

岩性智能识别技术发展现状与实践

黄麟淇,魏云峰,李夕兵

(中南大学资源与安全工程学院)

摘要:岩性识别技术是分辨目标岩石类型,从而掌握地质构造特征和矿产分布的有力手段。传统岩性识别技术(如岩石手标本/薄片显微鉴定、遥感法和测井法等)存在主观性强、效率低、抗干扰性弱、工艺复杂等局限。基于传统机器学习的岩性自动化识别方法虽一定程度上突破了传统岩性识别技术的瓶颈,但丰富的岩性特征信息难以被充分利用。基于深度学习的岩性智能识别技术逐渐表现出优异性能。基于现有深度学习模型,详细介绍 VGG-16 卷积神经网络通过迁移学习来识别岩性的技术流程,该技术不但可以降低对岩性标注数据量的依赖,还能通过自动捕捉岩性的高维特征信息来增加识别的泛化能力。此外,岩性智能识别技术将会在以下方向进行创新发展:构建包含多矿种、多尺度的标准岩石图像数据库;开发现场实时岩性识别系统,轻量化处理识别模型;融合岩石视觉、光谱、物理属性等多维度的数据信息,通过协同分析方法来提升智能识别模型的可靠性;构建矿山岩性动态感知系统,推动精准采矿向全流程智能化升级。

关键词:矿山勘探;岩性识别;人工智能;深度学习;VGG-16;机器学习

中图分类号:TD313

文献标志码:A

文章编号:1001-1277(2025)07-0001-13

doi:10.11792/hj20250701

引 言

矿产资源开采是经济社会发展的重要保障。岩性识别技术可以对矿物进行准确评估,确定资源的可开采储量和空间分布,从而指导矿山前期勘探工作的方向和定位。另外,通过岩性识别技术能够掌握矿产性质,为矿石开采及分选方案的制定提供有力的数据支撑。

岩性识别技术经历了漫长的发展过程,从最早的观察与分类逐步发展到利用先进的科学仪器和技术来获得更准确的识别结果。在地质学早期发展阶段,科研人员便已提出岩石岩性识别概念,随着对地球内部结构和岩石形成认识的不断深入,科学家开始尝试通过观察和分析岩石的物理、化学和结构特征来推断其性质和成因^[1-2]。19 世纪,英国著名地质学家查理士·莱尔提出了“现在是认识过去的钥匙”的原则,强调通过观察现代岩石和地质过程来理解地球历史和岩石形成。20 世纪初,岩石薄片观察技术的发展为岩石岩性识别提供了重要工具。利用光学显微镜观察岩石薄片的矿物组成、纹理和结构特征,可以确定岩石的类型和演化历史^[3]。随着科学技术的进步,岩性识别方法不断丰富和发展,科学仪器和识别技术如扫描电子显微镜(SEM)、X 射线衍射(XRD)、电子探

针(EPMA)等的应用,能够更准确、更快地分析岩石的组成、结构和化学特征^[4-6]。近年来,计算机技术的飞速发展帮助岩性识别技术逐渐从传统的岩性识别技术向智能识别过渡,科研人员可以利用机器学习、深度学习等智能算法来解决岩石岩性识别这一难题^[7-10]。岩性识别技术发展至今的一般通用技术方法统计如图 1 所示。

传统岩性识别技术包括岩石手标本/薄片显微鉴定、测井技术、重磁法、地震法和遥感法等,通常传统方法对使用人员技术水平要求较高,需要其具备充分的专业知识或设备操作能力,其次还要有先进精准的装置设备。尽管传统方法发展至今已较成熟地应用于工程现场,但仍然存在某些困境短板,如人工依赖性强、判读有偏差、经济成本高、环境干扰不可控等。为此,研究人员结合人工智能技术,提出基于各种智能算法的岩性识别技术,旨在既吸纳传统识别方法的优点,又利用智能算法的优势弥补传统识别短板。智能算法包括机器学习和深度学习,其中,深度学习是机器学习的一个拓展分支。K-means 聚类分析法、贝叶斯分析法、随机森林、支持向量机等机器学习算法被应用于地球物理测井数据的分析,实现岩性分类预测^[11-15]。深度学习主要采用迁移学习方法来实现岩性的识别功能,通过微调或特征提取的手

收稿日期:2025-04-23; 修回日期:2025-05-18

基金项目:国家自然科学基金项目(52174098)

作者简介:黄麟淇(1987—),女,教授,博士,从事矿山微震监测和安全预警等研究工作;E-mail:huanglinqi@csu.edu.cn



图1 岩性识别技术类别

Fig. 1 Lithology identification technology category

段改进已有的卷积神经网络(CNN)模型,使之适用于岩性识别领域^[16-18]。利用深度学习方法来识别岩性,一般依靠岩石的手标本或薄片图像集来训练网络模型,充分发挥了深度学习在图像识别上的强大处理能力。

1 传统岩性识别技术

传统岩性识别技术可以分为岩石薄片图像人工识别法、手标本图像识别法、测井数据识别法及其他现代技术识别法。岩石薄片图像人工识别法是将工程现场获取到的岩石制备成合适的岩石薄片^[19],然后利用偏光显微镜观察样品薄片,通过分析岩石矿物的主体结构、组成成分和晶体特性,来确定岩石类别和成因特征,实现对岩石岩性的识别分类,如图2-a)所示。岩石薄片图像人工识别法被广泛应用于地质学领域,通过该方法能够确定地层的岩性、结构及组成成分,了解地质层序和矿产赋存形式。




图2 偏光显微镜下的岩石薄片及手标本图像

Fig. 2 Images of rock sections and hand specimens under a polarizing microscope

手标本图像识别法是指专家学者观察如图2-b)所示的石灰岩标本图像,从岩石的颜色、结构、构造及矿物成分等特征要素进行岩性识别分类。针对三大类岩石不同特点,人工鉴定步骤存在不同。对于岩浆岩,最显著特征就是颜色,浅色一般是酸性岩或中性岩,深色为基性岩或超基性岩,因此第一步就是观察

其颜色,而后观察结构与构造,再其次观察其矿物成分,最后才是岩石定名,识别分类完成。对于沉积岩,由于其主要分布在地表,因此种类繁多,性质多变,一般具有碎屑结构、泥质结构、化学和生物化学结构;通常先观察其层理特征,将岩浆岩与变质岩区分开来,再根据成因、结构和矿物成分等要素对其进行细化分类。变质岩手标本样品鉴定与岩浆岩的鉴别步骤类似,主要观察其构造、结构和矿物成分;首先通过对构造的观察初步鉴定其类别,再根据成分含量和变质岩特定矿物来对其定名。三大类岩石在颜色、结构、构造及矿物成分等特征信息上存在明显差异,但是对于三大类岩石中相近的岩石,其特征信息有细微差别,这对识别人员的专业知识及专注力要求较高,因此在识别过程中,容易发生误判且识别效率不高。

