

引用格式: Cui Gang, Wu Jinsheng, Yu Zhen, *et al.* Comparison Analysis on Wheat Mapping Using Deep Learning Algorithm from Different Satellite Data Source[J]. Remote Sensing Technology and Application, 2019, 34(4): 748-755. [崔刚, 吴金胜, 于镇, 等. 深度学习对不同分辨率影像冬小麦识别的适用性研究[J]. 遥感技术与应用, 2019, 34(4): 748-755.]  
doi:10.11873/j.issn.1004-0323.2019.4.0748

# 深度学习对不同分辨率影像冬小麦识别的适用性研究

崔刚, 吴金胜, 于镇, 周玲

(国家统计局山东调查总队, 山东 济南 250001)

**摘要:** 定量分析遥感影像尺度与分类精度之间的关系是进行土地覆盖分类的基础。深度学习具有从底层到高层特征非监督学习的能力, 解决了传统分类模型中需要人工选择特征的问题。这种新型的分类方法的分类精度是否受到不同分辨率尺度影响, 有待研究。利用深度卷积神经网络(Deep Convolutional Neural Network, DCNN)——金字塔场景分析网络(Pyramid Scene Parsing Network, PSPNet)进行4种分辨率(8、3.2、2和0.8 m)的米级、亚米级影像冬小麦分类。实验结果表明: PSPNet能够有效地进行大样本的学习训练, 非监督提取出空间特征信息, 实现“端一端”的冬小麦自动化分类。不同于传统分类器分类精度与分类尺度之间的关系, 随着影像分辨率的逐步增高, 地物表达特征越来越清晰, PSPNet识别的冬小麦精度会逐步增高, 识别地块结果也越来越规整, 不受分辨率尺度的影响。这对于选择甚高亚米级影像提高作物分类精度提供了实验基础。

**关键词:** 图像融合; 深度卷积神经网络; ResNet; PSPNet; 高分1/2号卫星

**中图分类号:** S127; TP79 **文献标志码:** A **文章编号:** 1004-0323(2019)04-0748-08

## 1 引言

空间分辨率是影响遥感技术进行土地覆盖/利用分类精度的关键, 过大或过小的空间分辨率都会对土地覆盖的遥感提取精度产生影响, 需要二者之间的平衡<sup>[1-2]</sup>。因此, 掌握影像分辨率尺度与地物格局之间的内在关系, 确定最优的影像分辨率, 是保证高精度土地覆盖/利用遥感识别的关键。

Markham等<sup>[3]</sup>研究发现, 遥感影像空间分辨率的大小对分类精度影响存在两面性, 即不是随着分辨率的增高分类精度会一味地提升。在进行遥感影像土地覆盖分类时, 精细的空间分辨率可减少边界的混合像元, 在一定程度上提高分类的精度; 但过高的分辨率也会造成地物内部的光谱异质性增

大, 从而降低分类精度<sup>[4]</sup>。可见, 满足高精度地物识别的最优影像空间分辨率是进行土地覆盖/利用遥感分类重点考虑的方面。Bian总结地理方差、局部方差、纹理分析和分形是研究尺度和分辨率之间的效应关系。Woodcock等<sup>[5]</sup>提出局部方差和Markowitz<sup>[6]</sup>提出的变异函数方法, 是基于空间统计学中的空间依赖理论分析空间尺度对地物的表达效果。陈春雷等<sup>[7]</sup>利用中、高分辨率遥感影像进行了局部变异、变异函数的适用性和验证。在确定遥感影像空间分辨率对地物表达适应性能力方面, 明冬萍等<sup>[1]</sup>提出了基于可变窗口与可变分辨率的改进局部方差方法, 以局部方差为衡量标准来确定最优分辨率。韩鹏等<sup>[8]</sup>基于信息熵选择遥感分类的最优空间尺度, 冯桂香等<sup>[9]</sup>采用 Triangular Prism Method

收稿日期: 2018-05-10; 修订日期: 2019-06-20

基金项目: 山东三农普无人机飞行测量服务项目。

作者简介: 崔刚(1967—), 男, 山东茌平人, 高级统计师, 主要从事社会经济调查、农业调查。E-mail: cuigang@stats-sd.gov.cn。

通讯作者: 吴金胜(1979—), 男, 山东武城人, 主要从事农业调查、农业遥感统计。E-mail: wjs@stats-sd.gov.cn。

(TPM)、Double Blanket Method、TPM 3种分形维数确定影像的分辨率。以上方法利用不同的定量指标表达出遥感分辨率与目标地物尺度之间的关系,从地物类型尺寸、光谱异质性以及地物景观特征等方面确定出最优影像的空间分辨率。

