

doi: 10.12097/gbc.2023.12.007

基于成像光谱的砂岩铀矿岩性分类深度学习方法

潘蔚¹, 张元涛^{2*}, 师俞晨¹, 陈雪娇¹

PAN Wei¹, ZHANG Yuantao^{2*}, SHI Yuchen¹, CHEN Xuejiao¹

1. 核工业北京地质研究院遥感信息与图像分析技术国家级重点实验室, 北京 100029;

2. 核工业二八〇研究所, 四川 广汉 618300

1. National Key Laboratory of Remote Sensing Information and Image Analysis Technology, Beijing Research Institute of Uranium Geology, Beijing 100029, China;

2. No. 280 Institute of Nuclear Industry, Guanghan 618300, Sichuan, China

摘要:【研究目的】岩心编录对获取地球深部地质信息意义重大,目前,人工编录仍然是获取岩性等信息的主要手段,存在编录过程费时费力,编录结果不完整、主观性强的缺点。【研究方法】以鄂尔多斯盆地西南部砂岩型铀矿岩性钻孔 ZKH3 为研究对象,将深度学习技术与成像光谱技术应用于岩心岩性识别。【研究结果】构建了包含 7 个一维卷积层、2 个池化层、1 个一维卷积注意力模块和 3 个全连接层卷积神经网络模型。并收集整理了 7 类岩石共 26877 条光谱样本,完成了模型优化和训练。最后,通过与支持向量机(SVM)的对比及在整孔岩心中的应用,评价了模型性能。结果表明,深度学习岩性识别模型的总体精度(OA)达到 94.6%,其中泥岩、细砂岩、粉砂岩、中砂岩、粗砂岩、砂砾岩及背景的生产者精度(PA)分别为 95.07%、72.02%、97.50%、97.37%、96.65%、97.33%、99.01%,Kappa 系数为 0.94,总体优于 SVM,且取得了与地质编录相当的效果。【结论】表明基于成像光谱数据的深度学习模型具有良好的钻孔岩性分类识别能力,可实现岩性的无损快速识别,在一定程度上降低了人工地质编录的主观性,可为岩心数字化及自动化编录研究提供参考。

关键词: 成像光谱; 铀矿; 砂岩粒度; 岩性分类; 深度学习

创新点: 将深度学习与成像光谱技术应用于钻孔岩性自动识别,实现了岩性的无损快速识别,降低了人工地质编录的主观性影响。

中图分类号: P619.14 文献标志码: A 文章编号: 1671-2552(2025)02/03-0315-11

Pan W, Zhang Y T, Shi Y C, Chen X J. Deep learning method for lithology classification of sandstone uranium deposits based on imaging spectroscopy. *Geological Bulletin of China*, 2025, 44(2/3): 315-325

Abstract: [Objective] Core logging is crucial for obtaining deep geological information about the earth. Currently, manual logging remains the primary method for acquiring lithological and other information, but it is time-consuming, labor-intensive, and prone to incomplete results and subjectivity. [Methods] Therefore, this study focuses on the ZKH3 of sandstone-type uranium deposits in the southwest of the Ordos Basin, applied deep learning and imaging spectroscopy techniques to core lithology identification. This study constructed a CNN model consisting of 7 one-dimensional convolutional layers, 2 pooling layers, 1 one-dimensional CBAM, and 3 fully connected layers. [Results] Additionally, a total of 26877 spectral samples from 7 types of rocks were collected, and model optimization and training were completed. Finally, the performance of the model was evaluated through comparison with Support Vector Machine (SVM) and its application in the whole borehole. The results show that the overall accuracy (OA) of deep learning model reached 94.6%, among which the producer's accuracy (PA) of mudstone, fine sandstone, siltstone, medium sandstone, coarse

收稿日期: 2023-12-04; 修订日期: 2024-01-22

资助项目: 中国核工业集团公司集中研发项目《第四代铀矿勘查关键技术研究及示范(第一阶段)》(编号: 中核科发[2021]143号)、核技术研发科研项目(编号: HNKF202309(36))

作者简介: 潘蔚(1963-),男,博士,正高级工程师,从事地学目标的遥感识别技术与方法研究。E-mail: panweiprc@163.com

*通信作者: 张元涛(1991-),男,博士,工程师,从事遥感地质应用研究。E-mail: 809316163@qq.com

sandstone, glutenite and background were 95.07%, 72.02%, 97.50%, 97.37%, 96.65%, 97.33%, and 99.01%, respectively. The Kappa coefficient was 0.94, which was better than SVM overall and achieved comparable results to geological logging. **[Conclusions]** This indicates that deep learning model based on imaging spectral data demonstrates excellent lithology classification and identification capabilities for core samples. And this approach enables non-destructive and rapid lithology identification while reducing the subjectivity inherent in manual geological logging to some extent, which provides valuable reference for digitization and automated logging research of core samples reference for research on digitalization and automation of core logging.

Key words: imaging spectrum; uranium deposit; sandstone particle size; lithology classification; deep learning

Highlights: Deep learning and imaging spectroscopy techniques are applied to the automatic identification of rock types in borehole, which achieves non-destructive and rapid lithology recognition, and reduces the subjective influence inherent in manual geological logging.

岩心编录是记录和保存深部地质信息的主要手段,目前仍主要依靠肉眼观察和人工记录实现,不仅费时费力,且受编录人员经验影响,很难避免主观因素造成的记录和认识偏颇。及时、准确、高效和经济地从岩心中挖掘尽可能多的地质信息,是提高钻探价值和效用的有效途径。作为新一代岩心数字化技术,成像光谱(高光谱)扫描能获取全面、客观反映岩石结构、矿物成分、岩石类型等特征的图谱合一数据,是当前的研究热点。借助这些数据,通过对岩心光谱的分析并结合图像处理,可实现岩心地学信息,如矿物(张杰林等, 2013; Mathieu et al., 2017; 张川等, 2017, 2019; De La Rosa et al., 2021; Greenberger et al., 2021)、岩性(Tappert et al., 2015)、脉体及构造(Tusa et al., 2019)、沉积特征(Speta et al., 2016)等的获取。

近年来,深度学习技术受到广泛关注,利用深度学习方法开展岩矿识别的研究已经兴起。Yu et al.(2021)将 3D 卷积自编码算法应用于 ZY1-02D 高光谱数据岩性识别,其结果表明该算法识别效率及精度较传统机器学习算法高。Ye et al.(2020)将多种深度学习方法应用于 GF-5 高光谱数据岩性识别,通过对比分析指出,多尺度 3D 深度卷积神经网络效果好,适合于该数据的岩性填图。与星载高光谱数据不同,钻孔高光谱数据具有数据量大、景数多的特点,其每米岩心最大数据量可达 1 GB(卢燕, 2018)。将机器及深度学习方法应用于岩心高光谱数据,可提高数据解译的速度和精度(De La Rosa et al., 2021)。De La Rosa et al.(2021)运用机器学习方法建立了扫描电镜识别矿物与钻孔高光谱数据之间的关系模型,并将其应用于 7000 m 共 80 个钻孔的矿物含量评估。卷积神经网络(convolutional neural networks, CNN)是一种典型的深度学习方法,主要由

