

地形校正对U-Net深度神经网络分类器分类精度的影响

贾莉^{1,2}, 郑柯¹, 唐娉¹, 霍连志¹

1. 中国科学院空天信息创新研究院, 北京 100094;

2. 中国科学院大学 电子电气与通信工程学院, 北京 100049

摘要: 在国土资源监测、森林资源调查等多个领域中, 基于遥感影像的分类技术受到了广泛应用。在利用传统分类器对地表覆盖分类提取中, 地形效应是制约分类精度提升的一种因素, 其影响可通过适当的校正模型减弱, 且已证明地形校正能够对分类精度的提升起到积极作用。相比于传统分类器, 基于深度学习理论的深度神经网络分类器具有深层特征学习和表达的优势, 在图像分类领域兴起并逐渐用于土地覆盖分类且取得了不错的精度提升。本文初步探究了地形校正正在利用深度神经网络分类器U-Net进行地表覆盖分类时对分类精度的影响情况。以Landsat 8 OLI 30 m影像为数据源, 结合GDEM_V2 30 m地形数据, 在GlobeLand 30和全国30 m森林分类结果的基础上, 利用U-Net深度神经网络分类器实现了山区地表覆盖分类提取, 并就不同训练样本获取方式及不同精细程度分类体系下地形校正前后的分类精度做了对比分析。分类结果表明: (1) 规则网格裁切和坡向辅助裁切这两种训练样本获取方式下, 地形校正后的分类精度较校正前不变或有极小幅度的降低, 降低范围在0.9%—1.39%; (2) 在对更精细的森林类型分类中, 地形校正后的分类精度较校正前下降了1.66%。本文初步探究得到: 在规则网格裁切和坡向辅助裁切这两种训练样本获取方式及不同精细程度的分类体系下, 地形校正均未能提高U-Net深度神经网络分类器的分类精度。

关键词: 遥感分类, 深度神经网络, U-Net模型, 地形校正, 地表覆盖分类, 分类精度

引用格式: 贾莉, 郑柯, 唐娉, 霍连志. 2022. 地形校正对U-Net深度神经网络分类器分类精度的影响. 遥感学报, 26(4): 698–710

Jia L, Zheng K, Tang P and Huo L Z. 2022. Topographic correction effect on classification accuracy for deep neural network classifier—A case study of the U-Net model. National Remote Sensing Bulletin, 26(4): 698–710 [DOI: 10.11834/jrs.20229322]

1 引言

遥感影像在国土资源监测、森林资源调查等多个领域得到了广泛应用。为了把遥感影像转换为专题类别信息, 普遍使用遥感影像分类技术(唐娉等, 2016)。尽管传统遥感影像分类技术取得了巨大进步, 但仍有很多因素限制着其进一步发展(贾坤等, 2011)。在众多制约因素中, 由地形起伏引起的地形效应是其中一种外部因素。不规则的地形起伏造成地表同种地物辐射亮度不一致, 进而导致地表反射率有所差异, 在影像上表现出阴坡暗, 阳坡亮的现象。这种因地表坡度与

坡向变异引起的辐射畸变会扰乱地物光谱信息, 给影像分类带来一定误差, 使得基于影像光谱信息的土地覆被分类难以达到较高精度(何超等, 2014)。

为进一步提高遥感影像分类精度, 国内外学者基于DEM数据建立了SCS(Gu和Gillespie, 1998)、SCS+C(Soenen等, 2005)、VECA(Gao和Zhang, 2007)等多种地形辐射校正模型来消除地形效应(姜亢等, 2014), 并初步评估了不同地形校正模型对地表覆盖分类的影响情况(陈趁新等, 2014)。已有的研究表明在最大似然、决策树、支持向量机等传统影像分类法中加入地形校

收稿日期: 2019-09-09; 预印本: 2019-12-20

基金项目: 国家科技基础条件平台建设专项(编号: 2014FY210800); 国家自然科学基金(编号: 41971396, 41401421); 中国科学院战略性先导科技专项(编号: XDA19080301)

第一作者简介: 贾莉, 研究方向为遥感图像处理、地表覆盖分类。E-mail: jiali_199311@163.com

通信作者简介: 霍连志, 研究方向为遥感图像处理、遥感图像分类技术。E-mail: huolz@radi.ac.cn

正这一预处理过程,一定程度上会恢复模糊的地表信息,大大提高地表地物特征的表达与解读(Brown 等, 1998; Li 等, 2013; Pimple 等, 2017; 邓禹 等, 2018)。