其实,对于土地覆盖提取,最优分辨率的确定不但会受到影像尺度的影响,也受到分类器的影响。杨闫君等<sup>[10]</sup>在分析空间分辨率与纹理特征对多光谱遥感分类性能的影响中,总结 Artificial Neural Network (ANN)相对于 Support Vector Machine (SVM), Maximum Likelihood Classification (MLC) 分类器的精度最高,确定实验区内多光谱特征的最优分辨率为5 m,加入纹理信息后,2 m分辨率下分类精度均有所提高。总结来看,遥感信息分析的最终目的是准确地提取出目标地物类型,而最优分辨率的确定受诸多因素的影响,如遥感影像特征(光谱特征、纹理)、分类器、区域景观和地物复杂性等因素,因此单靠光谱特征确定的最优分辨率难以在大区域上进行推广应用。

深度学习是近些年伴随并行计算和大样本标记样本学习的基础上发展起来的<sup>[11]</sup>。相对于传统单层隐藏层的神经网络,它包括2个及以上隐藏层深层网络,设置不同级别的感受视野实现不同空间尺度的特征学习,进行信息的提取。深度卷积神经网络(Deep Convolution Neural Network, DCNN)是一种能够从图像上有效学习空间特性的网络,已经在大尺度遥感影像分类中取得了巨大的成功<sup>[12-14]</sup>。为充分学习像元周边的空间特征,通过设定核尺寸、层数和扩张因子3种方式灵活地学习像元周边空间特征的感受视野,确定周边空间范围对中心像元的影响,同时通过卷积、池化能够从底层形状特征向抽象特征的学习,提取地物量化的本质特征<sup>[15]</sup>。DCNN非监督特征学习,能够随着输入影像特性不断优化特征<sup>[16]</sup>,这种具有弹性的特征学习方式能够适应遥感影像自身特点,更为重要一点是DCNN基于大量标记样本学习能够学习到广泛、鲁棒性强的地物特征,这一特性可以提高DCNN的泛化能力。

农作物在遥感影像上的表征受到地域、作物物候以及不同卫星数据源等方面的影响,表现出光谱差异强、农业景观特征复杂多样。已有研究表明,地物提取精度与影像空间分辨率有着内在关系,但DCNN能够多尺度非监督提取地物特征,这一特性

是否可以克服遥感影像随空间分辨率提高光谱异质性增强的问题,值得进行研究。本文利用高分一号PMS,高分二号以及相应的融合影像进行冬小麦DCNN分类,分析不同空间分辨率对冬小麦分类精度的影响,探讨DCNN是否能够适应空间分辨率的变化而持续提高冬小麦的分类精度。

## 2 研究数据

### 2.1 研究区概况

山东省位于34°22.9'~38°24.01'N, 114°47.5'~122°42.3'E,国土面积15.8万km<sup>2</sup>,占全国总面积的1.6%,与河北、河南、安徽和江苏等省毗邻。全省西部为黄淮海平原,中部为鲁中山区,山地、丘陵等复杂地貌约占全省面积的一半。山东的气候属暖温带季风气候,雨热同季,年平均降水量一般在550~950 mm之间,年均温11~14℃。山东省光照时数年均2 290~2 890 h,光照资源充足,热量条件可满足农作物一年两作的需要。粮食作物分夏、秋两季,其中小麦、玉米和地瓜是山东省三大主要粮食作物。本文根据冬小麦种植空间分布和地形地貌,选取了19个村开展DCNN冬小麦分类,分析影像空间分辨率对冬小麦分类精度的影响。19个村的分布如图1所示。

### 2.2 数据及预处理

影像分辨率直接影响作物的分类精度,适当分辨率是保证分类精度的关键。本研究在冬小麦生长期获取了19个村的高分一号多光谱(8 m)和全色影像(2 m)、高分二号多光谱(3.2 m)和全色影像(0.8 m)4个尺度的遥感影像。高分一号遥感影像获取时间为2017年1月下旬至2月下旬,高分二号获取时间为2017年6月上旬至中旬,均处于冬小麦生长季节内,适用于冬小麦遥感分类。由于19个村在全省分布离散(图2),每个村影像获取的具体时间不一致,跨度时间不较长,因此不再列出具体影像获取日期。

