强模型的泛化能力.ReLU 激活函数可以增强网络的非线性能力,使其能更好地拟合复杂的数据模式和特征.最后通过最大池化(MaxPool)降低特征图的尺寸,从而减少网络中的参数量,减少过拟合的风险.

3) Inception 块.通过 InceptionV1 块提取深层特征图中的不同尺度信息,使网络能更好地捕捉固井质量数据图的细节和全局信息,从而增强了网络的表达能力.

4) 输出层.输出层中不同的神经元对应不同的固井质量类别.

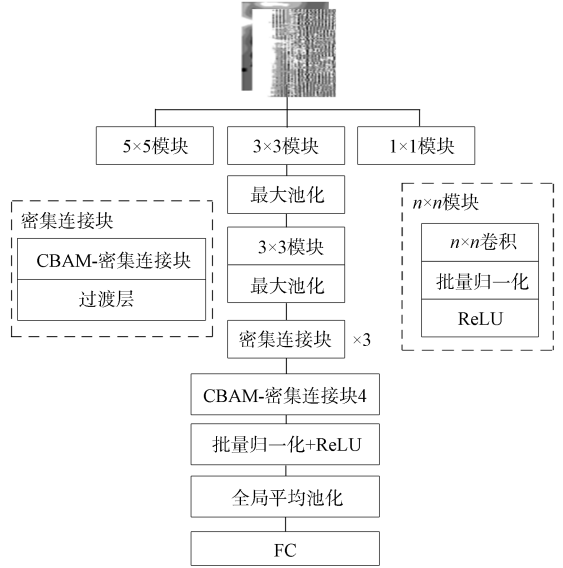


图 1 改进的 DenseNet 网络模型架构

Fig. 1 Architecture of improved DenseNet network model

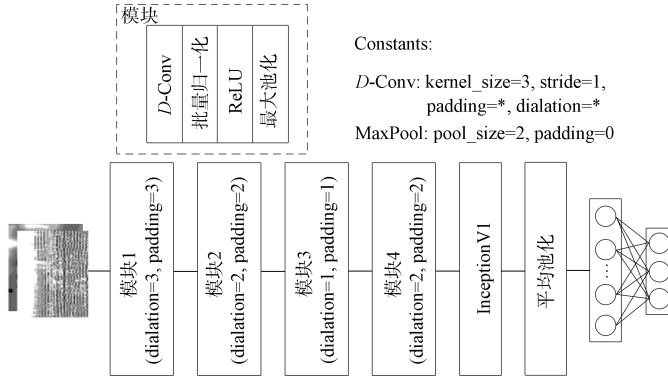


图 2 Inception-DCNN 模型架构

Fig. 2 Architecture of Inception-DCNN model

1. 1. 3 ResNet50

ResNet<sup>[22]</sup> 是一种深度卷积神经网络, 该网络打破了传统的层与层之间的直接连接方式, 通过引入残差连接解决深层网络中的梯度消失问题, 同时提高了模型的表达能力和学习能力. 残差结构如图 3 所示.

本文选择经典卷积神经网络 ResNet50 调整优化并进行训练. ResNet50 属于 ResNet 系列模型, 共包含 16 个残差单元, 由 50 层组成, 包括 49 个卷积层和 1 个全连接层. 引入的残差结构允许直接将输入特征映射添加到后续的特征映射中, 使固井质量的数据信息能在网络中更快地传递.




图 3 残差结构

Fig. 3 Residual structure

1. 1. 4 MoblieNetV3-Small

MobileNetV3<sup>[23]</sup> 是一种轻量级卷积神经网络模型, 它继承了 MobileNetV1 的深度可分离卷积和 MobileNetV2 具有的线性瓶颈的倒残差结构, 并在此基础上用 Net Adapt 算法自动获取卷积核和通道的最佳数量; 在倒残差结构引入挤压和激励注意力模块(SE), 组成 bneck 结构; 同时使用新的激活函数 hard-swish(x)代替 ReLU6, 计算公式为

$$\text{hard-swish}(x) = x \cdot \text{ReLU6}(x + 3) / 6, \tag{1}$$

其中 ReLU6(x)函数为将输入值限制在 0~6 内的 ReLU 函数变体. 本文采用 bneck 和通道数量更少的 MobileNetV3-Small 作为固井质量评价的训练模型.