测井数据识别法依靠各种专业设备进行随钻测井,继而获取岩层的物理特性,如电阻率、天然放射性、声速、密度和孔隙率等,所有特征参数对每类岩层的岩性都有响应,因此传统测井方法通过对测井曲线进行解释分析来实现岩性的识别工作。例如:李哲等^[20]基于钻孔轨迹、自然电位、电阻率、自然伽马等测井参数,对新景矿15121工作面的钻孔岩性进行了识别,并且利用测井信息交会图和钻孔视频成像对煤体的结构进行了精准的识别。王伟等^[21]采用伽马射线测井技术对鄂尔多斯盆地西南缘白垩系进行岩性识别,利用自然伽马对短源距测井曲线进行修正,从而提高对泥岩、粉砂岩和砂岩的识别。OKEUGO等^[22]根据测井曲线伽马射线与泊松阻抗的交叉图(如图3所示),划分出了净砂、砂质页岩、泥质砂岩和页岩4种岩相类型,发现砂岩岩相具有较低的伽马值和PI值,而页岩岩相相对较高,另外显示了页岩中优质砂(砂带)、优质砂(砂-页岩带)和劣质砂(泥-砂带)。测井技术




图 3 A 井砂岩测井曲线伽马射线与泊松阻抗交叉图^[22]
Fig. 3 Poisson impedance cross view of the sandstone logging profile of Well A

不但可以根据岩层的物理特性来进行识别,还发展出另外一种方法,即矿物元素识别法,由于不同岩性的岩石拥有各自特定的元素成分,因此科研人员可以运用现代科学技术来解析岩石的组成元素,以解决岩性分类问题。具体地,在矿山前期勘探工程中,随着钻井技术与工艺的不断革新,PDC 钻头、空气钻井等高效钻井方法逐步替代了传统技术,显著提升了钻孔效率。然而,新技术在破碎岩层时会产生细碎且混杂的

岩屑,导致基于岩屑样品的岩性识别精度下降,进而造成地层岩性的误判,对后续资源评估与开采设计产生潜在风险。为此,元素录井技术应运而生,它能够针对钻井时产生的岩屑所含元素进行量定,从而识别各岩层的岩性^[23]。目前,X 射线荧光元素录井技术简称 XRF(X-Ray Fluorescence,XRF),应用最为广泛,其传统解释方法有图版法、曲线法、图谱法和定量解释法,同时也有研究人员将 XRF 与机器学习融合使用^[24-25]。采用元素光谱分析方法,通过高能 X 射线直射岩屑样品,让各岩屑元素原子经历稳定态—激发态—稳定态的动态平衡过程,这个过程中释放出的能量就是 X 射线荧光。对 X 射线荧光的波长和强度进行检测可以获知组成岩屑的元素类型和各元素的相对含量,帮助识别岩屑样品的岩性,其中,波长有助于确定岩屑样品的元素类型,强度有助于确定元素相对含量。YARBROUGH 等^[26]就使用了 XRF 来分析北达科他州威利斯顿盆地下部 Bakken 组和 Three Forks 组的 8 个岩芯剖面,并创建该地区的化学地层测井曲线,从而可以识别该地层的岩性并根据其元素比数量进行评估。Charlotte 1-22H 井的元素分析结果如图 4 所示。




图 4 Charlotte 1-22H 元素比说明^[26]
Fig. 4 Elemental ratios of Well Charlotte 1-22H illustrated

岩性识别技术除了上述技术,还有重磁岩性识别技术、遥感岩性识别技术等。其中,重磁岩性识别技术是一种利用地球重力场和地磁场的变化来确定地下岩石性质和结构的方法。一方面,由于地球表面物体受重力场的引力作用及不同岩石密度不同,不同岩体引力略有差异,通过对地球重力场的测量和分析,可以推断出地下岩石的密度变化,从而间接反映出岩石的类型和构造;另一方面,因为地球具有磁场,地下岩石对磁场的响应也不同,表现为岩石的磁性性质存在差异,通过对地磁场的测量和分析,可以推断出地下岩石的磁性变化,进而判断岩石的类型和结构。目前,常用重力测量和地磁测量,其数据处理和解释技

术,如重磁数据的滤波、剖面解释、正演模拟和三维反演算法等,是通过对重磁数据的采集、处理和解释,获得地下岩石的密度和磁性分布,从而识别不同岩石类型(如沉积岩、火山岩、变质岩等)。遥感岩性识别技术是利用卫星或航空平台获取的遥感影像数据来确定地表岩石类型、分布范围和情况的技术。遥感技术在岩性识别领域中可以获取极广的地表信息,而且不会受地理因素的限制;收集地表信息而不与地面有所接触,因此不会对环境或地质样本造成破坏;可以长期且不间断地对地表进行监测;能够收集到如光学、热红外、重力、磁场差异等多源数据,对于岩性识别的准确性有足够大的提升。综

上,遥感岩性识别技术具有广域覆盖、不接触地面、长期监测、多源数据融合等优势。王建刚等^[27]总结前人的相关研究文献,认为可以从遥感信息特征入手,将该技术分类为:基于光谱特征、基于空间特征和多源信息复合的岩性分类。OUSMANOU等^[28]对Banyo(喀麦隆Adamawa地区)东南部的花岗岩进行了区分,该地花岗岩含有铁和刚玉矿,研究将Landsat 8 OLI遥感数据和野外数据相结合,从而实现对岩性的识别,并为野外勘查提供了基本信息。但是从学者研究中也发现遥感法的缺点,即对遥感数据的处理与解释存在困难,还有光学和大气的干扰制约该技术在岩性识别领域的发展。

除传统技术外,随着时代进步,计算机科学技术飞速发展,人工智能技术越发成熟,被众多学者专家应用到各个领域,引领新技术的发展。同样该技术也被引入到岩性识别领域,旨在解决传统岩性识别方法无法处理的疑难问题,优化岩性识别技术在工程上的应用。

2 机器学习岩性识别技术

机器学习岩性识别技术通常基于人工神经网络(ANN)、支持向量机(SVM)、随机森林(Random Forest, RF)等机器学习算法,主要应用于测井数据的岩性识别,也有部分学者利用钻井采集的振动信号来训练机器学习模型继而识别岩性。例如:WANG等^[29]使用高频测量传感器采集钻具在工作时由振动发出的时频域特征数据,构建基于神经网络的岩性智能识别模型,通过现场时频域特征数据验证该方法的可行性,发现其具有较高的识别精度。针对大量复杂的测井样本数据进行训练和学习,岩性自动识别和分类是关键,其中,包括支持向量机、主成分分析法(PCA)、K-means等常用算法。LU等^[30]基于灰狼算法优化支持向量机(GWO-SVM)构建了岩性测井自动识别模型,经过对比其他机器学习算法,证明该方法在处理复杂储层中岩性识别和分类问题上具有较大优势。蔡明等^[31]以新疆轮南地区侏罗系砂泥岩层为研究对象,通过敏感性分析确定5个测井参数,以此构建CatBoost岩性智能识别模型,并利用实际测井资料,对比其他机器学习算法,验证了该模型的可行性。张昭杰等^[32]采用遗传算法挑选出最合适的支持向量机核函数参数和惩罚因子,从而建立GA-SVM模型识别砂砾岩岩性。

上述研究人员积极将SVM应用到基于测井数据的岩性识别领域中,但仍然存在难以准确选定合适的核函数、大规模数据处理效率不高的问题。REN等^[33]结合主成分分析和模糊决策树(FDT)构建模型,