卷积层、池化层及全连接层组成,在图像处理及模式识别等领域广泛应用(万亚玲等, 2021)。在钻孔岩性识别研究中,一些学者尝试将卷积神经网络应用于岩心扫描获取的真彩色图像以进行岩性识别,并取得了一定效果(Baraboshkin et al., 2020; Alzubaidi et al., 2021; Houshmand et al., 2022),然而其研究未采用高光谱数据。

为此,为识别砂岩铀矿钻孔岩性,本次研究利用成像光谱仪扫描获取岩心高光谱影像,并基于卷积神经网络构建岩性识别模型,开展砂岩铀矿碎屑岩岩性自动分类,以期岩心数字化、自动化编录研究提供一定参考。

1 砂岩铀矿相关岩性与分类依据

1.1 砂岩铀矿相关岩性的地质分类

砂岩铀矿是一种产于沉积岩中的矿床,与沉积成岩和后生氧化作用关系密切。与砂岩铀矿相关的岩性是碎屑岩,主要包括砾岩、砂岩、泥岩,少量煤层和页岩。砂岩可以进一步按照构成岩石的碎屑颗粒大小分为粗砂岩、中砂岩、细砂岩和粉砂岩。砂岩由碎屑颗粒和填隙物两部分组成。碎屑颗粒常由石英、长石、白云母、方解石、粘土矿物、白云石、鲕绿泥石、绿泥石等组成;填隙物包括胶结物和碎屑杂基 2 种组分,常见的胶结物是硅质和碳酸盐,杂基成分主要指与碎屑同时沉积的颗粒更细的粘土或粉砂质物。

1.2 地质分类依据的成像光谱特征

1.2.1 成像光谱数据获取与处理

研究使用的岩心成像光谱数据由挪威 NEO 公司产的 HySpex 成像光谱仪获取,该仪器由独立成像的可见光-近红外高光谱相机和短波红外高光谱相机组成。其中,可见光-近红外相机 VNIR-1600 探测波长范围为 400~1000 nm,光谱采样间隔为 3.7 nm,波

段数为 160, 空间分辨率 0.18×0.36 mrad, 距离岩心 1 m 扫描时图像像素大小为 $0.18 \text{ mm} \times 0.36 \text{ mm}$, 每米岩心的数据量最高可达 1 GB 以上; 短波红外探测器 SWIR-320m-e 探测波长范围 1000~2500 nm, 光谱采样间隔 6.25 nm, 波段数为 256, 空间分辨率 0.75×0.75 mrad, 距离岩心 1 m 扫描时图像像素大小为 $0.75 \text{ mm} \times 0.75 \text{ mm}$, 每米岩心的数据量为 0.19 GB。

本文所用数据于 2022 年 12 月 3 日至 12 月 10 日在鄂尔多斯盆地西南部岩心库内获取, 包括 ZKH3 全孔约 1 200 m 岩心短波红外影像。原始数据在经过辐射定标、反射率反演、噪声滤除及岩心图像裁剪后(张川等, 2017)得到反射率光谱图像数据。

1.2.2 碎屑粒度空间特征

碎屑颗粒指构成岩石基本架构的矿物或岩屑, 颗粒大小是全部碎屑几何形态的统计特征, 碎屑颗粒的粒级决定了岩石的基本名称, 从而确定了岩性的类别。本次采集的 HySpex 短波红外数据的空间分辨率为 0.75 mm, 仅能反映粗砂(0.5~2 mm)及以上粒度的岩石结构, 因此仅从影像纹理的角度无法实现各类碎屑岩的区分, 无法满足砂岩铀矿勘查对于矿物粒度区分的要求。

1.2.3 胶结物的光谱特征

碎屑岩中的胶结物主要为硅质(SiO_2)和碳酸盐。硅质(SiO_2)在短波红外波段无明显吸收特征, 无法利用短波红外光谱直接识别。碳酸盐类在 2310~2350 nm 有明显的吸收特征, 其中方解石在 2330~2340 nm 有主吸收谷, 白云石在 2310~2320 nm 有主吸收谷, 在 2230 nm 处有次级吸收现象。

1.2.4 粘土矿物的吸收特征

陆相碎屑岩中的粘土矿物主要有伊利石、蒙脱石和伊蒙混层, 海相碎屑岩还发育鲕绿泥石、绿泥石等。这些矿物都有明显的吸收特征, 其中伊利石主要在 2200 nm 和 2345 nm 附近存在吸收特征, 蒙脱石的光谱吸收特征主要出现在 2000 nm 附近, 绿泥石在 2330~2350 nm 之间有主要吸收, 在 2250~2260 nm 附近有次级吸收(张川, 2020)。

综上所述, 碎屑岩胶结物和粘土矿物在短波红外波段具有较好的特征响应, 特征吸收的位置取决于岩石、矿物的化学成分, 吸收特征(吸收谷宽度和深度)取决于图像像元内这些成分的占比。由于胶结物和粘土矿物是砂岩中的填隙物, 其单位面积(体积)内的占比与碎屑颗粒的大小、形态和空间排列,

也就是砂岩的结构相关, 因此本研究重点采用影像光谱特征开展岩性识别。

2 岩性分类模型

2.1 卷积神经网络及深度学习岩性分类模型

卷积神经网络(CNN)作为深度学习中目前最常用的一种算法, 在高光谱遥感图像分类中广泛应用(万亚玲等, 2021)。主要由卷积层、池化层及全连接层组成。卷积层用来对输入信息赋予权重和求取目标不同方面的特征, 是网络的核心部分。池化层用于特征精炼, 加快网络收敛。全连接层通过每个神经元与前一层的所有神经元全连接, 实现对卷积层或取样层中能反映目标分类特征的局部信息进行整合。一维卷积神经网络本质上和卷积神经网络相同, 其输入为一维向量, 相应的计算公式如下:

$$x_j^l = f \left(\sum_{i=1}^M x_i^{l-1} k_{ij}^{l-1} + b_j^{l-1} \right) \quad (1)$$

式中, x_j^l 为第 l 层第 j 个神经元的激活值, x_i^{l-1} 为第 $l-1$ 层第 i 个神经元的激活值, k_{ij}^{l-1} 为第 l 层第 j 个神经元与第 $l-1$ 层第 i 个神经元之间的权重, b_j^{l-1} 为 $l-1$ 层所有神经元对 l 层第 j 个神经元的偏置, $f(\bullet)$ 是激活函数。利用高光谱包含的大量光谱信息, 结合一维卷积神经网络(1DCNN)可进行矿物识别(田青林等, 2022)、地物分类(Hu et al., 2015)、药物成分(Guo et al., 2022)分析、湖泊沉积物粒度回归(Ghanbari and Antoniadis, 2022)等研究, 并取得了较好的效果, 体现出基于 1DCNN 的模型在光谱研究中具有较大的潜力。

