

<https://doi.org/10.3799/dqkx.2018.987>



基于卷积神经网络的高分遥感影像露天采矿场识别

程国轩, 牛瑞卿*, 张凯翔, 赵凌冉

中国地质大学地球物理与空间信息学院, 湖北武汉 430074

摘要: 矿山环境监测常用遥感影像, 研究卷积神经网络 (convolutional neural network, CNN) 对高分遥感影像露天采矿场识别有利于提高监测效率. 针对因训练数据量小而导致 CNN 对露天采矿场识别精度不高的问题, 采用了3种迁移学习方案对 CNN 的预训练模型进行训练与对比分析, 发现冻结 CNN 预训练模型底层参数并微调高层参数的迁移学习方法训练效果最佳, 在验证数据上的生产者精度与用户精度均超过 87%. 实验结果表明, 本方法训练的 CNN 能提升高分遥感影像中露天采矿场的识别效率, 可作为遥感解译露天采矿场中的辅助手段.

关键词: 露天采矿场; 遥感监测; 迁移学习; 卷积神经网络; 遥感.

中图分类号: P627

文章编号: 1000 - 2383(2018)S2 - 0256 - 07

收稿日期: 2018 - 11 - 10

Opencast Mining Area Recognition in High-Resolution Remote Sensing Images Using Convolutional Neural Networks

Cheng Guoxuan, Niu Ruiqing*, Zhang Kaixiang, Zhao Lingran

Institute of Geophysics & Geomatics, China University of Geosciences, Wuhan 430074, China

Abstract: The application of remote sensing is a commonly used approach to environmental monitoring in mine areas. The research on convolutional neural network (CNN) for recognition of opencast mining area in high-resolution remote sensing image could help to improve monitoring efficiency. This paper focused on the problem of low classification accuracy of opencast mining area based on CNN due to insufficient trained datasets, the experiment is designed with three types of transfer learning methods and tested in different pre-trained CNN models. The analysis shows that by contrast, fixed lower layers' parameters in pre-trained CNN models and fine-tune higher layers' parameters is the optimal training method, it achieved over 87% in both producer's accuracy and user's accuracy. This experimental results indicate that opencast mining area could be effectively recognized in high-resolution imagery based on this training method, therefore, the CNN which trained by this method can be used as an aid in remote sensing interpretation of opencast mining area.

Key words: opencast mining area; remote sensing monitoring; transfer learning; convolutional neural networks; remote sensing.

0 引言

露天开采所导致的地质灾害与环境污染的防治问题, 已成为矿山地质环境保护的重要研究内容之一 (李夏, 2017). 利用高分遥感影像识别露天采矿场, 可以为矿区地质环境监督管理提供基础资料和科学依据 (康日斐, 2017).

利用高分辨率遥感影像识别露天采矿场的技术, 主要分为基于像素的监督分类与面向对象分类. 例

如祝振江 (2010) 利用面向对象的分类技术, 在 Spot-5 遥感影像上提取出露天采矿场信息; 侯飞和胡召玲 (2012) 通过优化面向对象中多尺度分割, 提高了遥感影像中煤矿区地物要素的分类精度; 荆平等 (2017) 利用无人机遥感数据与面向对象的方法识别矿区开采面的信息; 漆小英等 (2008) 以攀枝花为例, 通过结合监督分类和土壤调节大气耐抗制备指数差值相结合的方法, 对钒钛磁铁矿的扩展信息进行有效提取; Demirel *et al.* (2011) 发现支持向量机算法对露天煤矿区

基金项目: 河南省矿山地质环境动态监测遥感解译项目 (No.106-KZ16Z20073).

作者简介: 程国轩 (1991 -), 男, 硕士研究生, 主要从事遥感地质研究. ORCID:0000-0001-7471-2631. E-mail:1201520078@cug.edu.cn

* 通讯作者: 牛瑞卿, E-mail:rqnui@163.com

引用格式: 程国轩, 牛瑞卿, 张凯翔, 等, 2018. 基于卷积神经网络的高分遥感影像露天采矿场识别. 地球科学, 43 (Suppl. 2): 256-262.

有很好的分类效果. 这些识别方法虽然简单易行, 但仅提取了影像的波段、纹理、结构等底层特征, 缺乏对露天采矿场高级语义特征的利用 (曹林林等, 2016).