并利用粒子群算法(PSO)优化模型,最终设计出新的岩性识别模型,其识别精度至少提升9.71%。叶涛等^[34]提出了主成分分析法与Bayes法联合识别方法,对渤海海域研究区域内9种火山岩的岩性进行识别,为缺失元素测井资料的火山岩岩性识别工作提供新的方法选择。JING等^[35]利用某勘探工程中获取的49个岩样的7个力学特性参数作为试验数据,验证了K-means动态聚类分析法对储层岩性进行分类的可行性和有效性。REN等^[36]结合模糊理论、决策树和K-means++算法提出对储层地质评价中岩性识别的分类识别模型,克服了测井数据中的模糊性及不确定性。ASANTE-OKYERE等^[37]将混合机器学习技术,K-means和高斯混合模型GMM(Gaussian mixture models, GMM)的聚类结果与RHOB、GR、SP、CN和RT的测井参数相结合,输入梯度增强机(GBM)岩性模型中,经验证K-means-GMM-GBM模型比GBM模型更加精确,泛化效果和预测能力也有所提升,并且可以进行新的岩性识别。综上,聚类分析不依赖于先验的标签或分类信息,适合于岩性数据的探索性分析,特别是在缺乏标注样本的情况;能够处理高维特征,找到复杂的非线性关系;对岩性特征(如物理、化学属性)的相似性进行分组,揭示出数据中的潜在模式和结构。但是,尽管聚类分析广泛应用在岩性识别中,其仍然存在缺点:一是聚类分析前需要预设类别(簇)数量,而储层地质条件复杂,因此选定合适的簇数量较困难;二是根据初始簇中心的选择不同,后续分析也将不同,这对识别结果有较大影响。

除上述算法之外,还有随机森林、贝叶斯分析法、模糊神经网络和概率神经网络等实用技术在岩性识别领域得到了广泛应用。机器学习具有良好的鲁棒性,它的引入实现了岩性识别自动化,极大降低了人工成本,同时可以处理繁杂的原始数据,提高岩性识别准确度。然而,机器学习岩性识别技术也面临一些挑战,如数据质量、特征选择、模型选择和参数调整等。为此,国内外研究人员结合现场实际不断挖掘和尝试新方法,旨在解决模型参数优化、合适特征提取等现存问题,提出一个泛化能力强的识别模型。

3 深度学习岩性识别技术

深度学习是机器学习发展过程中的一个分支技术,其着重于建立和训练多层神经网络模型,以便从大量数据中提取高级抽象特征,并用于模式识别和预测任务。传统的机器学习算法需要进行手动设计并提取数据特征,这对于复杂且规模巨大的数据集来说既繁琐又困难。但是,深度学习算法有效解决了这个难题,它能够自动提取数据中难以被人工捕捉的隐藏

特征,从而挖掘更有价值的信息,以提升模型的性能^[38]。

如今深度学习作为一种较成熟的技术,已被引入到了地球物理领域,不但有正在使用的应用,而且还有十分新颖的科研方向。例如:HUANG等^[39]将深度学习卷积神经网络应用到深井的微震识别定位中,相比于其他经典微震定位方法,该方法提高了定位准确度。将深度学习应用到岩性识别中也是目前的研究热点之一,该项技术主要针对岩石的手标本或薄片图像,通过深度学习中图像识别功能来实现对岩性的识别,采用图像识别领域广泛应用的卷积神经网络模型来进行识别分类^[40]。卷积神经网络经典模型有 AlexNet、VGG、ResNet 等,CNN 模型采用标记好的岩石样本数据进行训练,通过多个隐藏层从岩石图像中

提取高级抽象特征并送入全连接层,全连接层起到“分类器”和“预测器”的作用,最终实现对未知样本的岩性识别。

众多国内外学者通过岩石图像进行岩性识别的研究案例(如表 1 所示),利用深度学习在图像处理上的优势,基于岩石原始薄片图像或岩石手标本图像来预测岩石类型。结果表明:通过深度学习算法来识别岩石图像进而实现岩性的识别是可行且有效的,尤其是采用迁移学习方法,利用预训练好的网络模型不但能节省时间和人力成本,还能保证较高的分类准确性^[41-44]。研究将从建立数据库、搭建岩性识别智能模型、训练模型、验证模型和评估模型等步骤来详细介绍深度学习在岩性识别领域中的应用。

表 1 基于深度学习的岩性识别技术应用总览

Table 1 Overview of lithology identification technology based on deep learning in application

作者	深度学习算法	岩石类型	图像数量	结果
SEO 等 ^[45]	VGG-19BN ResNet-152	6类火成岩	23 808	>90 %
XU 等 ^[46]	Attention-based fusion model (AF model)	火成岩、沉积、变质岩	12 400	95.05 %
XU 等 ^[16]	Fusion identification model	火成岩、沉积岩和变质岩的 13 类	25 700	94.62 %
ALZUBAIDI 等 ^[47]	ResNeXt-50	砂岩、石灰岩、页岩	76 500	93.12 %
LIU 等 ^[48]	VGG-16	橄榄岩、玄武岩、大理岩、片麻岩、砾岩等 8 类	1 034	>96 %
RAN 等 ^[49]	RTCNNs	糜棱岩、花岗岩、砾岩、砂岩、页岩、石灰岩	24 315	97.96 %
POLAT 等 ^[50]	DenseNet-121	安山岩、玄武岩、脱石岩、乳岩、流纹岩、粗面	1 200	99.50 %
	ResNet-50	岩 6 类火山岩		98.80 %
刘晨等 ^[51]	ResNet-50	深灰色泥岩、深灰色粉砂质泥岩、浅灰色细砂岩等 7 类	315	93.93 %
马泽栋等 ^[52]	ResNet-50	底部砾岩、砂岩、页岩、泥岩、碎石土等 10 类	2 992	95 %
许振浩等 ^[53]	DSOD	12 类火成岩、8 类沉积岩、10 类变质岩	8 974	>88.19 %
	ResNet-101			>84.06 %
	ResNet-50			
冯雅兴等 ^[54]	AlexNet 孪生卷积神经网络	玄武岩、流纹岩、凝灰岩等 24 类	2 525	89.4 %

3.1 岩石图像数据集建立

目前,深度学习岩性识别领域中用于模型训练和验证的图像数据集,大多为手标本岩石图像数据集,通过高清拍摄设备对工程现场获取的岩样进行拍摄,或在实验室内进行岩样拍摄。此外,偏光显微镜下的岩石薄片图像集也可应用到深度学习中。

对于手标本图像,一般由研究人员对其进行质量甄别,删除不合格图像,然后依靠人工或算法裁剪与岩石图像无关的背景,减少非关键信息的干扰^[53]。初步收集好图像数据后再由人工标注各岩石类别,针对体量较小的数据集,采用随机旋转图像、随机平移、改变图像亮度、改变色度、改变锐度、镜像翻转、添加高

斯噪声或椒盐噪声等数据增强(Data Augmentation)^[55]的方法来扩充数据集,如图5所示。对于岩石薄片图像,其像素较高,如果直接将原始图像尺寸缩放成神经网络的输入尺寸就会导致图片丢失岩样特征信息,