近年来,深度学习技术被广泛用于图像分类领域(许慧敏, 2018)。相比传统主要基于影像光谱信息的统计分类方法,计算机模拟自学习的深度神经网络分类模型能有效地将轮廓、颜色等底层特征抽象成高层易分类特征;并学习提取复杂的本质特征、融合多种影像特征信息,从而降低分类不确定性,增强分类效果,成为图像深度特征提取的有力工具(马亚飞 等, 2018)。在图像分析领域,卷积神经网络 CNN 表现出独特的优势,获得了巨大的成功(李彦冬 等, 2016)。而全卷积网络 FCN 进一步将图像级分类延伸到像素级分类(Shelhamer 等, 2017),其中基于 FCN 架构的语义分割模型 U-Net 在医学图像分析领域获得了较好的分析效果(Ronneberger 等, 2015),也逐渐在遥感影像分类研究中取得了较高的分类精度(Maggiori 等, 2016)。且有研究表明,在非 100% 精度的样本标记前提下,使用深度神经网络分类器对遥感影像进行分类,仍然能获得较好的分类结果(Isikdogan 等, 2017; Liu 和 Chen, 2018)。

既然已有研究证明针对浅层传统分类器,地形校正能提高影像分类精度(Pimple 等, 2017),自然引发这样的思考:针对 U-Net 等深度神经网络分类器,地形校正能否达到同样的效果?或者说针对深度神经网络分类器,地形校正是否必要?本文以 Landsat 8 遥感卫星影像和 30 m 分辨率的 ASTER GDEM_V2 地形数据为例,结合国家基础地理信息中心制作的 GlobeLand30 地表覆盖分类产品(Chen 等, 2015)和清华大学研制的全国森林分类结果(Li 等, 2014),用 U-Net 语义分割网络对实验区进行地表覆盖分类研究,并重点对比分析了不同训练集获取方式及不同精细程度分类体系下遥感影像地形校正前后分类精度的差异情况。

2 研究实验区和数据源

2.1 实验区概况

实验区位于陕西、山西、河南 3 省交界处,涵盖 3 省 10 余个县,中心坐标为 $34^{\circ}15'18.39''\text{N}$, $110^{\circ}13'21.61''\text{E}$,落于陕西省洛南县境内。实验区地处秦岭东段南麓,属于湿润性暖温带季风气候,最高海拔 2655 m,最低海拔 210 m;地势西高东低,黄河穿流而过。研究所选实验区见图 1。




图 1 实验区示意图

Fig. 1 The study area

通过对 GlobeLand30 地表覆盖分类产品的读取, 参照 GlobeLand30-2010 的分类基准, 即耕地、森林、草地、灌木地、湿地、水体、苔原、人造地表、裸地、冰川和永久积雪这十大地类 (Chen 等, 2017), 得到本研究实验区范围内涵盖的地物类别, 包括耕地、森林、草地、湿地、水体以及人造地表 6 大类。其中森林面积最大, 耕地次之,

草地及湿地面积最少, 地物种类齐全并且具有明显的地形效应。

2.2 数据源

研究中采用了 Landsat 8 OLI 卫星影像、GlobeLand 30 分类产品、ASTER GDEM_V2 高程数据及全国 30 m 森林分类产品这 4 种数据源, 数据详情见表 1。

表 1 实验数据源列表
Table 1 List of experimental data

数据名称	数据来源	卫星/传感器	波段数	影像大小	分辨率/m	数据类型(年份)
Landsat 8 OLI	USGS	OLI_TIRS	7	5000×5000	30	TIFF(2013)
GlobeLand 30	National Geomatics Center of China	TM、ETM+HJ-1A/B	3	5000×5000	30	TIFF(2010)
ASTER GDEM_V2	Geospatial Data cloud	ASTER	1	5000×5000	30	TIFF(2011)
Forest Map for China	TSINGHUA UNIVERSITY	TM、ETM+MOD13Q1	1	5000×5000	30	TIFF(2010)

覆盖该实验区的 Landsat 8 OLI 影像是由相邻两景时相一致、无云的影像拼接裁剪而成, 见图 1, 所选用的这两景影像详细信息见表 2。

表 2 实验区 Landsat 影像数据列表
Table 2 Landsat image lists of study area

景数	传感器	条带号/ 行号	影像 获取日期	太阳 天顶角/(°)	太阳 高度角/(°)
1	OLI_TIRS	126/36	2013-06-02	119.31	68.47
2	OLI_TIRS	126/37	2013-06-02	115.59	68.90

研究中首先使用 USGS 官方发布的辐射校正算法 LaSRC 对 Landsat 8 卫星影像进行了辐射校正处理 (Vermote 等, 2016), 获取可用于定量计算的地表反射率数据。此外, 其他 3 种数据源均具有一定的可靠性:

(1) GlobeLand 30-2010 分类产品经第 3 方抽样检验, 得到 83.50% 的总体精度。其中, 水体精度最高, 其后是森林、人造地表、耕地、湿地、裸地、草地、永久积雪和冰川、灌木地 (Chen 等, 2017)。而本研究选择的实验区域中森林、人造地表及耕地占大多数, 该数据产品在该实验区内的精度可以满足其作为样本标签数据使用的要求。