(1) 图像融合。图像融合既能继承多光谱影像的谱段特性,又能包含全色影像的空间特征,从而兼顾光谱、空间特性进行地物的提取。已有研究表明<sup>[17]</sup>, Gram-Schmidt变换(GS变换)不仅能增加空间细节,又能较好的保持光谱信息,使图像具备更高的细节。因此,本实验采用GS变换对高分1号2 m和8 m、高分2号0.8 m和3.2 m两组影像进行融合,生成2 m和0.8 m的多光谱融合数据。

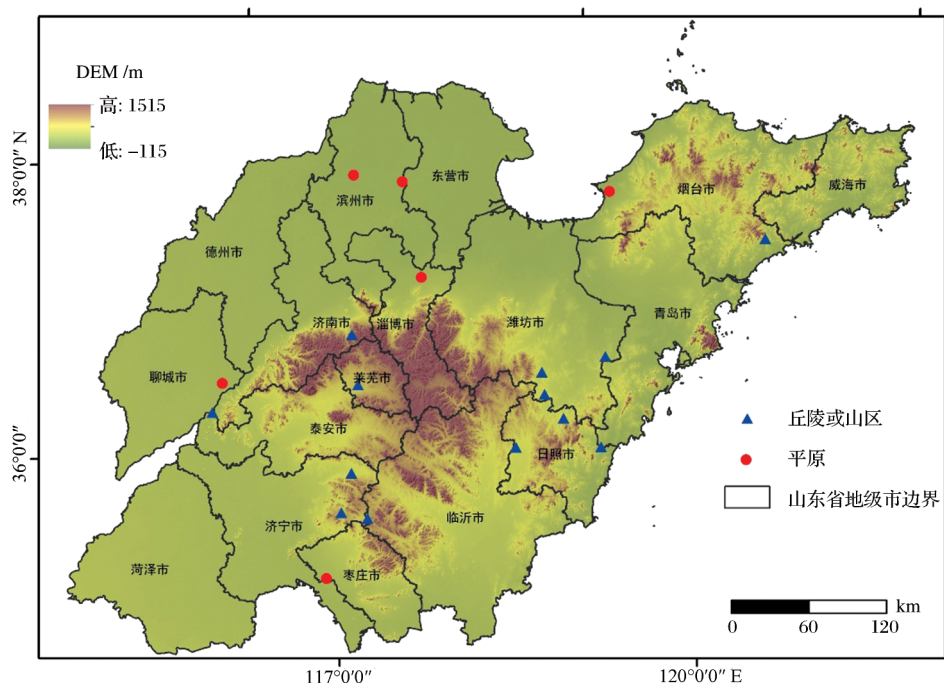


图1 山东19个村的空间分布

Fig.1 Distribution of 19 villages

(2) 图像几何精校正。利用精校正的2米遥感影像为参照图,对高分一号及二号和相应的融合影像选择控制点进行图到图的几何精校正,投影坐标系为 Albers-WGS84,两条标准纬线分别为 25°N 和 47°N,中央经线为 105°E。

(3) 标记样本构建。2017年5月开展了野外调查工作,在每个村随机布设5个200 m×200 m样方,利用GPS调查每个冬小麦地块的空间分布,共完成95个样方调查,用于高分遥感影像冬小麦地块的解译知识。大量标记样本是支撑PSPNet冬小麦遥感识别的基础,本文利用高分二号多光谱和全色融合生成的0.8 m遥感影像为底图,结合野外知识进行冬小麦目视解译,产生19个村精细的冬小麦地块,作为PSPNet训练的标记样本。

### 3 研究方法

#### 3.1 网络设计

采用卷积神经网络进行冬小麦分类,提取出冬小麦的空间分布。金字塔场景分析网络(Pyramid Scence Parsing Network, PSPNet)<sup>[18]</sup>是一种综合多尺度场景的网络架构,该架构简单,分为卷积层、金

为表达方便,对高分原始和融合影像进行命名,分别为高分二号GS融合影像(GF\_2\_GS, 0.8 m)、高分一号GS融合影像(GF\_1\_GS, 2 m)、高分二号多光谱影像(GF\_2\_MUL, 3.2 m)和高分一