1. 1. 5 GhostNet

GhostNet<sup>[24]</sup> 是一种轻量级深度卷积神经网络模型, 旨在保持模型的高效性能和准确性的同时, 减少模型的计算和存储开销. GhostNet 引入 Ghost 模块, 通过少量的计算即可获得大量特征图. Ghost 模块结构如图 4 所示.




图 4 Ghost 模块结构

Fig. 4 Structure of Ghost module

首先将输入特征图通过少量卷积得到部分特征图 Y\*, 然后将 Y\* 中的每个通道进行简单的线性

操作  $\Phi$  得到 Ghost 特征图  $y^*$ , 其中线性操作采用计算成本较低的深度可分离卷积操作, 最后将部分特征图  $Y^*$  与 Ghost 特征图  $y^*$  进行拼接, 得到最终的输出特征<sup>[25]</sup>.

### 1.2 支持向量机

支持向量机是一种用来解决二分类问题的监督学习算法, 该算法采用结构风险最小化原则, 具有较好的分类性能和泛化能力, 并且在处理复杂问题上取得了显著成果<sup>[26]</sup>. 其基本原理是通过寻找最优超平面进行分类, 该超平面不仅能将不同类别的样本完全分开, 还能使距离超平面最近的训练样本点所组成的支持向量与该划分超平面之间的间隔最大化.

在多分类问题中, 常使用多个二分类器的组合方法进行处理. 这些方法包括一对一(one-vs-one, OVO)、一对多(one-vs-rest, OVR)、层次支持向量机(H-SVMs)等. 对于  $K$  个类别的问题, OVO 方法需要构建  $K(K-1)/2$  个 SVM 分类器, 每个分类器专门用于区分其中两个类别之间的样本; OVR 方法将一个类别作为正类, 其他所有类别作为负类, 只需构建  $K$  个 SVM 分类器即可, 但结果可能产生冲突; H-SVMs 首先将所有类别分成两个子类, 再将子类进一步划分为两个次级子类, 如此循环, 直到得到一个单独的类为止.

### 1.3 CNN 与 SVM 级联模型

传统卷积神经网络采用的经验风险最小化原则为

$$R_{emp}(f) = \frac{1}{N} \sum_{i=1}^N L(y_i, f(x_i)), \tag{2}$$

其中  $y_i$  表示样本真实值,  $f(x_i)$  表示样本预测值,  $L(y_i, f(x_i))$  表示损失函数<sup>[27]</sup>. 根据大数定律, 只有当样本容量  $N$  接近无穷大时, 经验风险  $R_{emp}(f)$  才接近理想值. 但现实中的样本数据通常有限, 经验风险最小化原则很容易出现过拟合问题. SVM 采用的结构风险最小化原则可在一定程度上解决过拟合问题, 用公式表示为

$$R_{svm}(f) = R_{emp}(f) + \lambda J(f), \tag{3}$$

其中  $J(f)$  为模型的复杂度,  $\lambda$  为用于权衡经验风险和模型复杂度的系数. 因此, 本文基于 CNN 强大的特征提取能力及 SVM 结构风险最小化能力, 构建 CNN-SVM 的级联模型处理固井质量的评价问题, 其结构如图 5 所示.

首先利用 CNN 中的卷积和下采样等操作从 SBT 测井成像图中自动提取对评价任务有用的信息, 然后用 SVM 取代 CNN 的输出层, 将自动提取的特征向量作为 SVM 的输入, 采用 OVO 方法对其进行训练, SVM 的输出即为固井质量的三类评价类别. 因此, 将上述改进的 DenseNet, Inception-DCNN, Resnet50, MobileNetV3-Small 和 GhostNet 模型分别与 SVM 组合, 得到改进的 DenseNet-SVM, Inception-DCNN-SVM, ResNet50-SVM, MobileNetV3-Small-SVM 和 GhostNet-SVM 模型.

