

高分二号遥感影像提取冬小麦空间分布

宋德娟¹, 张承明^{1,2}, 杨晓霞¹, 李峰³, 韩颖娟⁴, 高帅⁵, 董海燕¹

1. 山东农业大学 信息科学与工程学院, 泰安 271018;

2. 山东省数字农业工程技术研究中心, 泰安 271018;

3. 山东省气候中心, 济南 250031;

4. 中国气象局 旱区特色农业气象灾害监测预警与风险管理重点实验室, 银川 750002;

5. 中国科学院空天信息创新研究院, 北京 100094

摘要: 精细的农作物空间分布数据对于资源、环境、生态、气候变化和粮食安全问题均具有重要的意义, 卷积神经网络已经成为从遥感影像中提取农作物空间分布数据的主要方法, 但提取结果中的种植区域边缘往往比较粗糙。本文以高分二号遥感影像为数据源, 选择冬小麦为提取目标, 利用RefineNet模型和最大后验概率模型构建冬小麦遥感提取模型WWRSE (Winter Wheat Remote Sensing Extraction), 获取精细的冬小麦空间分布数据。WWRSE模型利用RefineNet网络提取像素的语义特征, 使用改进的SoftMax模型生成像素的类别概率向量; 以类别概率向量的最大分量与次大分量的差值作为置信度, 根据置信度将类别概率向量分为可信和不可信两组, 可信组直接使用最大分量对应的类别标签作为相应像素的分类结果; 结合最大后验概率模型确定不可信组像素的分类结果。利用随机梯度法对WWRSE模型进行训练。选择SegNet、DeepLab、RefineNet作为对比模型进行实验, WWRSE提取结果的精度为92.9%, 比SegNet提高了13.8%, 比DeepLab提高了10.9%, 比RefineNet提高了8.6%。实验结果表明WWRSE模型在提取冬小麦空间分布数据方面具有一定的优势。WWRSE模型提取的结果能够为大范围冬小麦种植面积统计提供依据。

关键词: 高分二号, 卷积神经网络, RefineNet模型, 最大后验概率模型, 冬小麦, 空间分布, 章丘

引用格式: 宋德娟, 张承明, 杨晓霞, 李峰, 韩颖娟, 高帅, 董海燕. 2020. 高分二号遥感影像提取冬小麦空间分布. 遥感学报, 24(5): 596-608

Song D J, Zhang C M, Yang X X, Li F, Han Y J, Gao S and Dong H Y. 2020. Extracting winter wheat spatial distribution information from GF-2 image. *Journal of Remote Sensing(Chinese)*, 24(5): 596-608[DOI:10.11834/jrs.20208285]

1 引言

冬小麦是中国主要粮食作物之一, 及时、准确地获取冬小麦种植空间分布数据, 有助于政府相关部门更好地指导农业生产, 调整农业结构以保障国家粮食安全 (Wang 等, 2018; 郭文茜等, 2018)。

遥感图像具有时效性强、覆盖范围大、信息丰富等特点, 是获取冬小麦空间分布数据的良好数据源 (Zhang 等, 2014)。MODIS (Moderate Resolution Imaging Spectroradiometer)、ETM/TM

(Enhanced Thematic Mapper/Thematic Mapper) 和 SPOT (Système Probatoire d'Observation de la Terre) 是较早应用于农作物信息提取的数据源 (许青云等, 2014; Pringle 等, 2012)。逐像素分类技术是从遥感图像中获取农作物空间分布数据的主要手段, 为了提高逐像素分类结果的精度, 许多学者进行了大量的研究工作。何浩等 (2008) 以 SPOT 为数据源, 利用非监督—人工聚类法提取冬小麦空间分布信息并分析尺度变化对冬小麦种植面积遥感测量精度的影响。冯美臣等 (2009) 利用 MODIS 和 ETM/TM 数据, 使用监督分类法提取了

收稿日期: 2018-06-30; 预印本: 2019-03-04

基金项目: 山东省自然科学基金(编号:ZR2017MD018); 宁夏回族自治区重点研发计划(编号:2019BEH03008); 国家重点研发计划(编号:2017YFA0603004); 中国气象局旱区特色农业气象灾害监测预警与风险管理重点实验室开放研究项目(编号:CAMF-201701, CAMF-201803); 中国气象局干旱气候变化与减灾重点开放实验室干旱气象科学研究基金(编号:IAM201801)