字塔池化两个模块,其中卷积层的目的是实现从低层到高层特征的逐步抽象,金字塔池化是对卷积层模块最后一层抽象特征进行多尺度的池化与卷积,最后将多尺度池化/卷积特征进行上采样到卷积层最后一层尺度保持一致,进行二者的连接和卷积,然后反卷积与输入图像的尺度保持一致,判定每一个像元类型的归属,实现冬小麦的提取。PSPNet具有多方面优势,首先网络具有很好的灵活性,前半部分有效集成基础卷积层模块产生的特征,而卷积层模块可以采用不同的经典网络架构,如 AlexNet<sup>[19]</sup>,VGGNet<sup>[20]</sup>,GoogleNet<sup>[21]</sup>和 ResNet<sup>[22-23]</sup>等进行不同层级的特征提取;其次,在金字塔池化层部分能够通过池化实现4个尺度的全局特征学习,提供优于像元场景解析的全局上下文关系,多个层次复合可以保持全局到局部的细节,得到更加丰富的地物间上下文特征。图2是利用PSPNet进行冬小麦识别的网络框架设计,主要是针对输入的多光谱影像进行ResNet学习,然后学习到的特征输入到金字塔池化模块进行多尺度的特征学习,最终将ResNet与多尺度池化/卷积特征进行联合,通过Softmax函数判定像元类型,得到冬小麦的空间分布。

号多光谱影像(GF\_1\_MUL, 8 m)。利用PSPNet对4种尺度的影像进行冬小麦提取,分析不同尺度对分类结果的影响,从而解释DCNN对尺度的适应能力。






图2 基于PSPNet的冬小麦识别流程

Fig.2 Winter wheat identification using PSPNet

### 3.2 实验流程

针对多光谱和融合影像的4种尺度数据利用PSPNet进行训练,识别不同分辨率影像上的冬小麦。大量标记样本是进行PSPNet训练实现强泛化能力的基础,但建设大量样本需要投入大量的人力。迁移学习能够有效地从已有训练好的网络模型中迁移相应网络层的权重,要比“Scratch”随机方式确定的阈值更能够实现快速收敛,再利用少数的标记样本微调(Fine-tuning)训练模型,一定程度上消除“过拟合”问题<sup>[24]</sup>。根据研究组已经形成的全覆盖山东省米级土地覆盖数据,其分类体系包括农作物用地和其他用地类型,分割成500像素×500像素,样本量可达到20万多个,这能够满足PSPNet大样本训练的需求。利用该样本进行PSPNet训练,检验精度达到90%以上,形成预训练模型。针对本实验4个分辨率尺度的遥感影像数据集进行切割,随机选择15个村作为训练集合,剩余4个村用作检验和预测数据集。训练和检验单元为500像素×500像素的子区(Patch)。分类体系为:冬小麦、其他地物和背景。训练阶段利用PSPNet对上述4种影像进行迁移模型训练,SoftmaxWithLoss作为决策函数计算得分与标记类型之间的Loss,采用反向网络(Back Propagation, BP)不断调整权重,让Loss逐步降低,直到Loss趋于稳定并达到预先设定的标准或者达到达到最高的循环次数。利用训练好的模型用于检验的4个村影像,通过Softmax函数将像元的得分转换为地物的归属概率,实现对冬小麦类型归属的判定。

### 3.3 精度评价

采用误差矩阵进行冬小麦识别的精度评价<sup>[25]</sup>,总体精度(Overall Accuracy, OA)、生产精度(Producer's Accuracy, PA)和用户精度(User's Accuracy, UA)是进行土地覆盖精度评价的常用定量指

标,分别定量刻画了区域内识别精度、目标地物分类结果识别正确的精度(反映错出误差)、目标地被识别正确的精度(反映错入误差)。对于目标地物而言, $F_1$ -Score作为综合性指标表达目标地物识别精度的高低<sup>[12]</sup>。

$$F_1 - Score = 2 \frac{OA \cdot PA}{OA + PA} \quad (1)$$

## 4 结果分析

### 4.1 不同尺度的图像光谱特征分析

图3选取了高分一号、高分二号的一个子区影像和对应的GS融合影像。直观上看,GS融合影像的光谱信息较输入图像的差异比较大,这是融合过程中光谱信息损失的问题,但空间信息变得更为清晰。对于冬小麦,融合影像能够清晰的描述地块分布,地块边缘清晰,但对于高分一号影像地块边缘略微模糊,这是由于分辨率相对较粗(8 m)的缘故。

影像方差是一个用于衡量影像信息量的常用指标,描述为偏离影像均值的程度,是衡量一幅影像信息量大小的重要参量<sup>[25]</sup>。影像方差越小,则图像的对比度越小,色调越为单一,则信息量越小;方差越大,则表示所含的信息量越为丰富。图4是高分一号、二号原始影像和对应GS融合影像的灰度值方差。整体上看,两个影像融合前后光谱方差是降低的,这主要是融合后图像空间分辨率虽得以提高,但是原始光谱信息会有一定的损失。