本次研究利用一维卷积神经网络(1DCNN)通过对输入的一维光谱数据进行处理, 实现对钻孔岩性的分类。由于不同矿物的光谱在不同位置会形成吸收谷, 同时吸收谷的宽度、深度受岩石的粒度和矿物组成影响, 因此在模型中引入 Inception 结构(Szegedy et al., 2016), 在准确提取吸收特征的同时提升计算效率。为解决网络退化问题, 在模型中引入了残差网络的短接技术(He et al., 2016)。此外, 为高效分配和利用计算资源, 在模型中采用了 CBAM 注意力机制(Woo et al., 2018)。综上, 本文设计了如下岩心成像光谱岩性识别模型, 模型包括 7 个一维卷积层、2 个池化层、1 个一维卷积注意力模块, 以及 3 个全连接层(图 1-a)。模型中 Concat 函数用于

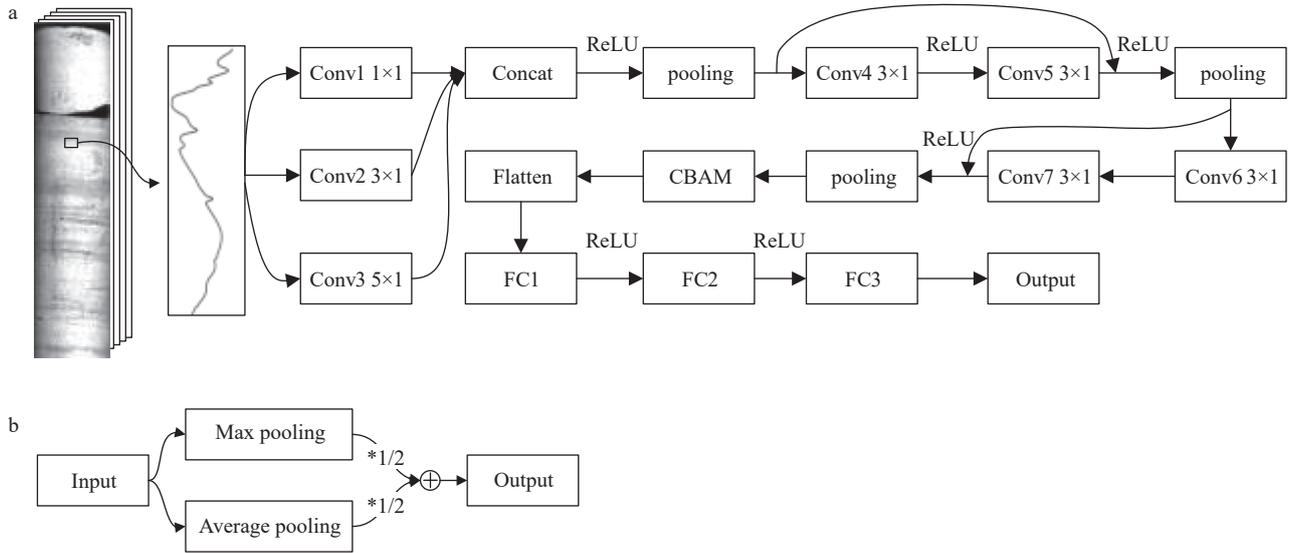


图 1 钻孔岩心成像光谱岩性识别 1DCNN 模型结构

Fig. 1 1DCNN model structure for core lithology identification using hyperspectral data

a—模型总体结构; b—池化层

张量拼接, 线性整流函数 (Retified Linear Units, ReLU) 用于激活, Flatten 函数用于将多维输入一维化。针对池化层, 本次研究采用了最大池化与平均池化相结合的方式 (图 1-b), 整个网络的具体参数如表 1 所示。

模型以像元光谱数据为输入层, 首先以 3 个不同尺寸的卷积核同时提取不同特征, 再经历一系列卷积和池化操作后, 获取了抽象特征。随后导入一维卷积注意力模块, 从通道和空间上加入注意力机制。最后经过 3 个全连接层输出分类结果。

2.2 支持向量机分类模型

支持向量机 (support vector machines, SVM) 作为

机器学习方法的典型代表 (管耀等, 2024), 较其他机器学习算法, 如最大似然及神经网络分类, 具有更高的分类效果 (Ye et al., 2020), 因而在遥感岩性分类领域广泛应用 (Yu et al., 2012; Ye et al., 2020; Shirmard et al., 2022)。其机理是寻找一个满足分类要求的最优分类超平面, 使该超平面在保证分类精度的同时, 能够使超平面两侧的空白区域最大化 (丁世飞等, 2011)。SVM 的性能取决于核函数, 由于基于径向基函数 (radial basis function, RBF) 的 SVM 在多光谱和高光谱影像中优异的性能 (Karimzadeh and Tangestani, 2021; 管耀等, 2024), 在本文中选用。此外, 模型也包括惩罚系数 C 及参数 gamma, 值分别为 100 和 10。前者用于平衡模型复杂度和误分率之间的关系。当 C 较小时, 支持向量及超平面的模型较简单, 离散群点数量增加, 误分率较高; 反之, 容易发生过拟合。后者用来度量两点之间的差异 (李鹏等, 2022)。以上 2 个参数可通过迭代实验获取。

3 岩性分类实验

3.1 样本集构建

标签样本的构建是深度学习研究的基础, 充足的训练样本有助于网络模型充分学习样本类内特征和类间差异, 从而大大提升模型的效果。地质编录资料显示, ZKH3 整孔岩心岩性主要包括泥岩、粉砂质泥岩、粉砂岩、细砂岩、中砂岩、中粗砂岩、粗砂

表 1 一维卷积神经网络参数

Table 1 The parameters of 1DCNN

网络结构	卷积核/窗口大小	步长	卷积核/输出通道数	零填充
Conv1	1	1	32	-
Conv2	3	1	32	1
Conv3	5	1	32	2
pooling	2	1	32	-
Conv4	3	1	16	1
Conv5	3	1	32	1
Conv6	3	1	64	1
Conv7	3	1	32	1
pooling	2	1	32	-
FC1	-	-	1000	-
FC2	-	-	256	-
FC3	-	-	7	-

岩、砂砾岩、砾岩等。考虑到有些岩性类别受肉眼影响容易混淆,为此对上述岩性类别进行梳理整合,将粉砂质泥岩归为泥岩,中粗砂岩归为粗砂岩,砾岩归为砂砾岩。同时,为去除背景干扰,引入背景类,包括岩心箱、阴影、岩心牌、干树叶等。最终分类类别为泥岩、粉砂岩、细砂岩、中砂岩、粗砂岩、砂砾岩及背景共 7 类。