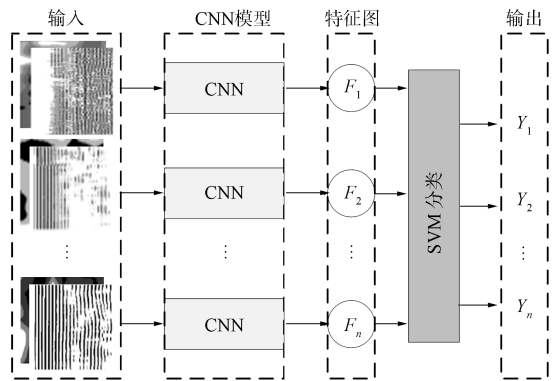


图 5 CNN-SVM 级联模型结构

Fig. 5 Structure of CNN-SVM cascade model

## 2 基于 CNN-SVM 的集成学习模型

### 2.1 集成学习

集成学习的主要思想是将多个网络模型组合形成一个更强大的模型, 以提高模型分类准确性及泛化能力. 集成学习的方法主要有 Bagging, Boosting 和 Stacking 三类<sup>[28]</sup>. Bagging 方法利用自助采样法为每个模型抽取不同的训练集, 然后对这些模型的训练结果进行综合; Boosting 方法将网络模型串联, 使每个模型的训练均依赖于前一个模型的训练结果; Stacking 方法通过将多个模型的训练结果作为新的训练数据, 再训练一个元学习器进行集成.



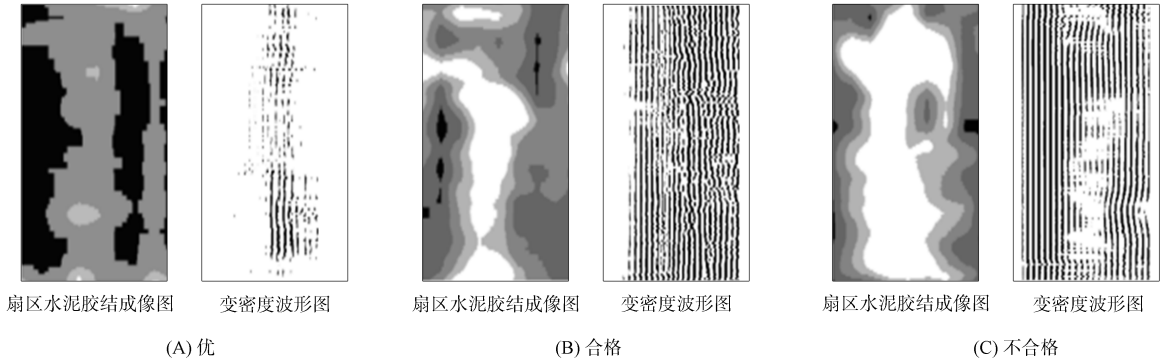


图 7 数据集图像示例

Fig. 7 Example of dataset image

和变密度波形图进行切分, 最终得到 12 222 个样本层张量(优 4 417 个, 合格 2 937 个, 不合格 4 868 个). 将整个数据集按 7 : 1.5 : 1.5 划分为 3 个相互独立且互不交叉的训练集、验证集、测试集, 最终得到 8 721 个训练集样本、1 649 个验证集样本和 1 646 个测试集样本. 将数据集中的扇区水泥胶结成像图和变密度波形图分别调整到 150×150 像素后按通道方向进行拼接得到模型的输入特征图.

### 3.2 实验评估指标

本文采用以下实验评估指标: 混淆矩阵、精确率( $P$ )、召回率( $R$ )、 $F_1$  分数和准确率( $ACC$ ). 其中混淆矩阵用于比较评价结果与实际标签的信息, 如表 1 所示, 表 1 中 TP, FP, FN, TN 分别表示真正类、假正类、假负类和真负类样本的数量. 虽然表 1 显示的为二分类, 但将正例视为评价结果(优, 合格, 不合格)中的某一类, 将负例视为评价结果的其他两类, 即可将二分类问题转化为本文的三分类问题. 根据这些值即可计算精确率、召回率、 $F_1$  分数和准确率:

$$P = \frac{TP}{TP + FP}, \quad (7)$$

$$R = \frac{TP}{TP + FN}, \quad (8)$$

$$F_1 = 2 \cdot \frac{PR}{P + R}, \quad (9)$$

$$ACC = \frac{TP + TN}{TP + FP + TN + FN}. \quad (10)$$

表 1 评价结果混淆矩阵

Table 1 Evaluation results of confusion matrix

真实情况	预测情况	
	正例	反例
正例	TP	FN
反例	FP	TN

### 3.3 实验平台及参数设置

本文实验的硬件条件为英特尔第八代 i5 CPU, 频率为 2.80 GHz, 内存为 16 GB, 所用 GPU 的规格为 NVIDIA GeForce RTX 2070, 内存为 8 GB. 实验软件平台为 PyCharm, 采用 Python3.8 编程语言实现, 在 Windows10 操作系统下运行, 使用的深度学习框架为 Pytorch.