### 4.2 尺度对冬小麦识别精度的影响分析

为分析尺度变化对PSPNet与传统分类方法分类结果的影响,实验中利用支撑向量机(Support Vector Machine, SVM)对4个检验村进行分类。SVM是使用非线性映射算法将低维输入空间线性不可分的样本转化为高维特征空间使其线性可分,在结构风险最小化理论之上在特征空间中构建最






图3 影像与对应的融合影像(子区图)

Fig.3 Image and fusion image (subregion)




Fig.4 Variance of four remote sensing images

优越平面,使得学习达到全局最优<sup>[26]</sup>。考虑到在4个分辨率尺度上应用SVM分类的适用性,在4个检验村选取样本的时候尽量位于尺寸较大的地物之内,然后采用二值SVM分类提取出冬小麦分布。表1是4个检验村冬小麦识别结果的精度评价,PSPNet在4个尺度上分类结果总体精度均超过了

80%。其中,GF-2-GS总体精度最高,达到90%以上,随后依次是GF-1-GS、GF-2-MUL和GF-1\_MUL,基本趋势是随着影像空间分辨率降低识别精度也随之降低。对于目标冬小麦而言,识别精度变化趋势也是一样的,GF-2-GS识别精度在4个尺度中是最高的,生产者精度为0.92,用户精度为0.86,F1-Score接近90%,而空间分辨率最低的GF-1-MUL冬小麦识别精度也是最低的。从4种尺度来看,随着分辨率的增高冬小麦识别精度逐步增高,二者基本同步,没有发现“最优分辨率”。GF-1-GS(2 m)虽然比GF-2-MUL(3.2 m)分辨率略高一些,但是二者分辨率仍较为接近,但GF-2-MUL更有丰富光谱优势,这是GF-2-MUL分类精度高的原因所在。在同一分辨率尺度上,PSPNet要优于SVM识别结果。对比分析分辨率对SVM的影响,GF-2-MUL识别出的冬小麦精度最高,其次是GF-2-GS、GF-1-GS和GF-1-MUL,这一结论与PSPNet分类得到的GF-2-GS最优有所不同。分

析原因是,PSPNet是一种深度卷积神经网络,通过多层卷积学习能够学习到优化的光谱、纹理、上下文特征进行分类,而且大数量标记学习可以增强这一学习的泛化能力,这突破了只用光谱特征进行SVM分类的局限。从4.1节中分析得出融合影像会造成一定的光谱信息损失,增强了光谱的异质性,因此光谱明显、空间特征适中的3.2 m GF-2-MUL适合SVM分类,有利于冬小麦的提取。

#### 4.3 子区图分析

选择海阳市北城阳村来进一步分析冬小麦的

分类细节,该村是一个典型的山地村庄,平坦农田和山地共存,冬小麦多分布在山脚的平坦地区。从图5(a)可以看出,山区植被与冬小麦的光谱较为接近。图5(c)~(f)是PSPNet在4个尺度影像上提取出的冬小麦结果。

从识别的冬小麦地块来看,随着像元分辨率提高,冬小麦地块越来越精细。GF-1-MUL影像分辨率为8m,混合像元现象突出,一些其它地物易混入到冬小麦识别结果中,破碎的地块明显,这种混淆现象会随着分辨率的增高而一定程度上消除。GF-1-GS和GF-1-MUL两个影像的分辨率分别为2 m和3.2 m,二者识别的冬小麦地块比较接近。GF-2-GS在表达地块空间特征上最有优势,能够有利于地块精细的表达,保证细碎冬小麦地块的识别精度。可见,PSPNet能够有效地挖掘出冬小麦的空间特征,不受限于高分辨率光谱异质性的影响,保证冬小麦的识别精度。

## 5 讨论

通过研究可以得到,对于深度卷积神经网络,影像分辨率仍然是影响分类精度的一个敏感因素。从8 m到0.8 m,随着影像分辨率的升高,图像表达

表1 4种尺度冬小麦分类精度					
Table1 The accuracy of winter wheat identification for four remote sensing images					
		生产精度/%	用户精度/%	F <sub>1</sub> -Score	总体精度/%
PSPNet	GF-1-MUL	0.80	0.88	0.84	83.57
	GF-1-GS	0.84	0.89	0.86	85.26
	GF-2-MUL	0.90	0.85	0.87	89.12
	GF-2-GS	0.92	0.86	0.89	90.78
SVM	GF-1-MUL	0.77	0.83	0.80	80.29
	GF-1-GS	0.81	0.86	0.83	85.26
	GF-2-MUL	0.88	0.85	0.86	86.67
	GF-2-GS	0.88	0.83	0.85	84.35