依据上述确定的类别,结合地质编录资料从岩心高光谱影像上选取样本光谱。大体操作为:①打开成像光谱数据和岩心照片,利用地质编录资料及岩心照片,在高光谱图像上找到岩性描述较准确的位置,圈定感兴趣区;②按感兴趣区的岩性类别输出对应岩石类型的 CSV 文件。为方便后续处理,将相同岩石类型的 CSV 文件放入同一文件夹,文件夹名称对应岩石类别标签;③将同一文件夹下所有 CSV 文件进行合并和处理,并添加类别标签信息,最终 CSV 文件共 257 列,前 256 列为波段,最后一列为岩性标签,每一行记录一条样本光谱;④比较待检测波段与前后 2 个波段的反射率关系,剔除异常样本。为提高选取样本的准确性,多从每个回次的开始或结束处挑选岩石类型。这是由于在地质编录中,每个回次的开始或结束处记录的位置、岩性特征更加清楚明确,因而样本选取会更容易和准确。此外,为提高模型的泛化能力,对整个钻孔按深度均匀取样。

依照上述处理流程,本次研究共选取了 7 类岩性 26877 条样本光谱(表 2;图 2)。其中泥岩、细砂岩、中砂岩、粗砂岩样本较多,而粉砂岩、砂砾岩及背景干扰类样本相对较少。为方便后续网络的训练及验证,按 7:3 将总样本划分为训练集和测试集。

3.2 模型评价方法

本次研究采用总体分类精度(Overall Accuracy, OA)、生产者精度(Producer's Accuracy, PA)、平均分类精度(Average Accuracy, AA)及 Kappa 系数对模型性能进行评价。这些指标的值越大,表示模型的分精度越高。总体分类精度表示正确分类的样本数与总体样本数的比值;生产者精度指每个类别真实参考数据被正确分类的概率,即类别正确分类样本数与该类总体样本数的比值;平均分类精度是所有类别生产者精度的平均值;Kappa 系数为测试样本的分类预测类别与实际类别的一致性检测指标系数,其值落在 [0,1] 范围内(万亚玲等, 2021; Agrawal and Govil, 2023)。

3.3 模型训练与超参数确定

以随机梯度下降(stochastic gradient descent, SGD)为优化器,并以交叉熵损失表示预测值与真实值之间的差异,对模型进行训练、优化及改进。

学习率、批量值(batch-size)及轮次 epoch 是影响模型性能的重要超参数,可通过先设计后实验的方法确定。为比较不同学习率对模型性能的影响,以 0.1、0.05、0.01、0.005、0.001、0.0005 共 6 种学习率进行实验,结果表明,学习率为 0.01 时模型精度相对最大达 94.8%,损失相对最小为 0.135。为比较批量值对模型性能的影响,分别以 64、128、256、512 四种大小进行实验。实验结果表明,当批量值大小为 64 或 128 时精度相对最高,误差相对最小(表 3)。为缩短训练时间,最终将批量值设置为 128。

为评价轮次对模型性能的影响,对模型进行 1000 轮次训练,其中模型的学习率、批量值大小分别为 0.01 和 128。实验结果显示,随着轮次的增加,模型的权重不断更新,模型精度在训练集和验证集上都不断增加。对于验证集,模型的精度在 520 个轮次训练后几乎不再变化,精度为 95.5%(图 3-a);模型的误差呈现先降低后增高的趋势,反映出模型由最初的欠拟合过渡到最佳拟合后出现过拟合的状态,其最佳拟合出现在 200 轮次附近(图 3-b)。为此最终将轮次设置为 200。

4 结果与讨论

基于实验确定的超参数,即轮次为 200,学习率为 0.01,批量值为 128,对模型进行训练。经过训练,模型在验证集中的总体精度 OA 为 94.6%,误差为 0.14。图 4 为模型在验证集上的混淆矩阵热力图,其横轴表示真实标签的数目统计,纵轴表示预测的类别数目统计。

从图 4 可发现,泥岩、粉砂岩、细砂岩、中砂岩、粗砂岩、砂砾岩及背景的生产者精度 PA 分别为 95.07%、72.02%、97.50%、97.37%、96.65%、97.33%、99.01%,除粉砂岩 PA 低于 95% 外,其余类别均大于 95%。其中,模型对背景的认识更是达到了 99%,反映模型能很好地区分背景干扰(图 4)。基于各类别生产者精度 PA,计算得到相应的平均分类精度 AA 为 93.65%。Kappa 系数为 0.94,其值大于 0.8,反映样本预测类别与实际类别具有良好的一致性。总体而言,经过训练的深度学习岩性识别模型

分类精度高、性能好,能够很好地识别泥岩、粉砂岩、细砂岩、中砂岩、粗砂岩、砂砾岩及背景。

为了进一步比较模型效果,验证本文建立的深度学习模型的性能,基于训练集和测试集,对支持向量机(support vector machines, SVM)进行了实验。经试验惩罚系数 C 和 γ 分别为 100 和 10,据此基于 SVM 开展岩性分类,结果显示其在验证集上的总体精度 OA 为 93.4%。图 5 为基于 SVM 的识别模型在验证集上的混淆矩阵热力图,从图 5 可发现,泥岩、粉砂岩、细砂岩、中砂岩、粗砂岩、砂砾岩及背景的生产者精度 PA 分别为 95.48%、77.01%、94.55%、96.55%、92.08%、94.98%、98.68%。与深度

学习岩性识别模型类似,粉砂岩生产者精度最低(图 4)。基于 SVM 方法的平均精度 AA 和 Kappa

表 2 各类总样本数

Table 2 The total number of samples of each type

类别	样本数	标签
泥岩	5776	0
粉砂岩	2364	1
细砂岩	4539	2
中砂岩	4884	3
粗砂岩	5188	4
砂砾岩	2122	5
背景	2004	6