本文网络模型参数设置如下: batch\_size=32, 采用 Adam 优化器, 初始学习率设为 0.001, 初始学习率衰减系数为 0.005, 随迭代次数的不同而减小; 权重衰减率为 0.000 1; SVM 采用高斯核函数, 系数为 0.001, 错误项的惩罚系数为 1.

### 3.4 CNN-SVM 级联模型实验验证

为验证使用 SVM 替换 CNN 输出层的改进效果, 针对上述改进的 DenseNet, Inception-DCNN, ResNet50, MobileNetV3-Small 和 GhostNet 5 个模型进行消融实验, 以考察 CNN-SVM 级联模型的准

准确率、精确率、召回率和  $F_1$  分数的变化情况。首先, 将上述 5 个模型在多次有放回的随机抽样所得的数据集上进行训练, 实验结果列于表 2。由表 2 可见, 针对固井质量评价问题, 采用改进的 DenseNet 模型准确率和  $F_1$  分数最高, 分别为 95.86% 和 93.80%。

表 2 5 种 CNN 模型的固井质量评价效果

Table 2 Cementing quality evaluation effect of five CNN models

模型	精确率	召回率	$F_1$	准确率
改进 DenseNet	92.83	94.80	93.80	95.86
Inception-DCNN	90.54	93.05	91.78	93.44
ResNet50	88.05	90.59	89.30	91.50
MobileNetV3-Small	89.17	90.90	90.03	92.41
GhostNet	87.37	90.51	88.91	90.88

CNN-SVM 级联模型的固井质量评价效果列于表 3。由表 3 可见: 改进的 DenseNet-SVM 模型性能最好, 准确率为 96.41%,  $F_1$  分数为 95.45%, 与表 2 中的改进 DenseNet 模型相比, 准确率提升了 0.55 个百分点,  $F_1$  分数提升了 1.65 个百分点; 表 3 中其他模型与表 2 中对应的模型相比, 准确率均约提高了 1.4 个百分点,  $F_1$  分数提高了 1.8 个百分点。实验结果表明, 使用 SVM 代替 CNN 的输出层是切实有效的。

表 3 5 种 CNN-SVM 模型的固井质量评价效果

Table 3 Cementing quality evaluation effect of five CNN-SVM models

模型	精确率	召回率	$F_1$	准确率
改进 DenseNet-SVM	94.65	96.26	95.45	96.41
Inception-DCNN-SVM	92.74	94.36	93.54	95.08
ResNet50-SVM	89.63	91.67	90.64	92.71
MobileNetV3-Small-SVM	91.89	93.77	92.82	94.41
GhostNet-SVM	89.56	91.55	90.54	92.65

图 8 和图 9 分别给出了改进 DenseNet 和改进 DenseNet-SVM 模型在测试集上的混淆矩阵, 其中横坐标对应模型的预测类别, 纵坐标对应真实类别。由图 8 和图 9 可见, 3 类结果均有误差, 且类别为优和不合格的样本更多被模型误判为合格。




图 8 改进 DenseNet 模型在测试集上的混淆矩阵

Fig. 8 Confusion matrix of improved DenseNet model on test set




图 9 改进 DenseNet-SVM 模型在测试集上的混淆矩阵

Fig. 9 Confusion matrix of improved DenseNet-SVM model on test set

### 3.5 基于集成学习的实际应用效果对比

图 10 为集成了改进 DenseNet-SVM, Inception-DCNN-SVM, ResNet50-SVM, MobileNetV3-Small-SVM 和 GhostNet-SVM 5 个模型的强学习器在测试集上的混淆矩阵, 评价结果为优的准确率为 98.47%, 合格的准确率为 97%, 不合格的准确率为 97.23%。