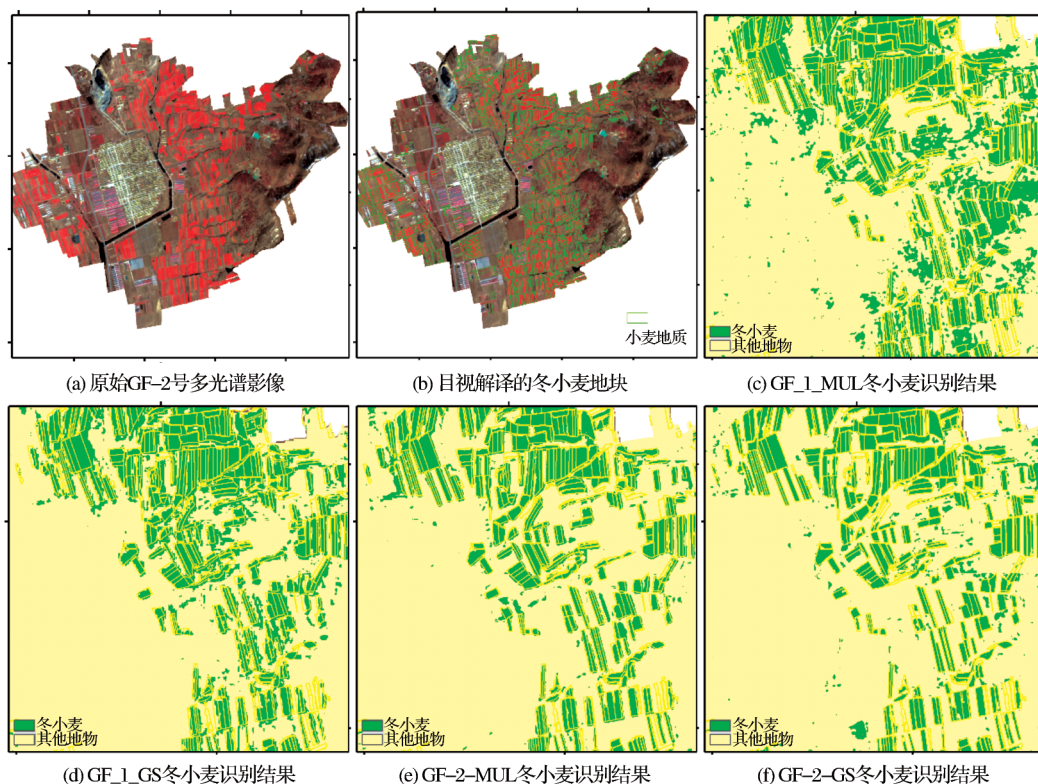


图5 分辨率尺度冬小麦识别结果

Fig.5 Results of winter wheat identification for four remote sensing images



地物的细节越来越精细。图5表明,即使影像上有与冬小麦相混的植被光谱,但随着分辨率的提高,PSPNet能够有效地利用影像的空间特征信息,通过空间特征可以准确地将冬小麦与其他光谱混淆的地物区分开,而低分辨率8 m空间信息不明显,造成光谱相混地物的混入。GF\_1\_GS和GF\_2\_MUL分辨率相近,虽然GF-2-MUL分辨率略粗,但GF-2-MUL原始光谱信息更为丰富,GF-1-GS存在光谱信息量的丢失。对于SVM分类方法,最优分辨率为3.2 m的GF\_2\_MUL,这与已有的研究结论是相同的<sup>[10]</sup>。但PSPNet可以突破这一局限,分辨率越高会增强空间特征的表达从而提高保证分类精度,这拓展了已有的研究结论“分辨率过高光谱异质性增强,降低了地物的分类精度”<sup>[4]</sup>,从而说明研究最优尺度的时候,要考虑到不同分类器特点,才能够得到更为符合实际应用的研究结论。