(2) ASTER GDEM_V2 地形数据根据 NASA 新一代对地观测卫星 TERRA 的观测结果, 由 ASTER 传感器通过搜集 130 万个立体像对数据制作完成, 数据水平精度为 30 m, 高程精度为 20 m, 均达到 95% 的置信度, 较 SRTM3 DEM 和 GTOPO 30 数据

有明显的提高。实验选取的 2 二版数据于 2011-10 发布, 相较于第一版在水域覆盖和偏差去除等方面有了进一步进展, 数据质量得到了很大提高, 可满足研究对地形数据的要求 (康晓伟和冯钟葵 等, 2011; <https://pubs.erusgs.gov/publication/70005960>[2019-09-09])。

(3) 全国 30 m 森林分类产品经质量检验与分类评估, 在中国范围内森林/非森林分类的生产者精度达到了 92.0%, 用户精度达到了 95.7% (Li 等, 2014), 数据产品具有一定的可靠性。

3 研究方法

本研究的总体方法为: 首先针对本实验区从常用的地形校正方法中优选最佳的校正方法及其主要参数, 对原始地表反射率影像进行地形校正; 其次, 根据地形条件特点对实验区进行训练及测试样本区的划分, 并根据 DEM 数据提取了研究区的坡向信息且进行了坡向分类; 再次, 把原始的地表反射率数据和经过地形校正的地表反射率数据分别用于 U-Net 模型的训练, 得到两组分类结果; 最后, 分别使用测试样本对不同组分类结果进行精度评价, 研究技术流程见图 2。

3.1 地形校正处理

在实验区范围内选取部分区域, 分别运用 C、SCS、SCS+C、VECA 及 Teillet 这 5 种地形校正模型结合 DEM 数据对地表反射率数据进行地形校正, 校正效果见图 3。




图2 研究技术流程图

Fig. 2 The flowchart of methods




图3 5种地形校正模型校正效果对比图

Fig. 3 Comparison of correction effects of five topographic correction models

5种校正结果中，C、SCS、SCS+C、VECA模型均存在不同程度的过校正现象，本实验区域内Teillet模型的校正效果较其他4种好。接着从Teillet模型校正结果中选取方形区域（图中黑色方框所示）对该模型4种不同卷积核的适用性作进一步分析，结果见图4。

4种卷积核中3×3大小的核校正效果最好。因为卷积核越大，通过DEM计算得到的地形因子越平滑，较大的卷积核会使细小地物变模糊，影响校正效果。

为了确保校正结果的准确性与可靠性，根据地物光谱一致性，即不同地形条件下同一类地物目标在经过地形校正后应具有基本相同的反射率（Han等，2010）。以实验区部分区域为例，依据全国森林分类产品，提取该区域内落叶阔叶林这一种森林类型影像，再分别选取所提取影像中邻近

阴阳坡上两块区域（图5），生成地形校正前后两区域植被均值光谱曲线及光谱差值曲线，以此来比较地形校正前后阴阳坡植被反射率的相似程度。通过对光谱一致性分析评价地形校正效果，地形校正前后光谱一致性曲线见图6和图7。





图4 Teillet模型4种卷积核校正效果对比图

Fig. 4 Comparison of correction effects for four convolution kernels of the Teillet model



落叶阔叶林覆盖区

图5 落叶阔叶林覆盖区邻近阴阳坡选取示意图

Fig. 5 The nearby shady-slope and sunny-slope of the deciduous broadleaf area

生成的两组植被光谱曲线中地形校正后阴阳坡光谱曲线形状趋于一致，光谱之差减小。即Teillet模型校正后削弱了影像数据的地形效应，产生的地形校正数据有可靠性，可作为分类输入数据使用。因而在本研究的后续实验中，将采用Teillet校正模型、3×3卷积核做地形校正处理。

3.2 样本区划分

实验区被均分成同等大小的九块区域，见图8。选择6块组合成训练样本区域，该区域涵盖6大地表覆盖类型，具有代表性；其余3块组合成测试样本区域，该区域既有平坦地区，也有高低起伏的山地，且森林覆盖面积大小有异，可以很好地验证研究的合理性。




图6 地形校正前光谱一致性

Fig. 6 Spectral consistency before topographic correction




图7 地形校正后光谱一致性

Fig. 7 Spectral consistency after topographic correction




图8 训练、测试样本区分

Fig. 8 Distribution of training data and test data

在后续的实验, 将通过从训练样本区域获取一定量的训练样本进行分类器模型的训练, 并对3个测试区域分别进行分类与精度评价。

3.3 坡向分类

为了更好地分析地形校正对U-Net分类器分类精度的影响规律, 探究不同的训练样本获取方式下地形校正对分类结果是否具有不同的影响, 研究中加入坡向数据辅助分类 (Álvarez 等, 2018), 基于阴阳坡及平地影像图获取训练集。首先利用ArcGIS软件对实验区DEM数据求取坡向, 并参照国家森林资源连续清查技术规定进行坡向分类, 将坡向分为阴坡, 阳坡及平地3类, 具体情况见表3。