卷积神经网络 (convolutional neural network, CNN) 能够通过多层网络结构逐层提取影像的高级语义特征, 在高分遥感影像识别中已被应用于车辆识别和土地利用分类 (Zhu *et al.*, 2017). 从头训练 CNN 的方法需要大量带标签的样本, 而实际带标签的露天采矿场样本量较小, 直接使用小样本训练的 CNN 识别精度不高 (许凤晖等, 2016). 本文研究 CNN 中迁移学习的训练方法, 以减少对训练数据量的要求, 提高露天采矿场的识别精度.

1 研究区和数据集

1.1 研究区概况

选择河南省鹤壁市部分矿区为研究区. 鹤壁市位于河南省北部, 地处华北平原与太行山东麓的交界处, 地势为西东低下, 地貌类型由中平原、低山和丘陵组成, 全市总面积 2 182 km². 鹤壁市属半干旱大陆性气候, 年平均降水量 654.2 mm. 露天开采导致的地形地貌景观破坏、滑坡与崩塌, 是鹤壁市矿山地质环境面临的主要问题之一 (孙森和杨春丽, 2012).

研究区影像 (图1) 由高分二号 (GF-2) 数据的全色与多光谱融合后的真彩色波段合成, 空间分辨率 1 m. 研究区地理坐标为 114°9'E, 35°41'N. 研究区露天采矿场分布密集, 露天开采剥离的矿层上部的土

石以及开采过程中产生的废渣, 对地形地貌景观造成不同程度地破坏.

1.2 实验数据集

实验数据集采用预处理后的 GF-2 遥感数据, 预处理包括几何校正与融合, 空间分辨率为 1 m. 实验数据集包括训练集、测试集和验证数据. 其中训练集与测试集包含 7 类场景 (图2), 分别是梯田、露天采矿场、道路、建筑、农田、森林、河流. 训练集用于 CNN 的迁移学习, 每类 80 幅; 测试集用于算法验证, 每类 16 幅. 验证数据为研究区的 GF-2 预处理数据, 用于评价算法在区域内识别露天采矿场的精度.




图 1 研究区遥感影像

Fig.1 The remote sensing images of the study area




图 2 训练集与测试集图像实例

Fig.2 Sample images of training set and test set

a. 农田; b. 建筑; c. 梯田; d. 森林; e. 河流; f. 道路; g. 露天采矿场

2 模型与方法

2.1 CNN-F 模型

本文采用 Ken 设计的网络框架 CNN-F(Chatfield *et al.*, 2014).CNN-F 是 8 层网络结构,其中前 5 层是卷积层,后 3 层是全连接层,输入图像大小为 224×224 .图 3 展示了 CNN-F 的网络结构.

卷积层与全连接层的参数如表 1 所示.卷积层与全连接层的网络结构包含 5 个卷积层和 2 个全连接层.对于每一个卷积层,Size 为卷积核的尺寸,Num 表示卷积核数量, stride、pad 和 pool 分别表示卷积步长、空间填充和降采样池化.全连接层 fc6 和 fc7 的神经元数分别为 4096 和 4096,最后一层 fc8 作为 softmax 分类器.

2.2 ResNet-50 模型

He *et al.*(2015) 提出深度残差网络 ResNet-50 是在传统卷积网络的基础上,开发出的一种减轻网络训练负担的残差学习框架.通过跨层连接形成的残差块,可以解决网络层数增多而导致的梯度下降问题,使反向传播中网络参数能更好的优化,提高网络对特征的提取能力.

图 4 展示了 ResNet-50 的网络结构,主要由 1 层卷积层与 16 个残差块组成,全连接层包含平均池化层与 softmax 分类器,网络的输入图像大小为 224×224 .

ResNet-50 模型的参数如表 2 所示,Num 代表卷积核的数量, size \times size 表示卷积核尺寸,括号外乘号后面的数字表示残差块的个数.网路的全连接层 fc 包括平均池化层与 softmax 分类器.

2.3 迁移学习

由于训练 CNN 需要大量数据,当数据量不足时,还可能会出现过拟合的现象 (Caruana, 1994; Bengio *et al.*, 2011; Bengio, 2012).为了解决这个问题通常会引入迁移学习的方法:通过将 CNN 在大型图像数据集上训练得到的预训练模型,将预训练模型中可复用的特征层抽取并利用其解决新的任务,这个过程称之为迁移学习 (Pan and Yang, 2010).