为验证本文方法的有效性, 将其与表 2 中性能最好的 CNN 模型、表 3 中性能最好的 CNN-SVM 模型、支持向量机以及文献[14]使用的具有不同大小内核的多尺度感知卷积神经网络模型进行对比, 结果列于表 4。由表 4 可见, 本文方法在精确率、召回率、 $F_1$  分数和准确率等指标上均高于其他方法,

本文方法得到的评价准确率达 97.69%， $F_1$  分数为 97.08%，且准确率和  $F_1$  分数相比于以上 4 种方法分别提高了约 4.5 个百分点和 5.7 个百分点。实验结果表明，本文方法对固井质量评价效果良好。

表 4 不同模型的性能对比

Table 4 Performance comparison of different models

模型	精确率	召回率	$F_1$	准确率
SVM	84.91	88.52	86.60	88.83
改进 DenseNet	92.83	94.80	93.80	95.86
改进 DenseNet-SVM	95.22	96.58	95.89	96.71
文献[14]	88.01	90.55	89.26	91.43
本文	96.61	97.57	97.08	97.69

在测井解释过程中，生成的测井成像图可能会受干扰和失真的影响。因此，为评估本文方法在这种情况下评价能力，通过在扇区水泥胶结成像图与变密度波形图中添加 10% 的高斯噪声，验证模型的稳定性和泛化能力，实验结果列于表 5。由表 5 可见，本文提出的基于 CNN-SVM 和集成学习的方法具有更强的抗干扰能力，即使测井成像图失真并有噪声，仍可以准确地评价固井质量。

表 5 添加噪声后不同模型的性能对比

Table 5 Performance comparison of different models after adding noise

模型	精确率	召回率	$F_1$	准确率
SVM	82.43	84.95	83.67	86.27
改进 DenseNet	88.09	90.42	89.24	91.43
改进 DenseNet-SVM	92.43	94.73	93.56	94.96
文献[14]	83.06	86.11	83.94	88.59
本文	93.32	95.28	94.29	95.57

### 3.6 实验结果分析

由表 2 和表 3 可见，基于 CNN-SVM 级联模型的评价效果最好，这是因为传统 CNN 具有强大的特征提取能力，能自动学习和提取输入数据中的高级特征，从而捕捉到测井成像图的空间局部性和层次结构，使模型能更好地理解并表示固井质量的数据图像，但在数据样本容量有限时，传统 CNN 易出现过拟合现象，导致模型在训练集上表现良好，在测试集上表现较差。而 SVM 可有效地处理小样本数据集，通过间隔最大化的原则，能在训练过程中有效控制模型的复杂度，从而降低过拟合的风险，因此使用 SVM 代替 CNN 中输出层的 CNN-SVM 模型能在固井质量评价方面性能更优。由图 8~图 10 的混淆矩阵可见，测试集中固井质量评价的误差主要出现在类别优与合格、合格与不合格之间，原因在于类别为合格的数据特征与其他两类特征较相似，会使模型产生一定的混淆。表 4 中 SVM 的评价效果最差，原因是 SVM 是一种基于特征的分类器，它依赖于事先提取的手工设计特征，且对空间特征的捕捉能力相对较弱，导致对测井成像图的空间特征利用不充分。结合表 4 和表 5 的结果可见，本文方法在原数据集和添加了噪声的数据集上都表现较好，这是因为本文方法利用了 5 种 CNN-SVM 模型的不同优点，可减少单个模型的偏差和方差，从而提高了整体的评价准确性；通过多个模型的集体决策，减少了对噪声的敏感性，且 SVM 通过最大化支持向量到分类超平面的间隔，同样可减少了对噪声数据的敏感性，使其拥有强大的鲁棒性和泛化能力，从而提高了网络的评价能力。

综上所述，为解决固井质量的评价问题，本文提出了一种基于 CNN-SVM 和集成学习的固井质量评价方法，将改进 DenseNet, Inception-DCNN, ResNet50, MobileNetV3-Small 和 GhostNet 5 个模型的输出层替换为 SVM，组合成 5 个新的 CNN-SVM 模型，既有效利用了 CNN 对扇区水泥胶结成像图




图 10 本文模型在测试集上的混淆矩阵

Fig. 10 Confusion matrix of proposed model on test set

与变密度波形图的特征提取能力,又结合了SVM控制模型复杂度、减少过拟合风险的能力;最终通过充分利用5个CNN-SVM模型各自的优点,集成了一个具有更高评价准确率和更强抗干扰能力的强学习器。该学习器既可避免人工评价带来的主观性,又能显著提升评价效率,从而为固井质量评价开辟了一条新途径。