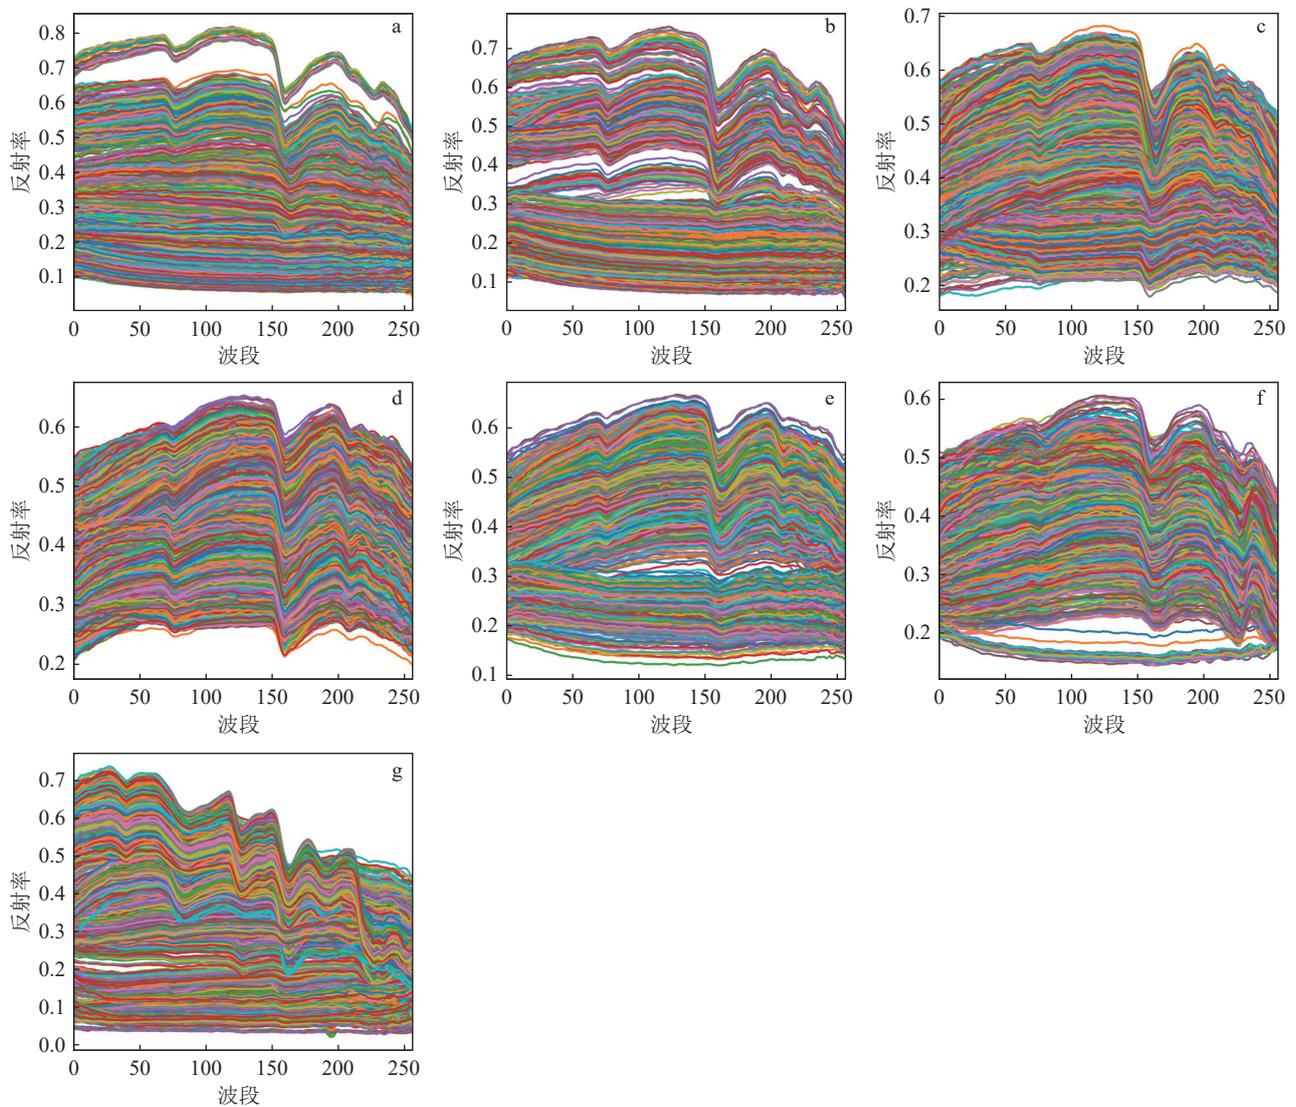


图 2 岩性样本与背景的光谱曲线集

Fig. 2 Spectral curves of the six types rock and the background

a—泥岩; b—粉砂岩; c—细砂岩; d—中砂岩; e—粗砂岩; f—砂砾岩; g—背景

系数分别为 92.78%、0.92。

图 6 反映了各评价指标在 2 种模型上的差异。从图 6 看出, 两类模型针对粉砂岩类的生产者精度 PA 均小于 80%, 远低于其他类别。对于深度学习模型, 在所有真实粉砂岩样本中, 有 27.56% 的样本被错分为泥岩(图 4)。而对于 SVM 模型, 也有 22.85% 的样本被错分为泥岩(图 5)。其可能的原因有 2 个, 一是由于粉砂岩与泥岩粒度接近, 地质编录时很容易错分, 致使以地质编录资料为参考进行样本选取时, 容易将二者混淆, 即在粉砂岩参考样本选取时有部分泥岩光谱混入; 二是原始岩心表面受泥土污染, 粉砂岩光谱受到改变。对所有评价指标进行观察, 也可发现除泥岩和粉砂岩类的生产者精度支持向量模型占优外, 其余指标均是深度学习模型占优(图 6), 反映深度学习模型优于支持向量模型。

结果表明, 本次研究构建的深度学习岩性识别模型分类精度较高、性能较好, 能够识别泥岩、粉砂岩、细砂岩、中砂岩、粗砂岩、砂砾岩及背景。

利用上述模型, 对 ZKH3 整孔岩心进行岩性识别, 模型对岩心高光谱图像中每个像元均进行了分类, 得到了岩性分类结果。图 7 展示了部分岩心段数码相机拍摄照片、短波红外影像(R、G、B 分别为 band81、band201、band49)及分类结果。

以 550.0~551.4 m 岩心段为例, 地质编录显示均为细砂岩, 而数码相机照片及高光谱影像上肉眼观察可发现其中存在一小段(宽约 10 cm)岩石的色调或形状完全不同于上下两侧岩石(图 7-a)。通过光

谱分析对比, 该段光谱与两侧岩石光谱差异显著。尤其是在 1000~1350 nm 区间段, 该段光谱曲线先降低后升高, 而两侧岩石光谱曲线不断升高。此外, 两侧岩石光谱除反射高低存在一定差异外, 整体表现出相似的光谱特征, 为同类岩性(图 8)。本文的识别模型除准确将此段岩心分类为细砂岩外, 还成功地从细砂岩中区分出这小段泥岩(图 7-a)。在 1175.5~1176.8 m 岩心段, 地质编录显示主要是砂砾岩和中砂岩, 数码相机照片上目视观察可发现 2 种岩性在颜色、色调、纹理等方面存在明显差异, 深度学习分类很好地识别了这 2 段岩性, 岩性分界线清晰, 分类结果与实际一致性较高(图 7-b)。总体而言, 基于成像光谱的深度学习模型, 成功实现了对砂岩铀矿相关岩性的识别与分类, 取得了与地质编录相当的效果。

表 3 不同学习率、批量值时模型精度及损失对比

Table 3 Comparison of model accuracy and loss under different learning rates or batch sizes

编号	超参数	学习率	精度	损失
1	学习率	0.1	65.4%	0.907
2		0.05	89.7%	0.247
3		0.01	94.8%	0.135
4		0.005	94.3%	0.141
5		0.001	92.5%	0.186
6		0.0005	90.0%	0.247
7	批量值	64	94.3%	0.138
8		128	94.3%	0.138
9		256	93.6%	0.148
10		512	92.5%	0.175