CNN 模型的最后一层全连接层被用于场景分类,因此该层中的神经元数量 (number of units) 等于数据集中的图像类别数.本文使用的预训练模型是在 ImageNet 数据集上训练得到的,由于实验数据集的类别数与 ImageNet 不同,所以在迁移学习之前,需要替换预训练模型的最后一层,以适应实验数据集.调

整过程如图 5 所示,保留预训练模型所有参数并将分类器替换,其中 N 代表训练数据集中影像的类别数.

迁移学习主要有两种策略:特征提取和参数微调.特征提取是通过保留预训练模型的部分网络参数,并将其应用在新的案例中,因为预训练模型的部分网络参数具有基础特征提取的能力,如影像的颜色、轮廓等信息 (Yosinski *et al.*, 2014).参数微调则与特




图 3 CNN-F 网络结构

Fig.3 CNN-F network structure

表 1 CNN-F 网络参数

Table 1 Parameters of the CNN-F network

结构名称	层名称	网络结构与参数
卷积层	Conv1	Size 11×11 , Num 64, stride 4, pad 0, Pool 2
	Conv2	Size 5×5 , Num 256, stride 1, pad 2, Pool 2
	Conv3	Size 3×3 , Num 256, stride 1, pad 1
	Conv4	Size 3×3 , Num 256, stride 1, pad 1
	Conv5	Size 3×3 , Num 256, stride 1, pad 1, Pool 2
全连接层	fc6	4 096
	fc7	4 096
softmax 分类器	fc8	1 000



图 4 ResNet-50 网络结构

Fig.4 ResNet-50 network structure

表 2 ResNet-50 参数

Table 2 Parameters of ResNet-50

结构名称	层名称	网络结构与参数
卷积层	conv1	Num 64, Size 7×7
	conv2_x	Num 64, Size 1×1
		Num 256, Size 1×1
	conv3_x	Num 128, Size 1×1
		Num 128, Size 3×3
Num 512, Size 1×1		
conv4_x	Num 256, Size 1×1	
	Num 256, Size 3×3	
	Num 1024, Size 1×1	
conv5_x	Num 512, Size 1×1	
	Num 512, Size 3×3	
	Num 2048, Size 1×1	
全连接层	fc	平均池化层, softmax 分类器

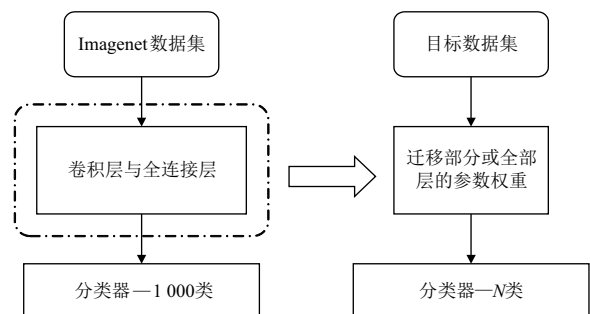


图 5 预训练模型调整流程

Fig.5 The flow chart of the adjusted pre-trained model

征提取不同, 是用目标数据集继续对预训练模型的部分或全部参数进行训练, 使网络所有层或部分层的参数进行调整以适应新的识别任务 (Razavian *et al.*, 2014).

3 实验与结果分析

3.1 迁移学习对比实验

本实验基于 CNN-F 的预训练模型, 首先替换最后一层网络, 使其适应实验数据集的类别数. 分别设计 An、Bn、Cn 3 种训练方法, 在训练集上对预训练模型进行训练. An 是将预模型的前 n 层权值参数冻结, 即不进行参数微调, 并对剩下的 $7-n$ 层参数初始化. Bn 是保留预训练模型的前 n 层权值参数, 将剩下的 $7-n$ 层初始化. Cn 是将预训练模型的前 n 层权值参数冻结, 同时保留剩余 $7-n$ 层的参数. 其中 $n=\{1, 2, \dots, 7\}$.

图6以 $n=1$ 为例, 阴影部分表示此层保留模型的权重参数, 白色代表权重参数初始化, 而有锁符号代表冻结此层的参数. 因此, A1 代表冻结预训练模型的第一层参数, 而剩下的 7 层参数全部初始化并重新训练. B1 表示除第一层参数外, 将预训练模型其余层的参数初始化后, 对整个网络重新训练. C1 表示冻结预训练模型的第一层参数, 其余层的参数进行参数微调.