第一作者简介: 宋德娟, 1994年生, 女, 硕士研究生, 研究方向为遥感信息提取。E-mail: 15650099558@163.com

通信作者简介: 张承明, 1971年生, 男, 副教授, 研究方向为遥感信息提取。E-mail: chming@sdau.edu.cn

山西省的冬小麦种植面积, 郝卫平等 (2011) 利用 ISODATA 非监督分类法, 从 ETM 影像和 MODIS 影像中提取农作物空间分布信息。美国 LACIE 计划利用 TM 和地面调查资料, 通过监督分类法提取小麦面积提取, 结果精度达到 90% 以上; 欧盟 MARS 计划则是将非监督分类法应用到农作物种植面积提取和产量预报应用中 (孙振蓉, 2015)。另有学者以时序 MODIS 数据作为数据源提取冬小麦空间分布 (黄健熙等, 2016)。以上研究均成功地提取了冬小麦等农作物的种植面积和空间分布数据, 但由于数据源为中低分辨率遥感影像, 提取结果的空间分辨率较低, 不能很好地满足应用需求。

随着遥感技术的发展, 高空间分辨率遥感影像逐渐成为提取农作物空间分布信息的主要数据源 (邬明权等, 2014)。与中低空间分辨率影像相比, 高空间分辨率遥感影像的细节更为丰富, 但高空间分辨率影像的光谱统计特性不如中低空间分辨率影像的光谱特征稳定, 同物异谱和同谱异物现象更加普遍, 增加了提取难度 (刘大伟等, 2016)。提取像素特征是进行逐像素分类的关键步骤 (钱晓亮等, 2018; 赵理君和唐娉, 2016), 传统的监督分类方法和非监督分类方法, 仅能提取图像的颜色、形状、纹理等低层特征, 不能提取更高层语义特征, 应用于高空间分辨率影像进行特征提取时, 所得特征的区分能力较差, 往往导致最后分类结果不理想 (李德仁等, 2014)。为了从高空间分辨遥感影像上获得更好的像素特征, 研究者使用了神经网络 NN (Neural Networks) (Mas 和 Flores, 2008) 和支持向量机 SVM (Support Vector Machines) 等方法 (Mountrakis 等, 2011; 陈杰等, 2014)。游炯等 (2016) 采用高分一号遥感影像为数据源, 利用 SVM 进行冬小麦信息提取, 取得了较好的效果。Liu 等 (2015) 在分类过程中加入影像的纹理、结构等特征, 进一步提高了提取结果的质量。但 SVMs 和 NNs 都是浅层的学习算法, 由于网络结构有限, 这些算法很难有效地表达复杂的特征。当样本数量以及样本的多样性增加时, 浅层学习模型就难以得到好的结果 (Wang 等, 2015)。

卷积神经网络 CNN (Convolutional Neural Networks) 是深度学习的重要分支, 由于其出色的特征提取能力, 在目标分类和识别中取得了很好的效果 (Wu 等, 2010; Hu 等, 2015)。Shelhamer 等 (2017) 在 CNN 的基础上提出了全卷积网络模

型 FCN (Fully Convolutional Networks), FCN 通过将 CNN 网络最后的全连接层替换为上采样层, 实现了逐像素分类。此后, 很多研究对 FCN 进行了拓展, 形成了一系列图像分割模型, 如 SegNet (Badrinarayanan 等, 2017), UNet (Ronneberger 等, 2015), DeepLab (Chen 等, 2018a), Multi-Scale FCN (Lin 等, 2017), ReSeg (Visin 等, 2016)、RefineNet (Lin 等, 2017) 等。以上模型中, SegNet 和 UNet 卷积结构清晰, 容易理解, 而且处理速度较快; DeepLab 使用了一种叫做“空洞卷积”的方法, 在处理细节丰富的相机图像方面有很强的优势; Multi-Scale FCN 能够同时提取尺寸差异较大的目标, 如海洋和船只; ReSeg 通过将卷积网络提取的局部特征转换为全局特征来提高整体分类精度; RefineNet 则使用了融合细节丰富的低级特征和粗糙的高级特征的策略, 这种策略能够充分发挥不同层次特征的作用, 有利于提高结果精度。以上模型在特定类型的图像上均取得了非常好的效果。尽管 RefineNet 等模型在处理相机图像时取得了非常好的效果, 但由于遥感图像的细节远不如相机图像丰富, 将它们应用于遥感图像时, 需要根据遥感图像的特点进行相应的处理 (Zhang 等, 2018a)。