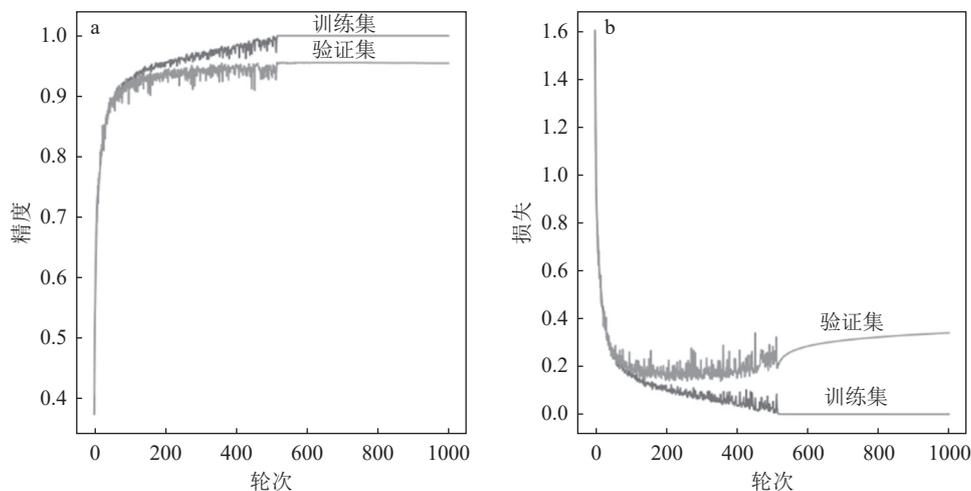


图 3 轮次与模型精度和误差的关系

Fig. 3 The relationship between epochs and model accuracy and loss

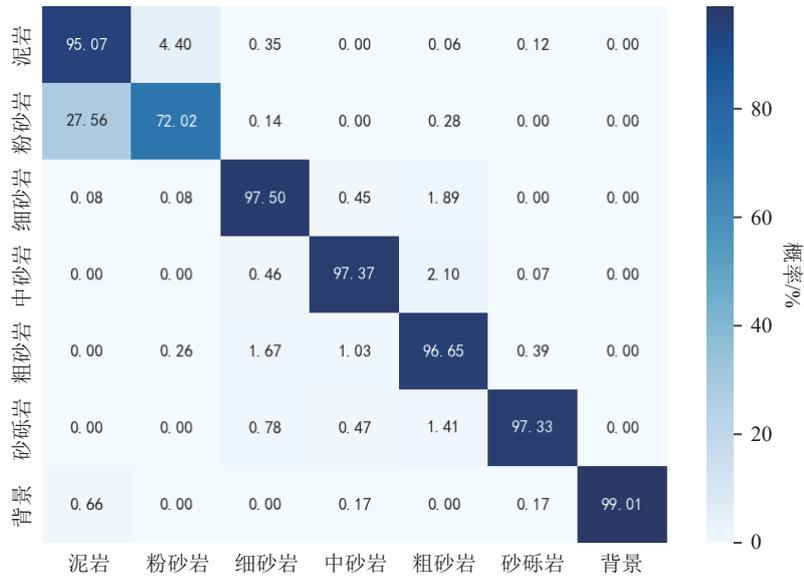


图 4 1DCNN 模型在验证集上的混淆矩阵

Fig. 4 Confusion matrix of the 1DCNN model on the verification set

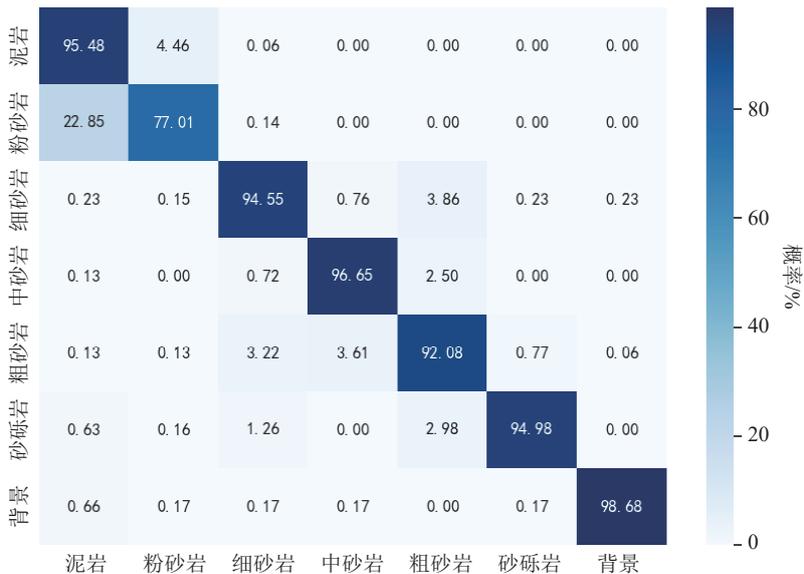


图 5 SVM 模型在验证集上的混淆矩阵

Fig. 5 Confusion matrix of the SVM model on the verification set

值得注意的是,由于高光谱数据包含丰富的光谱和空间信息,随着图像处理、机器学习乃至深度学习技术的进步,基于岩心高光谱数据,通过建立相应的识别模型,实现岩性、蚀变、构造等地质信息的一体化识别,进而实现岩心数字化、自动化及智能化编录将是研究重点。

5 结论

为了适应砂岩铀矿勘查数字化和信息化的要

求,本文针对传统岩心地质编录受编录者主观因素影响且费时费力的问题,研究利用岩心高光谱影像和深度学习模型开展岩心分类识别的方法。通过样本选择、卷积神经网络模型构建、模型训练及应用等实现了钻孔岩性分类识别。

(1)构建了基于岩心高光谱数据的参考样本库制作流程,指出在以地质编录资料为参考进行样本库构建时,样本选取应该优先考虑每个回次的开始或结束处位置,同时取样位应均匀分布于整孔。