因此,需要将原始图像切分为适当份数。另外,针对样品数量少的数据集,同样会采用数据增强的方法来扩充数据集。




图5 数据增强示例

Fig. 5 Examples of data augmentation

3.2 神经网络模型开发

训练新的可靠的神经网络模型需要具备规模巨大且标注完整的样本数据集、极其优秀的硬件设备和精心构造的网络结构,再通过一系列的卷积和池化操作,提取出原始图像数据中的高级特征。这是一个漫长又繁复的学习过程,相较之,利用迁移学习方法来实现岩性识别更具有可行性,因此当前岩性识别领域都采用迁移学习。

迁移学习旨在将在一个任务或领域上学习的知识和模型参数应用到另一个任务或领域中,既降低了建模时间、网络训练难度,又因为其具有良好的泛化能力而适用于小样本学习。简而言之,迁移学习就是

通过已经学习到的知识来帮助解决新任务中的学习问题,不需要重建底层知识架构来解决新出现的问题,类似于人类的学习活动。因此,迁移学习的能力已经足够解决岩性识别的问题,突破图像数据集不够丰富的难题^[45-52]。一般迁移学习方法通过使用特征提取和微调2种方法来实现。特征提取指引入预训练好的网络模型,在该模型中添加一个简单的分类器,将原网络作为新任务的特征提取器,只对最后增加的分类器参数进行重新学习。微调是使用预训练好的初始化网络,用新数据训练部分或整个网络。迁移学习的完整实现流程如图6所示。

需要注意,流程中ImageNet数据集是一个非常著




图6 迁移学习的完整实现流程

Fig. 6 Complete implementation process of transfer learning

名的图像分类数据集,包含了超过1 000个类别、100万张图像,许多稳定可靠的CNN模型都是在ImageNet数据集上训练得到的。选择当前某个已经训练成熟的CNN模型来识别岩性时,先要利用迁移学习

的方法,即特征提取或微调,对原模型改造以适配岩性识别问题,再由预先收集的岩石图像数据集来训练改造后的CNN模型,训练过程中要不断调整参数,直至得到识别精准度和稳定性皆满足工程要求的最终

新模型为止,以上即为完整迁移学习的工作流程。以预训练好的模型 VGG-16 为例说明神经网络模型开发流程。

VGG-16 模型的整体框架如图 7 所示,其运行流程为:该模型的输入端对图像有严格的像素要求,即图像尺寸应为 224×224 的彩色图像,另外要求图像要有 R、G、B 3 个颜色通道,而非单一通道的灰度图,即输入的图像大小是 224×224×3。将其输入网络后,会立刻转换为 224×224×3 的数字化矩阵,保证后续的卷积训练能够正常进行。图像按要求输入 VGG-16 模型后,会被卷积化处理,每段卷积流程都是卷积-ReLU-池化,经过 5 次卷积迭代后,图像的数字矩阵会被缩小到 7×7×512。这个过程既降低了图的空间尺寸,减少后续的计算复杂度,增加了通道数,从 3 增加到 512,丰富了多样化特征。而后将 7×7×512 的数字矩阵输入到全连接层中,迭代 2 次后展开得到包含 4 096 个神经元的一维向量 1×1×4 096。这两次迭代的作用分别是:将高维特征(25 088 维)压缩到更低

维,但更具判别性的空间(4 096 维);进一步细化特征表示。之后进入第三段全连接层,输出得到 1 000 个神经元,这是将细化后的特征映射到了 1 000 个类别概率中。最终通过 Softmax 函数输出这 1 000 个类别的预测概率值。




图 7 VGG-16 网络模型

Fig. 7 VGG-16 network model

VGG-16 模型一共包含 13 个卷积层和 3 个全连接层及 16 个隐藏层,池化层不涉及权重,因此不计入其中,且每组卷积都使用 3×3 的卷积核,卷积后使用 2×2 最大池化。其网络结构参数如表 2 所示。

表 2 网络结构参数

Table 2 Network structure parameter

网络层	Kernel(卷积核)	Stride(步长)	Padding(填充)	输出维度
Conv1-1	3×3	1	1	224×224×64
Conv1-2	3×3	1	1	
Maxpool1	2×2	2	0	112×112×64
Conv2-1	3×3	1	1	112×112×128
Conv2-2	3×3	1	1	
Maxpool2	2×2	2	0	56×56×128
Conv3-1	3×3	1	1	56×56×256
Conv3-2	3×3	1	1	
Conv3-3	3×3	1	1	28×28×256
Maxpool3	2×2	2	0	
Conv4-1	3×3	1	1	28×28×512
Conv4-2	3×3	1	1	
Conv4-3	3×3	1	1	14×14×512
Maxpool4	2×2	2	0	
Conv5-1	3×3	1	1	14×14×512
Conv5-2	3×3	1	1	
Conv5-3	3×3	1	1	7×7×512
Maxpool5	2×2	2	0	
Fc4096				1×1×4 096
Fc4096				1×1×4 096
Fc1000				1×1×1 000
Softmax				

隐藏层中的13个卷积层可以分为5段卷积层,每段卷积层之间由 2×2 的最大池化层过渡,每次池化后数字化矩阵尺寸都会缩小一半,通道数由卷积层改变。在最后3个连接层之间插入了Dropout函数,其作用是随机将连接层之间的某些神经元断开,防止模型训练过拟合。VGG-16模型运行的简要流程如图8所示。另外,注意隐藏层的所有单元都采用ReLU激活函数,其主要是为了解决梯度消失问题,更好地帮助网络收敛。




图8 网络结构流程

Fig. 8 Network structure flow

在VGG-16模型进行训练时,包括向前传递和向后传递2种方式。会对前两层全连接网络采用dropout防止过拟合,采用批量梯度下降和Momentum以交叉熵为目标损失进行训练优化模型参数。

向前传递就是将输入数据逐步转化为预测输出数据,实现输入与输出端点之间复杂的映射,一般都会进行卷积和池化操作:

$$z_{p,conv}^l(i,j) = \sum_{q=1}^{n^{l-1}} \sum_{u=-1}^1 \sum_{v=-1}^1 a_q^{l-1}(i-u, j-v) \quad (1)$$

$$k_{p,q}^l(u,v) + b_p^l$$

$$a_p^l(i,j) = \text{ReLU}(z_p^l(i,j)) \quad (2)$$

$$z_{p,pool}^l(i,j) = \max(a_p^{l-1}(2i-u, 2j-v)) \quad (3)$$

$$u, v \in (0, 1)$$

式中: n^{l-1} 为第 l 层的卷积核数目; $k_{p,q}^l$ 为第 l 层 p 通道与第 $1-1$ 层 q 通道对应的卷积核; b_p^l 为 p 通道的偏置。

式(1)、式(2)即为第 l 层的卷积操作公式,其中ReLU为激活函数, $\text{ReLU} = \max(0, x)$ 。经过操作就能得到第 l 层 p 通道未经过激活函数的前向输入 z_p^l ,以及第 l 层 p 通道经过激活函数后的前向输出 a_p^l 。由式(3)得到的经过最大池化后的第 l 层 p 通道前向输入 z_p^l 。