然后经波段运算分别提取阳坡、阴坡及平地这3类辅助影像, 部分区域提取结果见图9。

表 3 坡向分类
Table 3 Aspect classification

阳坡		阴坡		平地
坡向	角度/(°)	坡向	角度/(°)	
北	0—22.5 337.5—360	南	157.5—202.5	-1
东北	22.5—67.5	西南	202.5—247.5	
东	67.5—112.5	西	247.5—292.5	
东南	112.5—157.5	西北	292.5—337.5	

3.4 训练样本获取

不同于传统的分类方法，U-Net 模型需要输入一定大小的图像块且在每个图像块中逐像素地标

记类别信息。研究中将该模型输入的图像块大小定为 256×256，因而需要对训练样本区按照一定条件裁切出 256×256 大小的图像块，每个图像块将作为一个训练样本；此外，还需要对每个训练样本块中 256×256 个像素点逐一标注其类别。考虑到实验区 Landsat 8 获取时间为 2013 年，与 GlobeLand30 2010 年数据时间相近，且该实验区内地表覆盖变化较小，将直接从 GlobeLand30 数据获取对应每个图像块中每个像素点的类别标记信息。在类别标记获取之前，需要进行重投影、重采样等操作，以保证不同数据集投影方式一致，分辨率及图像尺寸大小相同。




图 9 阴阳坡及平地提取结果叠加原始影像显示
Fig. 9 Shady-slope, sunny-slope and flat areas superimposed over the original image

研究选取了两种训练集获取方式。(1) 坡向辅助裁切：根据提取的阴坡、阳坡、平地 3 个辅助影像对训练样本所在区域进行裁切，为了保持训练样本均衡，裁切样本总数为 12000 个，阴坡、阳坡、平地均裁切 4000 个；同时为避免阴阳坡训练样本的大量重复，选择更改训练样本的裁切步长得到更全面多样的样本数据；(2) 规则网格裁切：训练样本总数为 12000 个，网络参数与前者保持一致。训练样本具体获取情况见表 4。

表 4 训练样本获取情况
Table 4 Details of selecting training samples

	坡向辅助裁切			规则网格裁切
	阳坡	阴坡	平地	
单类样本量/个	4000	4000	4000	—
步长	80	100	10	50
裁切比例/%	20	20	5	—
总样本量/个	12000			12000
验证样本量/个	2400			2400

注：平地面积过小，裁切比例调整为 5%，更易获得训练集。

3.5 U-Net 模型

U-Net 是基于 FCN 端到端的网络架构（Ronneberger 等，2015），模型具有少样本学习的能力和较高的运算速率，在小数据集上可以训练得很好。该网络有 9 层结构，左半部分卷积层结合 4 个下采样层提取图像特征，右半部分 4 个上采样层拼接特征提取部分的输出获得准确分割，网络最后采用 1×1 卷积核映射出对应维数的特征图，得到精确的逐像素分类。研究所用 U-Net 网络结构见图 10。

研究中模型训练输入图像大小为 256×256，边界填充确保输入输出图像尺寸一致。将训练集中 80% 的样本做训练，20% 的样本做验证，使用训练集中的全部样本训练 150 次，每次迭代训练的样本数目（即批量大小）为 10，选择 ReLU 函数作为分类器的激活函数，选择随机梯度下降算法作为分类器的优化方法，选择多分类交叉熵损失函数作为分类器的损失函数，选择正确率作为分类器的评估参数。实验基于 Keras 框架实现，Python 语

言编写, 在 Linux 操作系统上完成, 系统配置 4 个 128 GB 内存及 80 TB 硬盘。
NVIDIA Titan XP GPU 显卡、32 核至强 E5 CPU、




图 10 研究用 U-Net 网络结构图

Fig. 10 The framework of U-Net in our study

3.6 精度评估

为了定量评价分类效果同时保证精度验证样本点选取的均匀性, 对每一幅测试影像, 首先创建覆盖整个影像的 1.32 km×1.32 km 规则网格, 生成 1444 个均匀的验证点; 其次由解译专家以 Landsat 8 影像为基础, 并结合 Google Earth 高分辨

率影像进行真实类别标注; 最后将真实类别与分类器分类结果进行对比, 生成混淆矩阵, 并从混淆矩阵中统计分类总体精度及 Kappa 系数。以一幅测试影像为例, 精度验证样本点的分布及局部放大情况如图 11 所示。