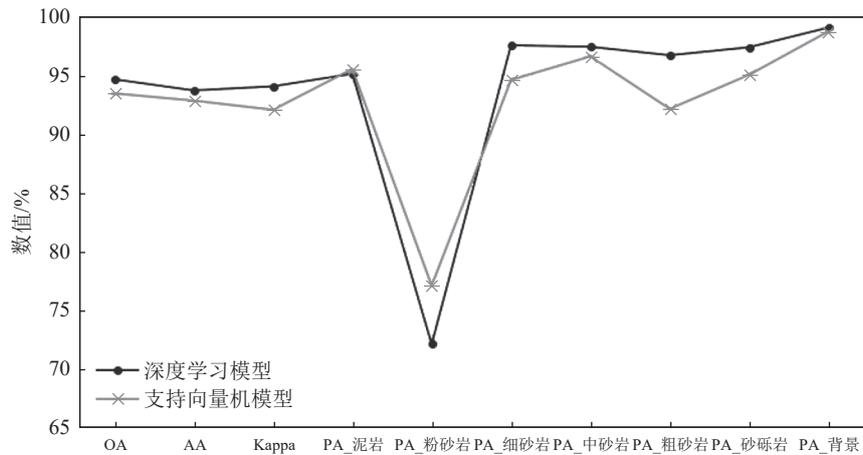


图 6 两类模型评价指标对比

Fig. 6 Comparison of evaluation metrics between two models

OA—总体分类精度; AA—平均分类精度; PA—生产者精度; Kappa—通过总体精度与偶然一致性误差比值计算的标准指标

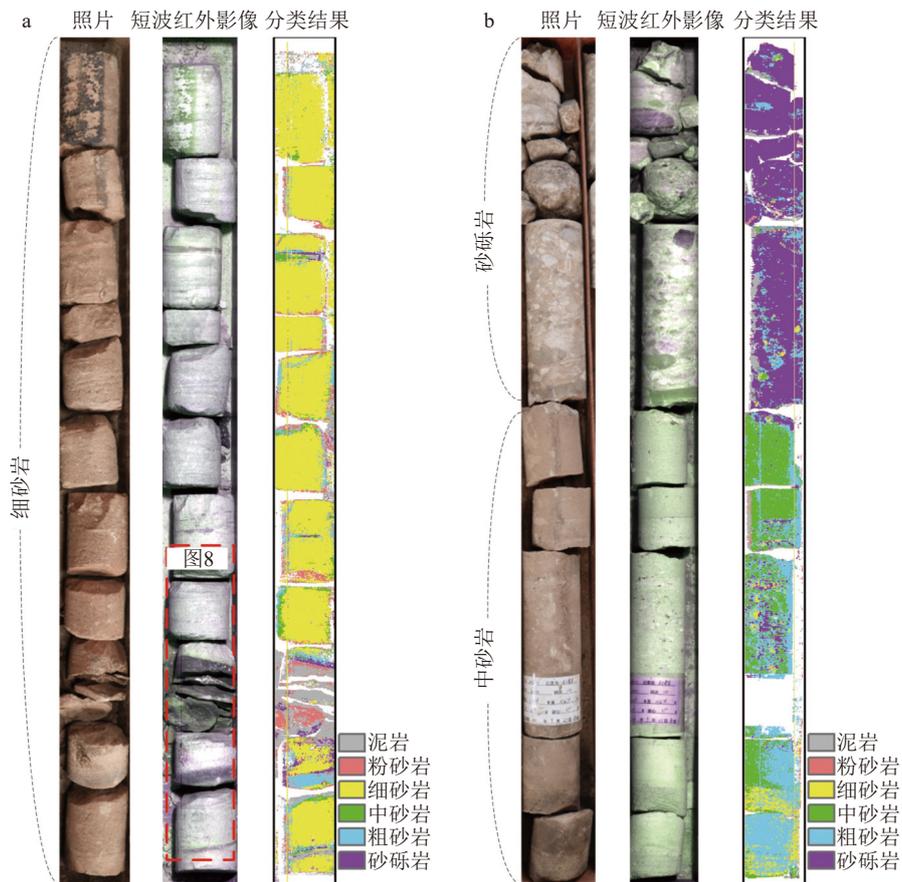


图 7 部分岩心段分类效果对比

Fig. 7 Comparison of 1DCNN classification results with geology coding and photos of selected cores

a—550.0~551.4 m 岩心段; b—1175.5~1176.8 m 岩心段

(2) 本文构建的 1DCNN 模型总体精度 OA 可达 94.6%, 较 SVM 模型性能好, 对泥岩、粉砂岩、细砂岩、中砂岩、粗砂岩、砂砾岩及背景

的 PA 分别为 95.07%、72.02%、97.50%、97.37%、96.65%、97.33%、99.01%, Kappa 系数为 0.94, 表明基于岩心成像光谱的深度学习模型能有效地进行岩性分类