如表2所示,经过18层卷积池化操作后可获得 $7 \times 7 \times 512$ 的特征图,为使其作为全连接层的输入,将会展平为 $(1, 7 \times 7 \times 512)$ 大小的向量,即 $(1, 25\ 088)$ 的向量。最终根据式(4)操作后,得到向前输出 a^{18} 。

$$a^{18} = F(\{z_p^{18}\}_{p=1, 2, \dots, 512}) \quad (4)$$

进入全连接层后,采用dropout防止训练过拟合,简写作 d 。将第 l 层节点的连通表示为 r^l ,该值服从伯努利分布: $r^l \sim \text{Bernoulli}(d)$ 。总结上述过程,网络模型的向前传递可用式(5)~(7)这三个公式描述:

$$\tilde{a}^l = r^l \odot a^l \quad (5)$$

$$z^{l+1} = W^{l+1} \tilde{a}^l + b^{l+1} \quad (6)$$

$$a^{l+1} = \text{ReLU}(z^{l+1}) \quad (7)$$

最后经由输出层的激活函数softmax输出最终结果 a_i^L ,表示预测分布:

$$a_i^L = \text{softmax}(z_i^L) = \frac{e^{z_i^L}}{\sum_{k=1}^{n^L} e^{z_k^L}} \quad (8)$$

L 为采用交叉熵损失的损失函数,其中, y_i 为真实目标分布:

$$L = - \sum_{i=1}^{n^L} y_i \lg a_i^L \quad (9)$$

神经网络除了向前传递之外,还会进行反向传递,通过从输出层向输入层逐层计算误差梯度,并以此解决网络参数的优化和损失函数的最小化问题。反向传播误差计算公式为:

$$\begin{cases} \delta^L = a^L - y \\ \delta^{l+1} = (W^{l+1})^T \delta^{l+1} \odot r^l \odot \text{ReLU}(z^l)' \\ \delta^{18} = F^{-1}((W^{19})^T \delta^{19}) \\ \delta^{l2} = \text{upsample}(\delta^{l+1}) \odot \text{ReLU}(z^l)' \\ \delta_q^l = \left[\sum_{p=1}^{n^{l+1}} \delta_p^{l+1} \text{rot } 180(k_{p,q}^{l+1}) \right] \odot \text{ReLU}(z_q^l)' \end{cases} \quad (10)$$

根据式(10)可计算得到输出层的反向传递误差 δ^L ;第 l 全连接层的反向传递误差 δ^{l+1} ;全连接层到池化层的反向传递误差 δ^{18} ;池化层到卷积层反向传递误差 δ^{l2} ;第 $l+1$ 卷积层到第 l 卷积层的反向传递误差 δ_q^l ,注意在该阶段计算中,当第 l 层为池化层时, $\text{ReLU}(z_q^l)=1$ 。

得到所有反向传递误差数据后,便可以着手进行梯度计算。其中,第 l 层全连接层的反向传递误差为 δ^{l+1} ,其梯度 $\frac{\partial L}{\partial W^{l+1}}, \frac{\partial L}{\partial b^{l+1}}$ 为:

$$\begin{cases} \frac{\partial L}{\partial W^{l+1}} = \frac{\partial L}{\partial z^l} \frac{\partial z^l}{\partial W^{l+1}} = \delta^{l+1} (a^{l-1})^T \\ \frac{\partial L}{\partial b^{l+1}} = \frac{\partial L}{\partial z^l} \frac{\partial z^l}{\partial b^{l+1}} = \delta^{l+1} \end{cases} \quad (11)$$

第 l 层卷积层的反向传递误差值为 δ^l ,其梯度

$\frac{\partial L}{\partial k_{p,q}^l}, \frac{\partial L}{\partial b_p^l}$ 为:

$$\begin{cases} \frac{\partial L}{\partial k_{p,q}^l} = \frac{\partial L}{\partial z_p^l} \frac{\partial z_p^l}{\partial k_{p,q}^l} = \delta_p^l a_q^{l-1} \\ \frac{\partial L}{\partial b_p^l} = \frac{\partial L}{\partial z_p^l} \frac{\partial z_p^l}{\partial b_p^l} = \sum_{i=1}^{n^l} \sum_{j=1}^{n^l} \delta_p^l(i,j) \end{cases} \quad (12)$$

在获得一个批次的梯度数据后,就可以对网络模型的参数权重 W , 阈值 b 进行优化更新, 公式为:

$$\begin{cases} b^i = b^i - \alpha v_{db^i} \\ W^i = W^i - \alpha v_{dW^i} \end{cases} \quad (13)$$

一般采用批量梯度下降和 Momentum 法来进行优化, 该方法的计算公式如式(14)所示, 其中, β 为 Momentum 法的可调参数, 一般设置为 0.9。

$$\begin{cases} v_{db} = \beta v_{db} + (1 - \beta) \frac{\partial L}{\partial b^i} \\ v_{dW} = \beta v_{dW} + (1 - \beta) \frac{\partial L}{\partial W^i} \end{cases} \quad (14)$$

反向传递会不断调整参数, 直至 VGG-16 模型的预

测结果足够准确, 输出结果与真实值之间足够接近。

VGG-16 模型在训练时会不断地自我优化完善, 一方面, 通过正向传递输出预测结果; 另一方面, 利用反向传递进行参数优化, 逐步提高预测精度。

3.3 迁移学习岩性识别

通过上述介绍, 了解 VGG-16 模型的整体架构及其运行流程, 然后采用迁移学习实现岩性识别, VGG-16 模型迁移学习实现岩性识别的具体过程如图 9 所示。需要注意, 新全连接层中的参数 1 000 应该根据实际需要灵活改动, 一般是以实际分类数为准。例如, 某一项目中需要分类的岩石类别为 13 种, 则全连接层的参数修改为 13。




图 9 VGG-16 模型迁移学习识别岩性过程

Fig. 9 Process of transfer learning to identify lithology based on VGG-16

对预训练好的 VGG-16 模型进行改造时, 要冻结原 VGG-16 模型的前 15 层, 调整最后的 Fc1000 全连接层, 将参数 1 000 改为符合实际需求的分类数目。然后将预处理得到的图像数据集中 80 % 的数据作为训练集输入到已改造好的模型进行训练, 再将 20 % 的测试集输入到新训练好的网络模型中进行测试, 最终得到岩性分类结果。

一般都会采用准确率 (ACC)、精确率 (P)、召回率 (R)、 F_1 -score 等指标参数及混淆矩阵来验证网络模型的准确性。混淆矩阵如图 10 所示, 由 4 个指标构成。TP: 实际是 Positive, 模型预测为 Positive; FN: 实际是 Positive, 模型预测为 Negative; FP: 实际是 Negative, 模型预测为 Positive; TN: 实际是 Negative, 模型预测为 Negative。

一般 TP 和 TN 指标越大, FN 和 FP 越小, 则表示模型的预测准确度越高。混淆矩阵一定程度上已经能够说明模型的优劣, 但在数据量大的情况下, 仍有不足。因此, 采用准确率 (ACC)、精确率 (P)、召回率 (R)、 F_1 -score 等指标参数帮助衡量模型优劣。