### 参 考 文 献

- [1] 胡洪瑾,李登华,赵凯,等.我国油气资源量-储量-产量关系解析:兼评全国油气资源评价发展方向[J].石油实验地质,2023,45(2):222-228.(HU H J, LI D H, ZHAO K, et al. Relationship among Oil and Gas Resources, Reserves and Production in China and Suggestions for the Development Direction of National Oil and Gas Resource Assessment [J]. Petroleum Geology & Experiment, 2023, 45(2): 222-228.)
- [2] 周龙,谢银涛,徐景林,等.提高固井质量的措施[J].石化技术,2022,29(12):25-27.(ZHOU L, XIE Y T, XU J L, et al. Measures to Improve Cementing Quality [J]. Petrochemical Industry Technology, 2022, 29(12): 25-27.)
- [3] 吴天乾,宋文宇,谭凌方,等.超低密度水泥固井质量评价方法[J].石油钻探技术,2022,50(1):65-70.(WU T Q, SONG W Y, TAN L F, et al. Evaluation Method for Cementing Quality of Ultra-Low-Density Cement [J]. Petroleum Drilling Techniques, 2022, 50(1): 65-70.)
- [4] 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. CBL/VDL Logging Evaluation on Bonding Quality of the Low Density Slurry [D]. Daqing: Northeast Petroleum University, 2022.)
- [5] 陈金宏,王静,刘江伟,等.八扇区水泥胶结测井仪刻度及测井数据处理[J].中国煤层气,2021,18(5):33-37.(CHEN J H, WANG J, LIU J W, et al. Calibration Method and Data Procession of SBT Logging [J]. China Coalbed Methane, 2021, 18(5): 33-37.)
- [6] 陈向军,李维彦,杨顺辉.固井质量评价面临的新问题及思路[J].测井技术,2015,39(1):1-5.(CHEN X J, LI W Y, YANG S H. New Problems & Measures in Interpreting Cement Sheath Evaluation [J]. Well Logging Technology, 2015, 39(1): 1-5.)
- [7] 杜冬楠,郑双进,赫英状,等.基于LM优化神经网络的固井质量预测方法——以顺北油田X区块为例[J].石油地质与工程,2021,35(3):123-126.(DU D N, ZHENG S J, HE Y Z, et al. Cementing Quality Prediction Method Based on LM Optimization Neural Network: By Taking X Block of Shunbei Oilfield as an Example [J]. Petroleum Geology and Engineering, 2021, 35(3): 123-126.)
- [8] SANTOS L, DAHI T A. Machine Learning Framework to Generate Synthetic Cement Evaluation Logs for Wellbore Integrity Analysis [C]//ARMA US Rock Mechanics/Geomechanics Symposium. [S. l.]: ARMA, 2021: 2543-2549.
- [9] LIU J C, WANG H T, ZENG P S, et al. Intelligent Evaluation Model for Cementing Quality Based on PSO-SVM and Application [J]. Applied Mechanics and Materials, 2011, 1366: 4293-4299.
- [10] LIU J C, ZENG P S, YUAN Z G, et al. Intelligent Evaluation Model for Cementing Quality Based on GA-SVM and Application [J]. Applied Mechanics and Materials, 2011, 121126: 2730-2734.
- [11] 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. Predicting the Cementing Quality in Shunbei Block Based on GA-SVR Algorithm [J]. Oil Drilling & Production Technology, 2021, 43(4): 467-473.)
- [12] 尚福华,于志东,曹茂俊.前馈神经网络在水泥胶结识别中的应用[J].计算机技术与发展,2013,23(9):223-226.(SHANG F H, YU Z D, CAO M J, et al. Application of Feedforward Neural Network in Cement Bond Identification [J]. Computer Technology and Development, 2013, 23(9): 223-226.)
- [13] 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 and Conference. [S. l.]: SPE, 2020: 202742-1-202742-12.
- [14] 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): 10997-1-10997-15.
- [15] FAN H W, XUE C Y, MA J T, et al. A Novel Intelligent Diagnosis Method of Rolling Bearing and Rotor