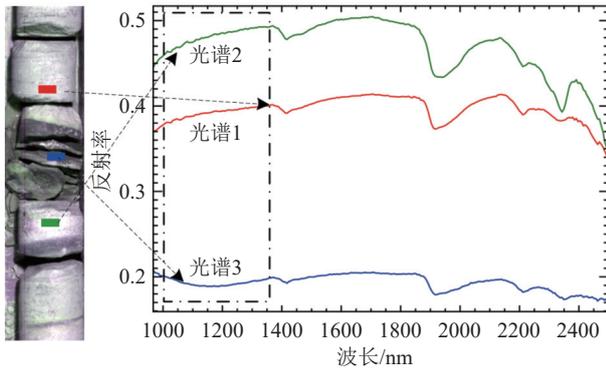


图8 550.0~551.4 m岩心段中局部段光谱特征对比

Fig. 8 Comparison of spectral characteristics in the 550.0~551.4 m core section

识别。

(3)以岩心高光谱数据为基础,后续建议加强深度学习等智能技术的应用,以提高岩心地学信息自动化及智能化编录的水平。

致谢:感谢核工业北京地质研究院贺锋高级工程师在野外岩心扫描工作中给予的支持与帮助,感谢审稿专家提出的宝贵意见。

References

- Agrawal N, Govil H. 2023. A deep residual convolutional neural network for mineral classification[J]. *Advances in Space Research*, 71(8): 3186–3202.
- Alzubaidi F, Mostaghimi P, Swietojanski P, et al. 2021. Automated lithology classification from drill core images using convolutional neural networks[J]. *Journal of Petroleum Science and Engineering*, 197: 107933.
- Baraboshkin E E, Ismailova L S, Orlov D M, et al. 2020. Deep convolutions for in-depth automated rock typing[J]. *Computers & Geosciences*, 135: 104330.
- De La Rosa R, Khodadadzadeh M, Tusa L, et al. 2021. Mineral quantification at deposit scale using drill-core hyperspectral data: A case study in the Iberian Pyrite Belt[J]. *Ore Geology Reviews*, 139: 104514.
- Ding S F, Qi B J, Tan H Y. 2011. An overview on theory and algorithm of support vector machines[J]. *Journal of University of Electronic Science and Technology of China*, 40(1): 2–10 (in Chinese with English abstract).
- Ghanbari H, Antoniadou D. 2022. Convolutional neural networks for mapping of lake sediment core particle size using hyperspectral imaging[J]. *International Journal of Applied Earth Observation and Geoinformation*, 112: 102906.
- Greenberger R N, Harris M, Ehlmann B L, et al. 2021. Hydrothermal alteration of the ocean crust and patterns in mineralization with depth as measured by micro-imaging infrared spectroscopy[J]. *Journal of Geophysical Research: Solid Earth*, 126(8): e2021JB021976.
- Guan Y, Wang Q H, Feng J, et al. 2024. Comprehensive lithology recognition of altered igneous reservoirs based on machine learning for wireline and cutting logs in Huizhou depression, Pearl River Mouth Basin, northern South China Sea[J]. *Journal of Jilin University (Earth Science Edition)*, 51(1): 345–358 (in Chinese with English abstract).
- Guo T, Xu F, Ma J, et al. 2022. Component prediction of antai pills based on one-dimensional convolutional neural network and near-infrared spectroscopy[J]. *Journal of Spectroscopy*, (1): 1–10.
- He K, Zhang X, Ren S, et al. 2016. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition: 770–778.
- Houshmand N, GoodFellow S, Esmaeili K, et al. 2022. Rock type classification based on petrophysical, geochemical, and core imaging data using machine and deep learning techniques[J]. *Applied Computing and Geosciences*, 16: 100104.
- Hu W, Huang Y, Wei L, et al. 2015. Deep convolutional neural networks for hyperspectral image classification[J]. *Journal of Sensors*, 2015: 1–12.
- Karimzadeh S, Tangestani M H. 2021. Evaluating the VNIR-SWIR datasets of WorldView-3 for lithological mapping of a metamorphic-igneous terrain using support vector machine algorithm: A case study of Central Iran[J]. *Advances in Space Research*, 68(6): 2421–2440.
- Li P, Jiang N S, Feng Z P, et al. 2022. Freshly-opened swidden mapping using Support Vector Machine (SVM) and spatial characteristics in Phongsaly Province, Laos[J]. *National Remote Sensing Bulletin*, 26(11): 2329–2343 (in Chinese with English abstract).
- Lu Y. 2018. Applications of hyperspectral mineral mapping in mineral and petroleum exploration[D]. China University of Geosciences (Beijing) PhD Thesis (in Chinese with English abstract).
- Mathieu M, Roy R, Launeau P, et al. 2017. Alteration mapping on drill cores using a HySpex SWIR-320m hyperspectral camera: Application to the exploration of an unconformity-related uranium deposit (Saskatchewan, Canada)[J]. *Journal of Geochemical Exploration*, 172: 71–88.
- Shirmard H, Farahbakhsh E, Müller R D, et al. 2022. A review of machine learning in processing remote sensing data for mineral exploration[J]. *Remote Sensing of Environment*, 268: 112750.
- Speta M, Gingras M K, Rivard B. 2016. Shortwave infrared hyperspectral imaging: A novel method for enhancing the visibility of sedimentary and biogenic features in oil-saturated core[J]. *Journal of Sedimentary Research*, 86(7): 830–842.
- Szegedy C, Vanhoucke V, Ioffe S, et al. 2016. Rethinking the inception architecture for computer vision[C]//Proceedings of the IEEE conference on computer vision and pattern recognition: 2818–2826.
- Tappert M C, Rivard B, Fulop A, et al. 2015. Characterizing kimberlite dilution by crustal rocks at the Snap Lake diamond mine (Northwest Territories, Canada) using SWIR (1.90–2.36 μm) and LWIR (8.1–11.1 μm) hyperspectral imagery collected from drill core[J]. *Economic Geology*, 110(6): 1375–1387.

- Tian Q L, Guo B J, Ye F W, et al. 2022. Mineral spectra classification based on one-dimensional dilated convolutional neural network[J]. *Spectroscopy and Spectral Analysis*, 42(3): 873–877 (in Chinese with English abstract).
- Tusa L, Andreani L, Khodadadzadeh M, et al. 2019. Mineral mapping and vein detection in hyperspectral drill-core scans: Application to porphyry-type mineralization[J]. *Minerals*, 9(2): 122.
- Wan Y L, Zhong X W, Liu H, et al. 2021. Survey of application of convolutional neural network in classification of hyperspectral images[J]. *Computer Engineering and Applications*, 57(4): 1–10 (in Chinese with English abstract).
- Woo S, Park J, Lee J Y, et al. 2018. Cbam: Convolutional block attention module[C]//*Proceedings of the European conference on computer vision (ECCV)*, Germany: 3–19.
- Ye B, Tian S, Cheng Q, et al. 2020. Application of lithological mapping based on advanced hyperspectral imager (AHSI) imagery onboard Gaofen-5 (GF-5) satellite[J]. *Remote Sensing*, 12(23): 3990.
- Yu J, Zhang L, Li Q, et al. 2021. 3D autoencoder algorithm for lithological mapping using ZY-1 02D hyperspectral imagery: A case study of Liuyuan region[J]. *Journal of Applied Remote Sensing*, 15(4): 1–14.
- Yu L, Porwal A, Holden E J, et al. 2012. Towards automatic lithological classification from remote sensing data using support vector machines[J]. *Computers & Geosciences*, 45: 229–239.
- Zhang C, Ye F W, Yao J L, et al. 2017. Implementation method of drill core logging based on imaging spectrometer[J]. *Remote Sensing Information*, 32(5): 69–74 (in Chinese with English abstract).
- Zhang C, Ye F W, Xu Q J, et al. 2019. Deep drill logging and its alteration zoning features based on hyperspectral core imaging in west of Xiangshan uranium orefield[J]. *Remote Sensing for Land and Resources*, 31(2): 231–239 (in Chinese with English abstract).
- Zhang C. 2020. Core imaging spectroscopy and three-dimensional alteration modeling for uranium deposit in Xiangshan, Jiangxi[D]. China University of Geosciences (Beijing), PhD Thesis: 1–150 (in Chinese with English abstract).
- Zhang J L, Huang Y J, Wang J H, et al. 2013. Hyperspectral drilling core logging and 3D mineral mapping technology for uranium exploration[J]. *Uranium Geology*, 29(4): 249–255 (in Chinese with English abstract).

附中文参考文献

- 丁世飞, 齐丙娟, 谭红艳. 2011. 支持向量机理论与算法研究综述[J]. *电子科技大学学报*, 40(1): 2–10.
- 管耀, 王清辉, 冯进, 等. 2024. 基于机器学习的蚀变火成岩测录井综合岩性识别——以南海北部珠江口盆地惠州 26-6 井区为例[J]. *吉林大学学报(地球科学版)*, 54(1): 345–358.
- 李鹏, 蒋宁桑, 封志明, 等. 2022. 基于支持向量机的老挝丰沙里省新开辟刀耕火种遥感监测及其空间特征[J]. *遥感学报*, 26(11): 2329–2343.
- 卢燕. 2018. 高光谱矿物填图技术在金属矿产和油气勘查中的应用研究[D]. 中国地质大学(北京)博士学位论文.
- 田青林, 郭帮杰, 叶发旺, 等. 2022. 一维空洞卷积神经网络的矿物光谱分类[J]. *光谱学与光谱分析*, 42(3): 873–877.
- 万亚玲, 钟锡武, 刘慧, 等. 2021. 卷积神经网络在高光谱图像分类中的应用综述[J]. *计算机工程与应用*, 57(4): 1–10.
- 张川. 2020. 岩心成像光谱技术与江西相山铀矿蚀变三维建模[D]. 中国地质大学(北京)博士学位论文: 1–150.
- 张川, 叶发旺, 徐清俊, 等. 2019. 相山铀矿田西部深钻岩心成像光谱编录及蚀变分带特征[J]. *国土资源遥感*, 31(2): 231–239.
- 张川, 叶发旺, 姚佳蕾, 等. 2017. 成像光谱钻孔岩芯编录的实现方法[J]. *遥感信息*, 32(5): 69–74.
- 张杰林, 黄艳菊, 王俊虎, 等. 2013. 铀矿勘查钻孔岩心高光谱编录及三维矿物填图技术研究[J]. *铀矿地质*, 29(4): 249–255.