## 6 结 语

利用PSPNet深度卷积网络,实验分析了从8 m(高分一号多光谱,GF-1-MUL)、3.2 m(高分二号多光谱,GF-2-MUL)、2 m(GS融合多光谱:GF-1-MUL)和0.8 m(GS融合多光谱:GF-2-MUL)4个尺度影像进行冬小麦分类。从冬小麦识别结果可以得出,只要不断提高影像的空间分辨率,PSPNet能够充分地利用空间特征保证冬小麦的分类精度,消除分辨率增高造成光谱异质性的不足。这为利用PSPNet进行准确农作物信息提取最优分辨率的确定提供了实验支撑。

本研究影像分辨率是限定在米级分辨率开展的研究工作,下一步有待研究粗分辨率(如GF-1 WFV、Landsat OLI)、更细分辨率(航片)的两种尺度影像,分析卷积神经网络的尺寸以及感受野对不同分辨率影像识别地物的适应能力。

## 参考文献(References):

- [1] Ming Dongping, Wang Qun, Yang Jianyu. Spatial Scale of Remote Sensing Image and Selection of Optimal Spatial Resolution[J]. Journal of Remote Sensing, 2008, 12(4): 529-537. [明冬萍,王群,杨建宇. 遥感影像空间尺度特性与最佳空间分辨率选择[J]. 遥感学报, 2008, 12(4): 529-537.]
- [2] Ming Dongping, Qiu Yufang, Zhou Wen. Applying Spatial Statistics into Remote Sensing Pattern Recognition: with Case Study of Cropland Extraction based on GeOBIA[J]. Acta Geodaetica of Cartographica Sinica, 2016, 45(7): 825-833. [明冬萍,邱玉芳,周文. 遥感模式分类中的空间统计
- 学应用——以面向对象的遥感影像农田提取为例[J]. 测绘学报, 2016, 45(7): 825-833.]
- [3] Markham B L, Townshend J R G. Land Cover Classification Accuracy as a Function of Sensor Spatial Resolution[C]// Proceedings 15th Int. Symp. on Remote Sensing of Environment, Ann Arbor, MI, 1981.
- [4] Marceau D J, Hay G J. Remote Sensing Contributions to the Scale Issue[J]. Canadian Journal of Remote Sensing, 1999, 25(4): 357-366.
- [5] Woodcock C E, Strahler A H. The Factor of Scale in Remote Sensing[J]. Remote Sensing of Environment, 1987, 21(3): 311-332.
- [6] Markowitz H. Portfolio Selection-Efficient Diversification of Investments[M]. New York: Wiley, 1959.
- [7] Chen C L, Wu G. Choice of Optimal Scale for Multi-source Remote Sensing Images[J]. Journal of Zhejiang A & F University, 2011, 28(1): 164-172.
- [8] Han P, Gong J Y, Li Z L, *et al.* Selection of Optimal Scale in Remotely Sensed Image Classification[J]. Journal of Remote Sensing, 2010, 14(3): 507-518.
- [9] Feng Guixiang, Ming Dongping. Fractal based Method on Selecting the Optimal Spatial Resolution for Remote Sensing Image[J]. Journal of Geo-Information Science, 2015, 17(4): 478-495. [冯桂香,明冬萍. 分形定量选择遥感影像最佳空间分辨率的方法与实验. 地理信息科学, 2015, 17(4): 478-495.]
- [10] Yang Yanjun, Tian Qingjiu, Zhan Yulin, *et al.* Effects of Spatial Resolution and Texture Features on Multi-spectral Remote Sensing Classification[J]. Journal of Geo-information Science, 2018, 20(1): 99-107. [杨闫君,田庆久,占玉林,等. 空间分辨率与纹理特征对多光谱遥感分类的影响. 地理信息科学, 2018, 20(1): 99-107.]
- [11] Reichstein M, Camps-Valls G, Stevens B, *et al.* Deep Learning and Process Understanding for Data-Driven Earth System Science[J]. Nature, 2019, 566(7743): 195-204.
- [12] Maggiori E, Tarabalka Y, Charpiat G, *et al.* Convolutional Neural Networks for Large-scale Remote Sensing Image Classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 55(2): 645-657.
- [13] Wei Y N, Wang Z L, Xu M. Road Structure Refined CNN for Road Extraction in Aerial Image[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 709-713.
- [14] Zhang Bing. Remotely Sensed Big Data Era and Intelligent Information Extraction[J]. Geomatics and Information Science of Wuhan University, 2018, 53(12): 1861-1871. [张兵. 遥感大数据时代与智能信息提取[J]. 武汉大学学报(信息科学版), 2018, 53(12): 1861-1871.]
- [15] Zhang Kang, Hei Baoqin, Li Shengyang, *et al.* Complex Scene Classification of Remote Sensing Images based on CNN[J]. Remote Sensing for Land Resources, 2018, 33(6): 1095-1102. [张康,黑保琴,李盛阳,等. 基于CNN模型的遥感图像复杂场景分类[J]. 国土资源遥感, 2018, 33(6):