图 11 精度验证样本点分布图

Fig. 11 Distribution map of sample points used for accuracy assessment

4 结果与讨论

4.1 分类及精度评价结果

对 3 个测试样本区域影像, 经 U-Net 得到的分

类结果如图 13 和图 14 所示, 其中图 13 为规则网格裁切采样所得分类结果, 图 14 为坡向辅助裁切采样所得分类结果。为了增加对比性, 原始地表反射率数据和地形校正后的地表反射率数据如图 12 所示。3 个测试区域定量的分类精度见表 5。




图 12 测试样本区域 1,2,3 地形校正前后反射率影像图(7,6,4 波段显示)

Fig. 12 Reflectivity image before and after topographic correction in test area 1,2,3 (R:7 G:6 B:4)




图 13 规则网格裁切方式下测试样本区域 1,2,3 地形校正前后分类结果

Fig. 13 Classification results before and after topographic correction by grid clipping in test area 1,2,3




图 14 坡向辅助裁切方式下测试样本区域 1,2,3 地形校正前后分类结果

Fig. 14 Classification results before and after topographic correction by aspect auxiliary clipping in test area 1,2,3

表 5 分类精度统计表

Table 5 Classification accuracy statistics

裁切方式	影像	参量	测试样本 区域 1	测试样本 区域 2	测试样本 区域 3
规则 网格裁切	原始影像	总体精度/%	83.86	87.74	83.10
		Kappa	0.690	0.724	0.600
	地形校正 影像	总体精度/%	82.96	87.74	82.06
		Kappa	0.680	0.719	0.530
	变化范围/%		—	0.00	-1.04
坡向 辅助裁切	原始影像	总体精度/%	82.69	87.19	82.55
		Kappa	0.670	0.710	0.540
	地形校正 影像	总体精度/%	82.55	87.10	81.16
		Kappa	0.660	0.700	0.500
	变化范围/%		—	-0.14	-1.39

4.2 讨论

研究结合已有数据源及现有分类产品，通过 U-Net 分类模型实现了对 3 个测试区域的分类，得到表 5 定量的分类精度大小。从表 5 总结得到：

(1) 3 组测试区域中，地形校正后影像的分类

精度较未校正影像不变或有极小幅度的降低，降低范围在 0.9—1.39。实验结果初步表明，对于 30 m 分辨率的 Landsat 8 遥感影像数据，地形校正未能提高 U-Net 深度神经网络分类器的分类精度；

(2) 规则网格裁切与坡向辅助裁切这两种不同的训练样本集获取方式下，地形校正前后的分类精度呈现出一致的变化规律，且规则网格构建训练样本的方式比按坡向辅助构建方式取得了更高的分类精度。原因在于利用阴阳坡及平地影像辅助裁切训练样本集时并不能将所有地类都采样，导致样本数据训练不充分，影响了测试集的分类精度；

(3) 依据 GlobeLand 30 分类产品的分类体系，在实验区内只区分了森林与其他 5 大地类，并未对森林这类地物进行更精细的类别划分。在经地形校正后确保阴阳坡辐射差异相对一致的情况下，森林类型单一可能会掩盖地形校正的作用，使得地形校正的效果在这种粗划分的分类体系中没有得到很好地体现。

因此，为了进一步探讨森林体系单一是否是导致以上分类结果的因素，选择3.2节图8训练样本区3作为新的实验区，该区域山地起伏尤为明显、高差较大、有大面积森林覆盖、地形校正效果突出，具有代表性（图15）。同时，选择2010年全

国30 m分辨率森林分类图作为样本标签。在该产品类别体系中，将森林划分为六大类：常绿阔叶林、落叶阔叶林、竹子、常绿针叶林、落叶针叶林及混交林。




图15 森林测试区域(训练样本区3)地形校正前后反射率影像图(7,6,4波段显示)
Fig. 15 Reflectivity image before and after topographic correction in forest test area (the training area 3) (R:7 G:6 B:4)

U-Net网络训练时，训练样本集用规则网格裁切的方式获取（见3.4节），网络训练方式同3.5节

一致，精度评价方式同3.6节一致。森林测试区域（训练样本区3）地形校正前后的分类结果见图16。




图16 森林测试区域(训练样本区3)地形校正前后分类结果
Fig. 16 Classification results before and after topographic correction in forest test area (the training area 3)

由分类结果可知该测试区主要的森林类型是落叶阔叶林、常绿针叶林及混交林3大类，落叶阔叶林和混交林居多，常绿针叶林较少。初步统计得到地形校正前后不同森林类型面积的大小变化，地形校正前落叶阔叶林、常绿针叶林、混交林面积占比分别是41.91%、2.60%、55.49%，校正后面积占比分别是39.80%、2.23%、57.97%。对比发现地形校正后3种森林类型面积均有变化，落叶阔叶林和常绿针叶林的面积减小，混交林面积增多。