将本实验中 3 组迁移学习方式 An、Bn、Cn 训练后的模型, 在测试集中进行测试, 图7展示了测试模型的识别精度.

从红色菱形点 An 的 1~3 层趋势可以发现, 随着冻结层数的增加, 精度也随之提升, 在 A3 时精度达到最高. 但随着冻结层数继续增加, 精度随之下降. 从趋势分析可知, 预训练模型的前 3 层网络参数可有效提取实验测试集的特征. 但由于 ImageNet 数据集与实验数据集差异较大, 预训练模型的 4~7 层无法有效提取遥感数据的特征.

黄色三角点 Bn 的识别精度随微调层数的增加而提高, 在 B7 达到最高识别精度. 这表明尽管实验数据集与 ImageNet 数据集之间存在较大差异, 但参与微调的层越多, 对遥感影像的识别精度越高.

蓝色圆点 C1 与 C2 的识别精度达到 95.53%, 超越了 An 与 Bn 的最高识别精度 92.85% 与 93.75%. 但随着冻结层数的增加, 识别精度也随之降低.

由实验结果表明, C1 与 C2 通过冻结底层权值参数并微调高层权值, 不仅保留了预训练模型的特征提取能力, 又可以通过微调高层参数以适应新的识别任务. 为了对比 C1 与 C2 的训练效果, 选取露天采矿场的用户精度与生产者精度进行评价. 由表3可以看出, C1 训练的模型用户精度优于 C2, 而 C2 训练的模型生产者精度更高, 因此两种训练方式各有优势.

3.2 最佳训练方式的适用性实验

在上述实验中发现, 冻结预训练模型底层参数并微调高层参数的训练方式最佳. 为了验证此方法是否适用于其他 CNN 模型, 选择 ResNet-50 的预训练模型进行训练, 具体的训练方式如下:

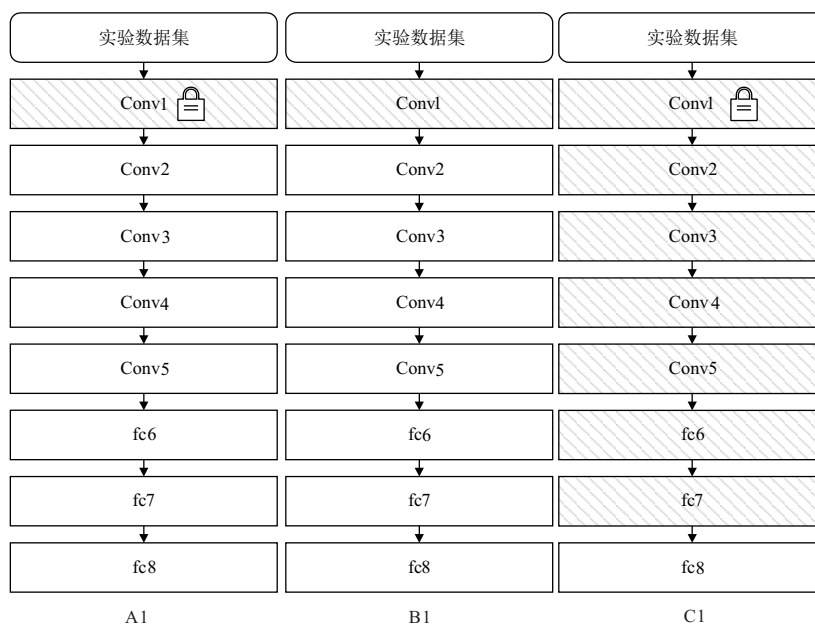


图 6 实验训练方法示例

Fig.6 The flow chart of experimental training method

ResNet- M 中 M 代表对 ResNet-50 预训练模型的第 M 层与其之前层的参数全部冻结, 并对其余层的参数在实验训练集上进行参数微调。

在图8中使用 $M=conv2_1$ 作为示例, ResNet-conv2_1 表示冻结 ResNet-50 预训练模型的 conv1 与 conv2_1 的参数, 并对其余层的权值参数进行微调。其中的虚线框内表示每一层都是一组残差块, 阴影部分表示保留 ResNet-50 预训练模型的权重参数, 白色表示将该层的参数初始化, 而锁符号代表该层冻结参数即不进行参数微调。