- 49–55.]
- [16] Yokoya N, Iwasaki A. Object Detection based on Sparse Representation and Hough Voting for Optical Remote Sensing Imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(5): 2053–2062.
- [17] Xu Kaijian, Tian Qingjiu, Yang Yanjun, *et al.* Response of Spatial Scale for Land Cover Classification of Remote Sensing[J]. Journal of Geo-Information Science, 2018, 20(2): 246–253.[徐凯健,田庆久,杨闫君,等.遥感土地覆被分类的空间尺度响应研究[J].地球信息科学学报,2018,20(2): 246–253.]
- [18] Zhao H S Shi J P, Qi X J, *et al.* Pyramid Scene Parsing Network[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 2881–2890.
- [19] Krizhevsky A, Sutskever I, Hinton G E. ImageNet Classification with Deep Convolutional Neural Networks[C]// International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012:1097–1105.
- [20] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. Computer Science, 2014:1409–1556.
- [21] Szegedy C, Ioffe S, Vanhoucke V, *et al.* Inception—v4, Inception—Resnet and the Impact of Residual Connections on Learning[C]// Thirty-First AAAI Conference on Artificial Intelligence, 2017, 4278–4284
- [22] He K, Zhang X, Ren S, *et al.* Deep Residual Learning for Image Recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [23] Yosinski J, Clune J, Bengio Y, *et al.* How Transferable are Features in Deep Neural Networks?[C]// Advances in Neural Information Processing Systems, 2014: 3320–3328.
- [24] Zhou Jingping, Li Cunjun, Shi Leigang, *et al.* Crops Distribution Remote Sensing Extraction based on Decision Tree and Object-oriented Method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(9): 318–326.[周静平,李存军,史磊刚,等.基于决策树和面向对象的作物分布信息遥感提取[J].农业机械学报,2016,47(9):318–326.]
- [25] Weng Yongling, Tian Qingjiu. Analysis and Evaluation of Method on Remote Sensing Data Fusion[J]. Remote Sensing Information, 2003(3):49–54.[翁永玲,田庆久.遥感数据融合方法分析与评价综述[J].遥感信息,2003(3):49–54.]
- [26] Li Shuming, Feng Quanlong, Liang Qichun, *et al.* Aircraft Auto-detection in Domestic High Resolution Remote Sensing Images Using Deep-learning[J]. Remote Sensing Technology and Application, 2018, 33(6): 1095–1102.[李淑敏,冯权流,梁其椿,张学庆.基于深度学习的国产高分遥感影像飞机目标自动检测[J].遥感技术与应用,2018,33(6): 1095–1102.]

## Comparison Analysis on Wheat Mapping Using Deep Learning Algorithm from Different Satellite Data Source

Cui Gang, Wu Jinsheng, Yu Zhen, Zhou Ling

(Survey Office of the National Bureau of Statistics in Shandong, Ji'nan, 250001, China)

**Abstract:** Quantitative analysis on the relationships between the remote sensing scale and the land cover classification accuracy, which is the basis for making a decision on remote sensing resolution determination, is essential for mapping the concise land cover. Up to now, deep learning is an innovative algorithm to learn the hierarchical layer features without supervised control, which is different from the traditional classifiers that require man-made labels as input. Therefore, it is interesting to explore the inherent relationship between the classification accuracy and remote sensing image spatial scale from this algorithm. In this paper, we applied a Deep Convolutional Neural Network (DCNN) which is Pyramid Scene Parsing Network (PSPNet) on four scale remote sensing image (8 m, 3.2 m, 2 m, 0.8 m) to map the wheat distribution. The experiment results showed that the PSPNet is good at learning the spatial feature without manual operations, then the wheat extent could be extracted automatically. Different from the conventional algorithm of determining the optimized spatial resolution, the PSPNet could identify the wheat better accompanying with the spatial resolution increased and more concise wheat results could be obtained. This conclusions represent that deep convolution neural network can take full use of the spatial information of the high remote sensing image to ensure the performance of wheat extent, which brings us a new idea of improving the accuracy of crop mapping adequately if we can get the super-high resolution remote sensing image.

**Key words:** Image fusion; Deep Convolution Neural Network; ResNet; PSPNet; GF-1/2