针对上述测试区，定量的分类精度结果见表6。结果表明，在对森林这一地表类型进行更精细的类别划分下，地形校正后的分类精度较校正前下降了1.66%，这与上述讨论（1）得出的结论是一致的，地形校正并未提高U-Net深度神经网络分类器的分类精度。即森林体系划分单一并不是导致以上分类结果的因素，而是U-Net分类器自身所达到的分类结果。

表 6 森林分类精度统计表

Table 6 Classification accuracy statistics in forest area

	地形校正前	地形校正后
总体精度/%	79.22	77.56
Kappa	0.680	0.660

5 结 论

本文选择了深度神经网络模型U-Net，对Landsat 8 30 m分辨率原始地表反射率数据及经过地形校正的反射率数据进行了分类提取，对比了规则网格裁切和坡向辅助裁切这两种训练样本构建方式下地形校正前后分类精度大小，并验证了不同精细程度的分类体系下地形校正前后分类精度的变化规律，并就不同情况下的分类结果进行了定量对比分析，得出以下结论：

（1）在实验区范围内利用U-Net深度神经网络分类器进行地表覆盖分类提取，在规则网格裁切和坡向辅助裁切这两种训练样本集采样方式下，地形校正均未能提高该深度神经网络分类器的分类精度。

（2）不同精细程度的分类体系下地形校正对U-Net分类器分类精度的影响规律是一致的。对森林地类精细的划分下地形校正仍然未提高U-Net分类器的分类精度。

（3）按照规则网格获取训练集较坡向辅助采

样方式取得了更高的分类精度。规则网格下的采样能更好地涵盖所有地物类别，保证所构建的训练样本具备地物特征的完整性以及多样性。

本研究初步探索了地形校正正在利用深度神经网络分类器U-Net进行地表覆盖分类时对分类精度的影响情况，旨在为简化深度神经网络分类器分类提取流程、提高遥感产品生产效率提供参考依据。本研究仍然存在着不足：首先，GlobeLand 30和全国森林分类产品较真实地表覆盖类型仍存在一定误差，后续会寻找更精细、准确的分类结果作为样本标签；其次，本研究中并没有考虑阴阳坡地表覆盖类型不同的情形；最后，本研究只针对U-Net这一种深度神经网络分类器展开，后续的研究中将尝试选择多种深度神经网络分类器，探究更精细尺度下不同深度神经网络模型在地形校正前后的分类精度变化情况，获取进一步的结论。

参考文献(References)

Álvarez-Martínez J M, Silió-Calzada A and Barquín J. 2018. Can training data counteract topographic effects in supervised image classification? A sensitivity analysis in the Cantabrian Mountains (Spain). *International Journal of Remote Sensing*, 39(23): 8646-8669 [DOI: 10.1080/01431161.2018.1489163]

Brown D G, Lusch D P and Duda K A. 1998. Supervised classification of types of glaciated landscapes using digital elevation data. *Geomorphology*, 21(3/4): 233-250 [DOI: 10.1016/s0169-555x(97)00063-9]

Chen C X, Hu C M, Huo L Z and Tang P. 2014. Effect of different radiation correction methods of Landsat TM data on land-cover remote sensing classification. *Journal of Remote Sensing*, 18(2): 320-334 (陈趁新, 胡昌苗, 霍连志, 唐婷. 2014. Landsat TM数据不同辐射校正方法对土地覆盖遥感分类的影响. *遥感学报*, 18(2): 320-334) [DOI: 10.11834/jrs.20143211]

Chen J, Chen J, Liao A P, Cao X, Chen L J, Chen X H, He C Y, Han G, Peng S, Lu M, Zhang W W, Tong X H and Mills J. 2015. Global land cover mapping at 30m resolution: a POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103: 7-27 [DOI: 10.1016/j.isprsjprs.2014.09.002]

Chen J, Liao A P, Chen J, Peng S, Chen L J and Zhang H W. 2017. 30-meter global land cover data product- GlobeLand30. *World Geomatics*, 24(1): 1-8 (陈军, 廖安平, 陈晋, 彭舒, 陈利军, 张宏伟. 2017. 全球30m地表覆盖遥感数据产品-GlobeLand30. *地理信息世界*, 24(1): 1-8) [DOI: 10.3969/j.issn.1672-1586.2017.01.002]

Deng Y, Huang J and He M. 2018. Study on terrain radiometric correction of Landsat 8 in Chong Qing mountainous area. *Rural Economy and Science-Technology*, 29(11): 16-18 (邓禹, 黄健, 何敏. 2018. 重庆山区Landsat 8地形辐射校正研究. *农村经济与科技*,