从图9可以看出, 在 ResNet-conv1 时识别精度达到最高。随着冻结层数增加, 特别是在冻结残差块后, ResNet-50 模型的识别精度下降。因此, 冻结底层参数并微调高层参数的方法适用于 ResNet-50 模型。

通过表4中的对比可以发现, 虽然 ResNet-50 的预训练模型在冻结底层参数并微调高层参数后, 在测试数据集中识别精度较好, 但总精度与生产者精度低于 CNN-F 的预训练模型。尽管 ResNet-50 模型在 ImageNet 数据集上的识别精度优于传统 CNN-F, 但本文的迁移学习方法更适合 CNN-F 模型。这一现象表明, 虽然残差网络的跨层连接方式可以降低参数的数量, 优化网络参数, 但也导致 ResNet-50 模型在迁移学习中的迁移效果不佳。

3.3 露天采矿场遥感识别

用 C1 方式训练的 CNN-F 对验证数据中的露天采矿场进行识别, 以评估最佳迁移学习方式训练

CNN 的效果。结果显示, 算法识别露天采矿场的生产者精度为 100%, 用户精度为 87.5%。通过对比露天采矿场的解译图与算法识别结果(图10), 发现仅在 A 处




图 7 An、Bn、Cn 分类精度对比

Fig.7 The comparison of An, Bn and Cn accuracy rate




图 8 ResNet-conv2_1 的迁移学习示意

Fig.8 The flow chart of ResNet-conv2_1 transfer learning




图 9 ResNet-M 分类精度

Fig.9 The accuracy rate of ResNet-M

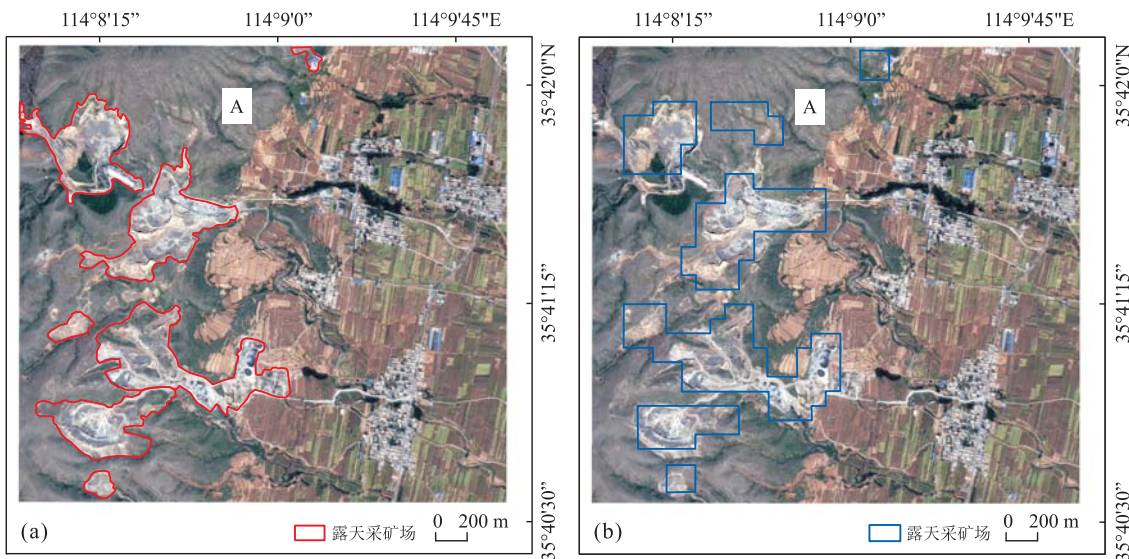


图 10 露天采矿场识别结果对比

Fig.10 Comparison of opencast mining interpretation result and automatic recognition result

a. 露天采矿场遥感解译结果; b. 算法识别露天采矿场的结果

表 3 精度评价

Table 3 Summary of user's and producer's accuracy rate

训练方法	生产者精度 (%)	用户精度 (%)
C1	93.75	100.00
C2	100.00	94.12

表 4 两种模型对目标数据集的分类精度

Table 4 The summary of accuracy rate in two models

训练方法	总精度 (%)	生产者精度 (%)	用户精度 (%)
resnet-conv1	87.50	75.00	100.00
C1	95.53	93.75	100.00
C2	95.53	100.00	94.12

的裸地被误分为露天采矿场, 而绝大部分露天采矿场可以通过本文算法识别. 本文验证数据包含的地物类型比较全面, 因此在该数据上识别的良好表现说明, 最佳迁移学习方式训练的 CNN 模型可以有效识别出露天采矿场的位置.