		预测标签	
		Positive	Negative
实际标签	Positive	TP	FN
	Negative	FP	TN

图 10 混淆矩阵

Fig. 10 Confusion matrix

准确率 (ACC): 模型预测结果准确的数量占总测试集数量的比例。

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

精确率 (P): 在模型预测全是 Positive 的结果中, 预测正确的数量比例。

$$P = \frac{TP}{TP + FP} \quad (16)$$

召回率(R):在实际值全是 Positive 的结果中,预测正确的数量比例。

$$R = \frac{TP}{TP + FN}$$

(17)

$F_{1-score}$:综合了 P 与 R 的结果, $F_{1-score}$ 取值范围为0~1,越靠近1说明模型预测越准确。

$$F_{1-score} = \frac{2PR}{P + R}$$

(18)

当前有不少学者已经使用 VGG-16 模型进行迁移学习实现岩性识别。例如:WANG^[56]通过迁移学习对 VGG-16 模型中的参数进行微调,最终实现基于 VGG-16 模型的岩石图像识别。白林等^[57]建立了用于分类岩石薄片的 VGG 迁移模型,对 6 种常见岩石种类进行识别分类,最终测试集识别准确率能够达到 82 %。范思萌等^[58]提出在 VGG-16 模型基础上添加一个网络分支来融合浅层特征和深层特征,即基于 C-VGG16 的岩性识别方法,该方法在样本数据集上的准确率能够达到 90 % 以上。LIU 等^[48]利用 Faster R-CNN 目标检测框架标记图像中的岩石对象,而后

基于简化后的 VGG-16 模型进行迁移学习,最终得到准确率高达 96 % 的岩性识别模型。综上研究,成功验证了该模型在岩性识别领域的可行性。

4 岩性识别技术对比

相比于岩石手标本及薄片图像人工识别法、测井法和遥感法等传统岩性识别技术,智能岩性识别技术具有显著优势(如表 3 所示)。①自动性和非破坏性:深度学习模型能够自动从原始数据中学习 to 更高级别的特征表示,然后依靠特征进行自动化识别,摆脱了主观性因素的影响,提高了岩性识别的准确性和客观性。另外,智能识别技术可以直接通过分析原始数据(如图像、测井数据等)达到识别目的,避免了对实际岩石样本的破坏性损伤。②迁移学习优势:采用迁移学习进行岩性识别,既降低了网络训练难度,又降低了对样本数据量的需求和模型训练时间。③高效处理大规模数据:智能识别模型在处理大规模数据时具有较强的处理能力,可以从大量数据中学习 to 更为准确和全面的特征,提高岩性识别的精度和效果。

表 3 岩性识别技术的优缺点

Table 3 List of advantages and disadvantages of lithology identification technology

技术	方法	优点	缺点
传统岩性识别技术	手标本及薄片分析方法	能够提供详细的岩性和岩石成分信息	工作量大,时间周期长,特别依赖专业技术和设备,主观性强
	重磁法	能够分辨地表下构造和岩层的分布,快速获取大范围的地质信息,三维反演算法较成熟	岩性识别能力相对较弱,对于复杂结构和深部信息的解释较差
	测井法	技术成熟,方法繁多,算法齐全	需要进行钻井操作,成本较高且工作量较大,不适用于无法钻探的区域
	遥感法	对于岩性分布和地貌特征具有较高的分辨率和快速获取能力、范围广	难以获取地表下岩性信息,受地表覆盖和大气干扰影响
机器学习岩性识别技术	支持向量机	可以处理高维数据和非线性问题,对小样本情况表现较好,有较好的泛化能力	需要较长的训练时间,对于大规模数据集不适用
	K-means 动态聚类分析方法	计算效率高,易于理解和实现	对聚类中心的选择敏感,容易受到初始值的影响,对于非凸形状的簇效果较差
	随机森林	高维数据和离散特征处理能力强,能够评估特征的重要性	模型复杂,需要更多的计算资源
	贝叶斯分析法	对小规模数据集和高维数据具有较好的表现,能够进行实时分类	依赖输入数据的假设,当先验假设不准确时可能导致错误的分类结果
深度学习岩性识别技术	迁移学习	自动提取特征,避免从零开始训练模型,算法效率高,对大量目标任务数据的依赖少	要求源领域和目标领域之间存在一定的相似性,深度学习模型的解释性较差,即黑盒特性

需要注意的是,智能识别技术也有部分限制,如对已标注数据的高需求、对数据质量的高依赖、模型解释性差、模型通用性弱、自动提取的特征不能完全

反映岩性本质等。因此,其他岩性识别技术在某些特定场景下仍然具有一定的优势。在选择岩性识别方法时,应该综合考虑现实的客观条件、工程任务的要

求和目的等因素,权衡各种方法的优劣势,选择最合适的方法来识别岩性。

5 结论与展望

传统岩性识别方法在矿产勘查与工程实践中发挥了重要作用。岩石薄片图像人工识别法凭借其高精度和微观结构可视化的优势,广泛应用于岩石分类与成因分析;手标本图像识别则在现场识别中更具优势,直观且操作便捷;测井数据识别可为深部地层的识别提供重要依据。然而,这些方法普遍依赖人工经验,识别效率低、主观性强,面对数据量大、环境复杂的现代工程需求时,存在明显局限。为此,XRF元素录井技术、重磁法和遥感技术等现代手段不断丰富岩性识别的技术体系,实现了信息采集的自动化与多元化,有效提升了识别精度与范围。但这些方法在实际应用中仍面临诸如数据处理复杂、解释模型不统一、多源信息融合能力不足等技术瓶颈。此外,遥感法虽具广域覆盖优势,但受限于环境干扰和精度控制,对微细岩性的识别能力仍显不足。

人工智能技术不断发展迭代,迸发出了新的生机活力,为许多领域带来发展新机遇。其与传统岩性识别技术的深度融合,不仅能发挥人工智能在数据处理和智能决策方面的优势,还能继承传统方法的理论依据与专家经验,并依托成熟的硬件设备获取高可靠性数据。其中,基于岩石图像或测井数据的岩性智能识别方法被提出并不断完善,使岩性识别技术迎来了新的发展阶段。岩性智能识别方法能够处理大量高维岩性数据,解决了传统方法识别效率低、主观性强的问题,具备较强的泛化能力与自动学习能力。尤其是在图像识别、测井数据分类和元素分析等场景中,卷积神经网络、支持向量机、随机森林等算法展现出较高的识别准确率与稳定性。然而,当前的岩性智能识别方法仍旧面临一些挑战。一方面,人工智能模型在训练时,对数据质量、样本数量和标注精度依赖性强;另一方面,由于不同地域的环境条件差异较大,因此模型的通用性及迁移能力较弱,限制其在实际工程中的推广应用。此外,人工智能技术仍处于“黑箱”状态,基于此技术构建模型的可解释性差。综上,人工智能技术正逐步突破传统岩性识别方法的性能上限,为提高识别效率与精度提供新的发展方向,但其在模型通用性、数据依赖性和可解释性等方面仍需进一步探索与优化。