- 29(11): 16-18 [DOI: 10.3969/j.issn.1007-7103.2018.11.008]
- Gao Y N and Zhang W C. 2007. Variable empirical coefficient algorithm for removal of topographic effects on remotely sensed data from rugged terrain//Proceedings of 2007 IEEE International Geoscience and Remote Sensing Symposium. Barcelona: IEEE: 4733-4736 [DOI: 10.1109/IGARSS.2007.4423917]
- Gu D G and Gillespie A. 1998. Topographic normalization of Landsat tm images of forest based on subpixel sun-canopy-sensor geometry. *Remote Sensing of Environment*, 64(2): 166-175 [DOI: 10.1016/S0034-4257(97)00177-6]
- Han X M, Li X H, Zhu R F and Shi X Y. 2010. Topographic correction method of remote sensing image considering Bi-directional reflectance//Proceedings of 2010 International Conference on Computer Application and System Modeling. Taiyuan, China: IEEE [DOI: 10.1109/ICCASM.2010.5622511]
- He C, Chen J Z and Yue C R. 2014. Comparison test and research progress of normalization topographic correction model. *Forest Inventory and Planning*, 39(3): 12-16, 34 (何超, 陈建珍, 岳彩荣. 2014. 归一化地形校正模型研究进展及其对比实验. *林业调查规划*, 39(3): 12-16, 34) [DOI: 10.3969/j.issn.1671-3168.2014.03.003]
- Isikdogan F, Bovik A C and Passalacqua P. 2017. Surface water mapping by deep learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(11): 4909-4918 [DOI: 10.1109/JSTARS.2017.2735443]
- Jia K, Li Q Z, Tian Y C and Wu B F. 2011. A review of classification methods of remote sensing imagery. *Spectroscopy and Spectral Analysis*, 31(10): 2618-2623 (贾坤, 李强子, 田亦陈, 吴炳方. 2011. 遥感影像分类方法研究进展. *光谱学与光谱分析*, 31(10): 2618-2623) [DOI: 10.3964/j.issn.1000-0593(2011)10-2618-06]
- Jiang K, Hu C M, Yu K and Zhao Y C. 2014. Landsat TM/ETM+topographic correction method based on smoothed terrain and semi-empirical model. *Journal of Remote Sensing*, 18(2): 287-306 (姜亢, 胡昌苗, 于凯, 赵永超. 2014. 地形抹平与半经验模型的 Landsat TM/ETM+地形校正方法. *遥感学报*, 18(2): 287-306) [DOI: 10.11834/jrs.20143258]
- Kang X W and Feng Z K. 2011. An introduction to ASTER GDEM and procedure reading. *Remote Sensing Information*, (6): 69-72 (康晓伟, 冯钟葵. 2011. ASTER GDEM 数据介绍与程序读取. *遥感信息*, (6): 69-72) [DOI: 10.3969/j.issn.1000-3177.2011.06.014]
- Li C C, Wang J, Hu L Y, Yu L, Clinton N, Huang H B, Yang J and Gong P. 2014. A circa 2010 thirty meter resolution forest map for China. *Remote Sensing*, 6(6): 5325-5343 [DOI: 10.3390/rs6065325]
- Li M Q, Im J and Beier C. 2013. Machine learning approaches for forest classification and change analysis using multi-temporal Landsat tm images over Huntington wildlife forest. *GIScience and Remote Sensing*, 50(4): 361-384 [DOI: 10.1080/15481603.2013.819161]
- Li Y D, Hao Z B and Lei H. 2016. Survey of convolutional neural network. *Journal of Computer Applications*, 36(9): 2508-2515 (李彦冬, 郝宗波, 雷航. 2016. 卷积神经网络研究综述. *计算机应用*, 36(9): 2508-2515) [DOI: 10.11772/j.issn.1001-9081.2016.09.2508]
- Liu T and Chen X. 2018. Application of deep learning in globeland30-2010 product refinement. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-3: 1111-1116 [DOI: 10.5194/isprs-archives-XLII-3-1111-2018]
- Ma Y F, Zhao J B, Li J and Qiao X S. 2018. Remote Sensing Image Classification Based on Artificial Neural Networks. *Standardization of Surveying and Mapping*, 34(4): 34-37 (马亚飞, 赵静波, 李健, 乔小松. 2018. 基于人工神经网络的遥感影像分类研究. *测绘标准化*, 34(4): 34-37)
- Maggiori E, Tarabalka Y, Charpiat G and Alliez P. 2016. Fully convolutional neural networks for remote sensing image classification//Proceedings of 2016 IEEE International Geoscience and Remote Sensing Symposium. Beijing, China: IEEE [DOI: 10.1109/IGARSS.2016.7730322]
- Pimple U, Sithi A, Simonetti D, Pungkul S, Leadprathom K and Chidthaisong A. 2017. Topographic correction of Landsat TM-5 and Landsat OLI-8 imagery to improve the performance of forest classification in the mountainous terrain of northeast Thailand. *Sustainability*, 9(2): 258 [DOI: 10.3390/su9020258]
- Ronneberger O, Fischer P and Brox T. 2015. U-Net: convolutional networks for biomedical image segmentation//Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Shelhamer E, Long J and Darrell T. 2017. Fully convolutional networks for semantic segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4): 640-651 [DOI: 10.1109/TPAMI.2016.2572683]
- Soenen S A, Peddle D R and Coburn C A. 2005. SCS+C: A modified sun-canopy-sensor topographic correction in forested terrain. *IEEE Transactions on Geoscience and Remote Sensing*, 43(9): 2148-2159 [DOI: 10.1109/TGRS.2005.852480]
- Tang P, Zheng K, Shan X J, Hu C M, Huo L Z, Zhao L J and Li H Y. 2016. Framework of remote sensing image automatic processing with "invariant feature point set" as control data set. *Journal of Remote Sensing*, 20(5): 1126-1137 (唐嫔, 郑柯, 单小军, 胡昌苗, 霍连志, 赵理君, 李宏益. 2016. 以“不变特征点集”为控制数据集的遥感图像自动化处理框架. *遥感学报*, 20(5): 1126-1137) [DOI: 10.11834/jrs.20166222]
- Vermote E, Justice C, Claverie M and Franch B. 2016. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. *Remote Sensing of Environment*, 185: 46-56 [DOI: 10.1016/j.rse.2016.04.008]
- Xu H M. 2018. Method research of high resolution remote sensing image classification based on U-net model of Deep learning. Chengdu: Southwest Jiaotong University (许慧敏. 2018. 基于深度学习 U-Net 模型的高分辨率遥感影像分类方法研究. 成都: 西南交通大学)