RefineNet 等模型通常分为特征提取器和分类器两部分, 其中特征提取器通过卷积运算为每个像素生成一个特征向量, 分类器根据像素的特征向量计算某个像素归属为每个类别的概率, 并组织为一个类别概率向量, 取概率最大的类别为该像素所属的类别, 这种判断规则最突出的问题在于仅仅利用了类别概率向量中最大概率值这一信息, 并没有考虑各概率之间差值大小所隐含的信息。事实上, 当类别概率向量中最大概率分量与其他分量差别较大时, 说明最大概率分量所对应的类别与该像素的匹配度要比其他类别与该像素的匹配度高, 错分的可能性很小; 而当类别概率向量中最大概率分量与其他分量差别较小时, 说明最大概率值所对应的类别与该像素的匹配度和其他类别与该像素的匹配度比较相近, 错分的可能性通常较大。因此, 提高后一类像素的分类精度, 是提高分类结果整体精度的关键。

最大后验概率模型 MAP (Maximum a posteriori estimation) 是一种规则化的最大似然估计方法, 可以结合被估计量的先验概率分布和观测结果对变量进行估计 (孟祥超等, 2014; 陈俊杰和金小

刚, 2015; 肖亮等, 2007)。利用MAP和已经获取的像素类别分布等先验知识, 能够对被错分可能性大的像素进一步处理, 提高分类结果的可靠性, 从而提高整体分类精度。

针对仅使用CNN模型提取的冬小麦空间分布结果中边缘比较粗糙的问题, 本研究利用RefineNet模型和最大后验概率模型构建冬小麦遥感提取模型WWRSE (Winter Wheat Remote Sensing Extraction)。WWRSE模型首先使用RefineNet模型对图像进行初分割, 为每个像素初步确定类别标签并生成一个类别概率向量, 根据类别概率向量筛选出被错分概率较大的像素, 利用MAP模型对筛选出的像素需要进一步处理, 最终达到获取高精度的冬小

麦空间分布数据的目标。

2 实验区和数据

2.1 实验区

本文研究区域为济南东部的章丘区, 范围在 $36^{\circ}25'N-37^{\circ}09'N$, $117^{\circ}10'E-117^{\circ}35'E$, 总面积为 1719 km^2 , 图1为实验区位置示意图。章丘区的地形自南而北依次为山区、丘陵、平原、洼地, 分别占章丘区总面积的30.8%、25.9%、30.7%和12.6%。章丘区属于暖温带半湿润大陆性季风气候, 四季分明, 雨热同季。冬小麦、玉米是该地区的主要粮食作物。

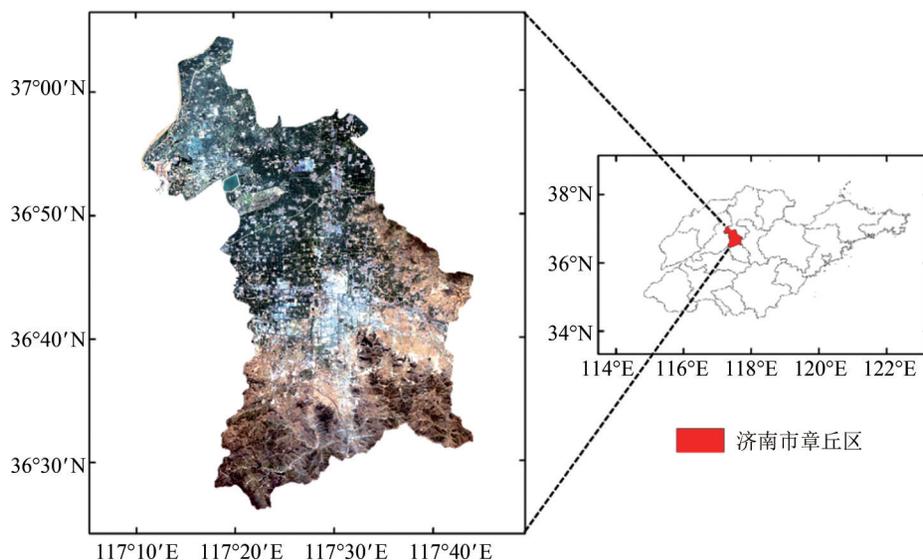


图1 山东省济南市章丘区

Fig.1 Zhangqiu district, Jinan city, Shandong province

2.2 地面调查数据

为了制作训练模型使用的样本数据, 我们分别于2017年12月6日—7日和2018年1月17日—19日在实验区进行了实地调查。调查结果包括调查时间、位置、土地利用类型等信息。调查时, 利用GPS获取位置信息, 并记录下相应的土地利用类型。地面调查共获得了89个样点的土地利用数据, 其中冬小麦样点61个, 其他类别样点28个, 图2给出了样点空间位置分布。