未来,智能岩性识别技术应该更加关注深度学习岩性识别技术,扩建标准岩石图像数据库,收集足够全面的多矿种、多尺度、高质量岩石图像。除此之外,智能岩性识别技术结合如岩石视觉、光谱、物理属性

等多源信息,实现直接从岩石图像或测井数据中解析出矿物成分、颗粒大小、胶结方式等关键信息,甚至可以关联和分析岩石的微观结构与宏观形貌等关键信息,构建岩体强度与变形特性的智能预测模型,实现多源信息的融合与力学特性的预测,减少对传统室内试验的依赖,推动现场实时评价技术。轻量化处理岩性识别模型,降低其运行成本,方便应用到工程现场,结合更精准高效的地下测量设备,实现现场实时岩性识别及力学特性预测。结合岩芯的空间重定位技术,反演岩芯初始姿态下的地应力状态,精简岩芯的地应力测量方法。结合上述技术,将当前静态的非实时岩性智能识别技术,通过处理多源信息、加入实时监测设备、精准轻量化的识别模型等手段,实现对矿山动态岩性识别感知。并推动岩性识别深度融合到采矿全过程中,协助进行矿产资源评估、开采设计和及时调整采掘参数等,打造一个可以适应复杂矿山现场且能够帮助优化采矿流程的系统。

[参 考 文 献]

- [1] 陈欢庆,石为为,杜宜静,等.火山岩储层岩相研究进展[J].地质科学,2022,57(4):1 307-1 323.
- [2] TANG H F, TIAN Z W, GAO Y F, et al. Review of volcanic reservoir geology in China [J]. Earth-science Reviews, 2022, 232: 104123.
- [3] NASERI A, NASAB A R. Automatic identification of minerals in thin sections using image processing [J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12(3): 2 451-2 465.
- [4] 赵林海,吴功勇,聂兴信,等.矿山岩石动力学研究现状及展望[J].黄金,2025,46(1):37-46.
- [5] 郭陈响,朱建国,刘恩彦,等.动态冲击下龄期较短充填体的力学特性研究[J].黄金,2024,45(1):6-11.
- [6] HAN S, LÖHR S C, ABBOTT A N, et al. Earth system science applications of next-generation SEM-EDS automated mineral mapping [J]. Frontiers in Earth Science, 2022, 10: 825043.
- [7] HAN R Y, WANG Z W, WANG W H, et al. Lithology identification of igneous rocks based on XGboost and conventional logging curves, a case study of the eastern depression of liaohu basin [J]. Journal of Applied Geophysics, 2021, 195: 104390.
- [8] HAN R Y, WANG Z W, WANG W H, et al. Igneous rocks lithology identification with deep forest: Case study from eastern sag, Liaohu basin [J]. Journal of Applied Geophysics, 2023, 208: 104890.
- [9] WANG C R, LI P J, LONG Q Q, et al. Deep learning for refined lithology identification of sandstone microscopic Images [J]. Minerals, 2024, 14(3): 250.
- [10] 许振浩,马文,李术才,等.岩性识别:方法、现状及智能化发展趋势[J].地质论评,2022,68(6):2 290-2 304.
- [11] YANG J L, WANG M, LI M, et al. Shale lithology identification using stacking model combined with SMOTE from well logs [J]. Unconventional Resources, 2022, 2: 108-115.
- [12] YIN S T, LIN X C, HUANG Y J, et al. Application of improved support vector machine in geochemical lithology identification [J]. Earth Science Informatics, 2023, 16(1): 205-220.
- [13] ZHU X Y, ZHANG H B, REN Q, et al. ORALI: Open-set recogni-

- tion and active learning for unknown lithology identification[J]. Engineering Applications of Artificial Intelligence, 2024, 133: 108123.
- [14] LIU M, HU S, ZHANG J, et al. Methods for identifying complex lithologies from log data based on machine learning[J]. Unconventional Resources, 2023, 3: 45–56.
- [15] ZHU X Y, ZHANG H B, REN Q, et al. An automatic identification method of imbalanced lithology based on deep forest and K-means SMOTE[J]. Geoenergy Science and Engineering, 2023, 224: 211600.
- [16] XU Z H, SHI H, LIN P, et al. Integrated lithology identification based on images and elemental data from rocks[J]. Journal of Petroleum Science and Engineering, 2021, 205: 108951.
- [17] GENG Z X, LIU J, LI S Y, et al. Channel attention-based static-dynamic graph convolutional network for lithology identification with scarce labels[J]. Geoenergy Science and Engineering, 2023, 223: 211578.
- [18] LI D Y, ZHAO J J, LIU Z D. A Novel method of multitype hybrid rock lithology classification based on convolutional neural networks[J]. Sensors, 2022, 22(4): 1580.
- [19] 鲍俊军, 乌永兵. 铸体薄片的制片方法[J]. 辽宁化工, 2019, 48(6): 531–533.
- [20] 李哲, 高保彬, 雷文杰, 等. 基于钻孔多参数测井的煤层顶底板岩性及厚度识别[J]. 煤田地质与勘探, 2024, 52(12): 190–200.
- [21] 王伟, 武正乾, 贺锋, 等. 伽马-伽马测井在鄂尔多斯盆地西南缘白垩系识别岩性的研究[J]. 世界核地质科学, 2024, 41(2): 343–350.
- [22] OKEUGO C G, ONUOHA K M, EKWE C A, et al. Application of crossplot and prestack seismic-based impedance inversion for discrimination of lithofacies and fluid prediction in an old producing field, eastern niger nelta basin[J]. Journal of Petroleum Exploration and Production Technology, 2019, 9(1): 97–110.
- [23] YIN P, QI L, ZHU Q, et al. Application of element logging to lithologic identification of key horizons in Sichuan–Chongqing gas provinces[J]. Natural Gas Industry B, 2018, 5(2): 132–138.
- [24] WANG Q S, ZHANG X J, TANG B, et al. Lithology identification technology using BP neural network based on XRF[J]. Acta Geophysica, 2021, 69(6): 2 231–2 240.
- [25] 王虎, 程修雷, 李兆龙. X射线荧光元素录井技术应用方法研究[J]. 西部探矿工程, 2023, 35(4): 29–30, 4.
- [26] YARBROUGH L D, CARR R, LENTZ N. X-ray fluorescence analysis of the Bakken and three forks formations and logging applications[J]. Journal of Petroleum Science and Engineering, 2019, 172: 764–775.
- [27] 王建刚, 叶发旺, 邱骏挺, 等. 遥感岩性识别分类研究[J]. 世界核地质科学, 2020, 37(1): 10–22.
- [28] OUSMANOU S, FOZING E M, KWÉKAM M, et al. Application of remote sensing techniques in lithological and mineral exploration: Discrimination of granitoids bearing iron and corundum deposits in southeastern Banyo, Adamawa region-Cameroon[J]. Earth Science Informatics, 2023, 16(1): 259–285.
- [29] WANG C, XUE Q L, HE Y M, et al. Lithological identification based on high-frequency vibration signal analysis[J]. Measurement, 2023, 221: 108765.
- [30] LU S Y, LI M J, LUO N, et al. Lithology logging recognition technology based on GWO-SVM algorithm[J]. Mathematical Problems in Engineering, 2022, 2022: 1640096.
- [31] 蔡明, 周庆文, 杨聪, 等. 砂泥岩地层岩性智能识别方法与应用——以新疆轮南侏罗系岩层为例[J]. 煤田地质与勘探, 2025, 53(1): 235–244.
- [32] 张昭杰, 王建华, 刘强, 等. GA-SVM模型在砂岩岩性识别中的优化与应用[J]. 地球物理学报, 2021, 64(5): 123–134.
- [33] REN X, WANG Y, LI Z, et al. A hybrid PCA-FDT model with pos optimization for lithoigy identification[J]. Journal of Petroleum Science and Engineering, 2023, 220: 110876.
- [34] 叶涛, 韦阿娟, 黄志, 等. 基于主成分分析法与Bayes判别法组合应用的火山岩岩性定量识别: 以渤海海域中生界为例[J]. 吉林大学学报(地球科学版), 2019, 49(3): 873–880.
- [35] JING J K, KE S Z, LI T J, et al. Energy method of geophysical logging lithology based on K-means dynamic clustering analysis[J]. Environmental Technology & Innovation, 2021, 23: 101234.
- [36] REN Q, ZHANG H B, ZHANG D L, et al. A novel hybrid method of lithology identification based on K-means plus plus algorithm and fuzzy decision tree[J]. Journal of Petroleum Science and Engineering, 2022, 208: 109678.
- [37] ASANTE-OKYERE S, SHEN C B, ZIGGAH Y Y, et al. A novel hybrid technique of integrating gradient-boosted machine and clustering algorithms for Lithology classification[J]. Natural Resources Research, 2020, 29(4): 2 257–2 273.
- [38] DONG S, WANG P, ABBAS K. A survey on deep learning and its applications[J]. Computer Science Review, 2021, 40: 100379.
- [39] HUANG L Q, LI J, HAO H, et al. Micro-seismic event detection and location in underground mines by using convolutional neural networks (CNN) and deep learning[J]. Tunnelling and Underground Space Technology, 2018, 81: 265–276.
- [40] DARGAN S, KUMAR M, AYYAGARI M R, et al. A Survey of deep learning and its applications: A new paradigm to machine learning[J]. Archives of Computational Methods in Engineering, 2020, 27(4): 1 071–1 092.
- [41] YU F C, XIU X C, LI Y H. A survey on deep transfer learning and beyond[J]. Mathematics, 2022, 10(19): 3617.
- [42] IMAN M, ARABNIA H R, RASHEED K. A review of deep transfer learning and recent advancements[J]. Technologies, 2023, 11(2): 40.
- [43] HUA J, ZENG L C, LI G F, et al. Learning for a robot: Deep reinforcement learning, imitation learning, transfer learning[J]. Sensors, 2021, 21(4): 1278.
- [44] CHEN W H, SU L M, CHEN X Q, et al. Rock image classification using deep residual neural network with transfer learning[J]. Frontiers in Earth Science, 2023, 10: 1079447.
- [45] SEO W, KIM Y, SIM H, et al. Classification of igneous rocks from petrographic thin section images using convolutional neural network[J]. Earth Science Informatics, 2022, 15(2): 1 297–1 307.
- [46] XU Z H, SHI H, LIN P, et al. Intelligent on-site lithology identification based on deep learning of rock images and elemental data[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1–5.
- [47] ALZUBAIDI F, MOSTAFAVI P, SWIFTOJANSKI P, et al. Automated lithology classification from drill core images using convolutional neural networks[J]. Journal of Petroleum Science and Engineering, 2022, 2022: 1640096.