4 结论

针对因训练数据量小而导致 CNN 对露天采矿场识别精度不高的问题, 本文通过对比实验, 发现冻结 CNN 预训练模型网络底层参数并微调高层参数的迁移学习方法, 训练后的 CNN 模型不仅识别精度最高, 而且适用于不同结构的 CNN 模型. 使用该方法训练的 CNN-F 在验证数据上的生产者精度与用户精度均超过 87%, 证明使用上述方法训练的 CNN 模型可以有效识别高分遥感影像中的露天采矿场, 为露天采矿场遥感监测提供参考价值.

References

- Bengio, Y., 2012. Deep Learning of Representations for Unsupervised and Transfer Learning. *Proceedings of Machine Learning Research*, 27: 17–36.
- Bengio, Y., Bastien, F., Bergeron, A., et al., 2011. Deep Learners Benefit More from Out-of-Distribution Examples. *Proceedings of Machine Learning Research*, 15: 164–172.
- Cao, L.L., Li, H.T., Han, Y.S., et al., 2016. Application of Convolutional Neural Networks in Classification of High Resolution Remote Sensing Imagery. *Science of Surveying and Mapping*, 41(9): 170–175 (in Chinese with English abstract).
- Caruana, R., 1994. Learning Many Related Tasks at the Same Time with Backpropagation. *Advances in Neural Information Processing Systems*, 7: 657–664.
- Chatfield, K., Simonyan, K., Vedaldi, A., et al., 2014. Return of the Devil in the Details: Delving Deep into Convolutional Nets. *Proceedings of the British Machine Vision Conference: Machine Learning*, Nottingham.
- Demirel, N., Emil, M.K., Duzgun, H.S., 2011. Surface Coal Mine Area Monitoring Using Multi-Temporal High-Resolution Satellite Imagery. *International Journal of Coal Geology*, 86(1): 3–11. <https://doi.org/10.1016/j.coal.2010.11.010>
- He, K., Zhang, X., Ren, S., et al., 2015. Deep Residual Learning for Image Recognition. *Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 770–778.
- Hou, F., Hu, Z.L., 2012. Remote Sensing Information Extraction of Typical Surface Objects in a Coal Mining Area Based on Multiple-Scale Segmentation. *Bulletin of Surveying and Mapping*, (1): 22–25 (in Chinese).
- Jing, P.P., Li, B., Jia, Z.R., et al., 2017. Research on Information Extraction Based on UAV Remote Sensing. *Geomatics & Spatial Information Technology*, 40(12): 77–80 (in Chinese with English abstract).
- Kang, R.F., 2017. Remote Sensing Monitoring and Evaluation of Mine Geological Environment in Ji'nan Open Pit Mining Area (Dissertation). Shandong Normal University, Jinan (in Chinese with English abstract).
- Li, X., 2017. Open-Pit Mining Mine Geological Environment Treatment and Recovery. *World Nonferrous Metals*, (4): 126–128 (in Chinese with English abstract).
- Pan, S.J., Yang, Q., 2010. A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10): 1345–1359. <https://doi.org/10.1109/tkde.2009.191>
- Qi, X.Y., Yang, W.N., Shao, H.Y., et al., 2008. An Automatic Extraction Method of Mining Area Expanding Remote Sensing Image: A Study on Panzhihua Vanadium Titanium Magnetite Ore. *Science of Surveying and Mapping*, 33(3): 76–78 (in Chinese with English abstract).
- Razavian, A.S., Azizpour, H., Sullivan, J., et al., 2014. CNN Features Off-the-Shelf: An Astounding Baseline for Recognition. *Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Columbus, 512–519.
- Sun, M., Yang, C.L., 2012. Geological Environment Problems and Countermeasures of Mining Areas in Hebi City. *West-China Exploration Engineering*, 24(11): 80–82 (in Chinese).
- Xu, S.H., Mu, X.D., Zhao, P., et al., 2016. Scene Classification of Remote Sensing Image Based on Multi-scale Feature and Deep Neural Network. *Acta Geodaetica et Cartographica Sinica*, 45(7): 834–840 (in Chinese with English abstract).
- Yosinski, J., Clune, J., Bengio, Y., et al., 2014. How Transferable are Features in Deep Neural Networks? *Proceeding NIPS'14*, 2: 3320–3328.
- Zhu, X.X., Tuia, D., Mou, L.C., et al., 2017. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4): 8–36. <https://doi.org/10.1109/mgrs.2017.2762307>
- Zhu, Z.J., 2010. Study on Mine Area Information Extraction Based on Object-Oriented High-Resolution Remote Sensing Image Classification and Its Application (Dissertation). China University of Geosciences, Beijing (in Chinese with English abstract).