Topographic correction effect on classification accuracy for deep neural network classifier—A case study of the U-Net model

JIA Li^{1,2}, ZHENG Ke¹, TANG Ping¹, HUO Lianzhi¹

1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;

2. University of Chinese Academy of Sciences, School of Electronic, Electrical and Communication Engineering, Beijing 100049, China

Abstract: Remote sensing image classification technology has been widely used in land resource monitoring, forest resource investigation, and other related fields. For the traditional classification methods, terrain effect is an unavoidable factor that restricts the improvement of classification accuracy in the classification of land cover types, and the influence can be weakened by an appropriate correction model, and topographic correction has been proven to play a positive role in improving classification accuracy. Compared with traditional classifiers, deep neural network classifiers based on deep learning theory have the advantages of deep feature learning and expression, which have emerged in the field of image classification and have been gradually applied to land cover classification with good results. Our study has some shortcomings. First, some errors remain in GlobeLand30 and national forest classification products compared with the actual surface cover types. Therefore, more detailed and accurate classification results need to be found as sample labels in the future. Second, the surface of sunny-shady slopes with different types of coverage is not considered in this study. Finally, U-Net should not be the sole focus. In subsequent research, we will attempt to select a variety of deep neural network classifiers to explore the classification accuracy changes before and after topographic correction of neural network models at a more precise scale to obtain further conclusions.

This paper further explores the influence of topographic correction on the classification accuracy of land cover classification by deep neural network classifiers.

Using Landsat 8 OLI image data and GDEM_V2 terrain data with 30 m resolution as data sources, and based on the classification results of GlobeLand30 and national forest types, this paper implemented the classification extraction of land cover types by the U-Net semantic segmentation network and made a comparative analysis of classification accuracy before and after topographic correction with different sample acquisition methods and different levels of classification systems.

Classification results show the following. (1) With two training sample acquisition methods, namely, grid clipping and aspect auxiliary clipping, the classification accuracy after topographic correction is unchanged or slightly reduced compared with that before correction, and the reduction range is 0.9%—1.39%. (2) For the classification of more precise forest types, the classification accuracy after topographic correction decreased by 1.66% compared with that before correction.

In this paper, we conduct a preliminary study and find that in the classification of land cover types by the U-Net model with different sample acquisition methods, namely, regular grid clipping and aspect auxiliary clipping, and under different classification systems, the classification accuracy of the deep neural network classifier-U-Net is not improved by the topographic correction process.

Our study has some shortcomings. First, some errors remain in GlobeLand30 and national forest classification products compared with the actual surface cover types. Therefore, more detailed and accurate classification results need to be found as sample labels in the future. Second, the surface of sunny-shady slopes with different types of coverage is not considered in this study. Finally, U-Net should not be the sole focus. In subsequent research, we will attempt to select a variety of deep neural network classifiers to explore the classification accuracy changes before and after topographic correction of neural network models at a more precise scale to obtain further conclusions.

Key words: remote sensing classification, deep neural network, U-Net model, topographic correction, land cover classification, classification accuracy

Supported by National Facilities and Information Infrastructure for Science and Technology (No. 2014FY210800); National Natural Science Foundation of China (No. 41971396, No. 41401421); Strategic Priority Research Program of the Chinese Academy of Sciences (No. XDA19080301)