- neering, 2021, 197: 107968.
- [48] LIU X B, WANG H Y, JING H D, et al. Research on intelligent identification of rock types based on faster R-CNN method [J]. IEEE Access, 2020, 8: 21 804–21 812.
- [49] RAN X J, XUE L F, ZHANG Y Y, et al. Rock classification from field image patches analyzed using a deep convolutional neural network [J]. Mathematics, 2019, 7(8): 755.
- [50] POLAT O, POLAT A, EKICI T. Automatic classification of volcanic rocks from thin section images using transfer learning networks [J]. Neural Computing & Applications, 2021, 33(18): 11 531–11 540.
- [51] 刘晨, 赵晓晖, 梁乃川, 等. 基于ResNet50和迁移学习的岩性识别与分类研究[J]. 计算机与数字工程, 2021, 49(12): 2 526–2 530.
- [52] 马泽栋, 马雷, 李科, 等. 基于岩石图像深度学习的多尺度岩性识别[J]. 地质科技通报, 2022, 41(6): 316–322.
- [53] 许振浩, 马文, 林鹏, 等. 基于岩石图像迁移学习的岩性智能识别[J]. 应用基础与工程科学学报, 2021, 29(5): 1 075–1 092.
- [54] 冯雅兴, 龚希, 徐永洋, 等. 基于岩石新鲜面图像与孪生卷积神经网络的岩性识别方法研究[J]. 地理与地理信息科学, 2019, 35(5): 89–94.
- [55] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning [J]. Journal of Big Data, 2019, 6(1): 60.
- [56] WANG H J. Intelligent identification of logging cuttings based on deep learning [J]. Energy Reports, 2022, 8: 1–7.
- [57] 白林, 魏昕, 刘禹, 等. 基于VGG模型的岩石薄片图像识别[J]. 地质通报, 2019, 38(12): 2 053–2 058.
- [58] 范思萌, 王梅, 李东旭, 等. 基于C-VGG16的岩性识别[C]//中国石油学会. 2021 IPPTC 国际石油石化技术会议论文集. 北京: 石油工业出版社, 2021: 1–10.

Current development and practice of smart lithology identification technology

Huang Linqi, Wei Yunfeng, Li Xibing

(School of Resources and Safety Engineering, Central South University)

Abstract: Lithology identification technology is a powerful means to distinguish the type of target rock, thereby mastering the geological structural characteristics and mineral distribution. Traditional lithology identification technologies (such as rock hand specimen/thin section microscopic identification, remote sensing, and logging methods) have limitations such as strong subjectivity, low efficiency, weak anti-interference ability, and complex processes. Although rock lithology automatic identification methods based on traditional machine learning have broken through the bottlenecks of traditional lithology identification technology to some extent, the rich lithology feature information is not fully utilized. Smart lithology identification technology based on deep learning has gradually shown excellent performance. Based on existing deep learning models, this paper introduces the technical process of using the VGG-16 convolutional neural network to recognize lithology through transfer learning, which not only reduces the dependency on the amount of lithology annotation data but also increases the generalization ability of identification by automatically capturing the high-dimensional feature information of lithology. In addition, the development and innovation of smart lithology identification technology will be carried out in the following directions: constructing a standard rock image database containing multiple ore types and multiple scales; developing an on-site real-time lithology identification system with lightweight processing of identification models; integrating multi-dimensional data information such as rock vision, spectral, and physical properties, and improving the reliability of intelligent identification models through collaborative analysis methods; and constructing a mine lithology dynamic sensing system to promote the smart upgrading of the whole process of precision mining.

Keywords: mine exploration; lithology identification; artificial intelligence; deep learning; VGG-16; machine learning