附中文参考文献

- 曹林林, 李海涛, 韩颜顺, 等, 2016. 卷积神经网络在高分遥感影像分类中的应用. *测绘科学*, 41(9): 170–175.

侯飞, 胡召玲, 2012. 基于多尺度分割的煤矿区典型地物遥感信息提取. 测绘通报, (1): 22-25.

荆平平, 李兵, 贾宗仁, 等, 2017. 基于无人机遥感的信息提取研究. 测绘与空间地理信息, 40(12): 77-80.

康日斐, 2017. 济南市露天开采集中区矿山地质环境遥感监测与环境评价研究 (硕士学位论文). 济南: 山东师范大学.

李夏, 2017. 露天采矿矿山地质环境治理与恢复研究. 世界有色金属, (4): 126-128.

漆小英, 杨武年, 邵怀勇, 等, 2008. 矿山扩展遥感信息自动

提取方法研究——以攀枝花钒钛磁铁矿为例. 测绘科学, 33(3): 76-78.

孙森, 杨春丽, 2012. 鹤壁市矿山地质环境问题及防治对策. 西部探矿工程, 24(11): 80-82.

许凤晖, 慕晓冬, 赵鹏, 等, 2016. 利用多尺度特征与深度网络对遥感影像进行场景分类. 测绘学报, 45(7): 834-840.

祝振江, 2010. 基于面向对象分类法的高分辨率遥感影像矿山信息提取应用研究 (硕士学位论文). 北京: 中国地质大学.

第五届青年地学论坛在南京成功召开

2018年10月27-29日,由青年地学论坛理事会、中国科学院青年创新促进会地学分会主办,南京大学表生地球化学教育部重点实验室和中国科学院南京地理与湖泊研究所流域地理学重点实验室承办的第五届青年地学论坛在南京成功召开.大会由南京大学李高军教授和中国科学院南京地理与湖泊研究所段洪涛研究员担任共同主席,来自全国及部分海外单位2000余名青年科学家齐聚古都南京,其中国家杰青、优青、千人和万人等人才计划入选者200余人,是一次名副其实的青年科学家盛会.

大会开幕式10月27日在南京大学国际会议中心举行.承办单位领导南京大学副校长王振林教授、中国科学院南京地理与湖泊研究所副所长段学军研究员、南京大学前校长陈骏院士以及青年地学论坛理事长晏宏研究员等出席开幕式并分别致辞.此外,构造动力学家许志琴院士、地球物理学家陈颙院士等应邀出席大会开幕式.大会特邀长安大学彭建兵教授、中国科学院南京分院杨桂山研究员、中国科学院青藏高原研究所李新研究员和中国科学院地质与地球物理研究所魏勇研究员做大会主题报告,中国科学院生态环境中心刘倩研究员、南京大学丁爱军教授等12名优秀青年学者做大会青年报告,中国科学院青海盐湖研究所刘向军博士对第六届青年地学论坛的筹备情况进行了介绍.

本届论坛秉承“新时代·新青年·新地学”精神,围绕“第四纪地质与全球变化”、“地球化学”、“环境科学”、“生态与可持续发展”、“气溶胶与大气环境科学”、“地质灾害与工程地质”、“海洋地球科学”、“地理及地理信息科学”、“地球和空间物理”、“大气科学与全球变化”、“固体地球科学”、“月球与行星科学”、“水资源与水环境”、“矿产与资源”和“古生物、古地理与古环境”等15个主题展开学术交流,组织了共计约1100个精彩的学术报告,交流探讨了地学及各分支学科最新研究进展.会后部分参会代表到南京地湖所太湖站和天目湖站进行了实地考察.《地球科学》编辑部编辑参加了此次会议并针对大会主题进行了约稿.

第六届青年地学论坛将于2019年暑期在西宁举行.