- Composite Faults Based on Vibration Signal-to-Image Mapping and CNN-SVM [J]. *Measurement Science and Technology*, 2023, 34(4): 044008-1-044008-15.
- [16] SIDDIQUI S S S A, HYDER R T S H, MANJARAMKAR A, et al. Automatic Detection of Lung Diseases Using CNN and SVM [C]//2023 3rd International Conference on Intelligent Technologies (CONIT). Piscataway, NJ: IEEE, 2023: 1-5.
- [17] CHOUDHARY P, PATHAK P, CHAUBEY A. Activity Recognition System via Unification of CNN and SVM in Complex Domain [C]//2023 6th International Conference on Information Systems and Computer Networks (ISCON). Piscataway, NJ: IEEE, 2023: 1-6.
- [18] LIAO T T, LI L, OUYANG R S, et al. Classification of Asymmetry in Mammography via the DenseNet Convolutional Neural Network [J]. *European Journal of Radiology Open*, 2023, 11: 100502-1-100502-7.
- [19] 刘想德, 王芸秋, 蒋勤, 等. 语音识别中的 DenseNet 模型研究 [J]. *重庆邮电大学学报(自然科学版)*, 2022, 34(4): 604-611. (LIU X D, WANG Y Q, JIANG Q, et al. Research on the DenseNet Model for Speech Recognition [J]. *Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition)*, 2022, 34(4): 604-611.)
- [20] WANG W, TAN X A, ZHANG P, et al. A CBAM Based Multiscale Transformer Fusion Approach for Remote Sensing Image Change Detection [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 6817-6825.
- [21] 刘霞, 孙英杰. 基于融合残差注意力机制的卷积神经网络地震信号去噪 [J]. *吉林大学学报(地球科学版)*, 2023, 53(2): 609-621. (LIU X, SUN Y J. Seismic Signal Denoising Based on Convolutional Neural Network with Residual and Attention Mechanism [J]. *Journal of Jilin University (Earth Science Edition)*, 2023, 53(2): 609-621.)
- [22] FAN Z, LIN H B, LI C, et al. Use of Parallel ResNet for High-Performance Pavement Crack Detection and Measurement [J]. *Sustainability*, 2022, 14(3): 1825-1-1825-21.
- [23] BI C G, XU S Z, HU N, et al. Identification Method of Corn Leaf Disease Based on Improved Mobilenetv3 Model [J]. *Agronomy*, 2023, 13(2): 300-1-300-17.
- [24] LANG X M, HAN F C. MFL Image Recognition Method of Pipeline Corrosion Defects Based on Multilayer Feature Fusion Multiscale GhostNet [J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-8.
- [25] 曹远杰, 高瑜翔. 基于 GhostNet 残差结构的轻量化饮料识别网络 [J]. *计算机工程*, 2022, 48(3): 310-314. (CAO Y J, GAO Y X. Lightweight Beverage Recognition Network Based on GhostNet Residual Structure [J]. *Computer Engineering*, 2022, 48(3): 310-314.)
- [26] 李广, 丁迪, 石福升, 等. 基于支持向量机的可控源电磁数据智能识别方法 [J]. *吉林大学学报(地球科学版)*, 2022, 52(3): 725-736. (LI G, DING D, SHI F S, et al. Intelligent Recognition of Controlled-Source Electromagnetic Data by Support Vector Machine [J]. *Journal of Jilin University (Earth Science Edition)*, 2022, 52(3): 725-736.)
- [27] 李尤慧子, 俞海涛, 殷昱煜, 等. 基于超级账本的集群联邦优化模型 [J]. *计算机工程*, 2023, 49(1): 22-30. (LI Y H Z, YU H T, YIN Y Y, et al. Cluster Federated Optimization Model Based on Hyperledger Fabric [J]. *Computer Engineering*, 2023, 49(1): 22-30.)
- [28] 艾成豪, 高建华, 黄子杰. 混合特征选择和集成学习驱动的代码异味检测 [J]. *计算机工程*, 2022, 48(7): 168-176. (AI C H, GAO J H, HUANG Z J. Code Smell Detection Driven by Hybrid Feature Selection and Ensemble Learning [J]. *Computer Engineering*, 2022, 48(7): 168-176.)

(责任编辑: 韩 啸)