2.3 遥感数据

实验中使用了9幅不同时期的高分二号 (GF-2) 遥感图像, 其中5幅于2017-12-10拍摄, 4幅于

2018-01-11拍摄。这些遥感数据覆盖整个章丘市, 而且与地面调查时间吻合。所选择的遥感数据云量很少且清晰度很高, 有利于进行对比实验。GF-2卫星载荷的主要技术指标见表1。选择了2幅2018年影像、3幅2017年影像作为训练数据, 其余的影像作为测试数据。

利用ENVI (Environment for Visualizing Images) 软件对获取的GF-2图像进行预处理, 预处理步骤包括: 大气校正、几何校正、使用Pan Sharpening方法对全色光谱和多光谱波段进行融合; 将对比度拉伸生成彩色增强的合成图像等。融合后得到的图像共4个波段, 空间分辨率为1 m, 像素值为表现反射率, 所有的4个波段都作为WWRSE的输入。

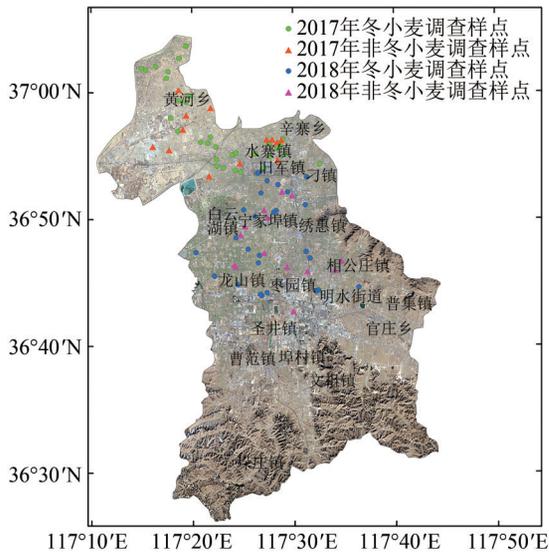


图2 样点空间分布

Fig.2 Sample spatial distribution

2.4 数据集制作

使用目视解译对遥感图像进行标记，具体步骤为：(1) 将调查样点在遥感图像上进行定位，作为人工标注的参考依据；(2) 利用地理信息系统类软件，手工勾画出冬小麦种植区域边界；(3) 利用ENVI软件中的ROI (Region of Interesting) 工具，以(2)中得到边界为基础，获取ROI区域内的像素编号；(4) 利用Python编写像素分类程序，根据(3)中的分类结果进行逐像素标记。(5) 利用ENVI软件分别对遥感图像和标记结果按从左到右，从上到下的顺序进行分块，每块的大小为480×360像素。图像块和相应的标记结果作为一对，最后共得到2622个图像-标记对，其中1456对用于训练，1165对用于测试。

表1 高分二号卫星的主要参数

Table 1 Main parameters of GF-2 satellite

传感器类型	波段号	波段范围/um	空间分辨率/m	幅宽/km	侧摆能力/(°)	重访时间/d	覆盖周期/d
全色	1	0.45-0.90	1	45	±35	5	69
	2	0.45-0.52					
多光谱	3	0.52-0.59	4	45	±35	5	69
	4	0.63-0.69					
	5	0.77-0.89					

3 方法

3.1 WWRSE 模型结构

图3给出了WWRSE模型的结构。WWRSE共分为5个部分，分别是：输入、特征提取器、

SoftMAX-Ex、MAP和输出。在训练阶段，输入由遥感图像块和相应的标记文件组成；而在测试阶段，输入仅为遥感图像块；输出结果是一个单波段文件，每个像素的值为输入图像块相应像素的类别号，在本文中，使用100表示冬小麦类别，使用200表示其他类别。

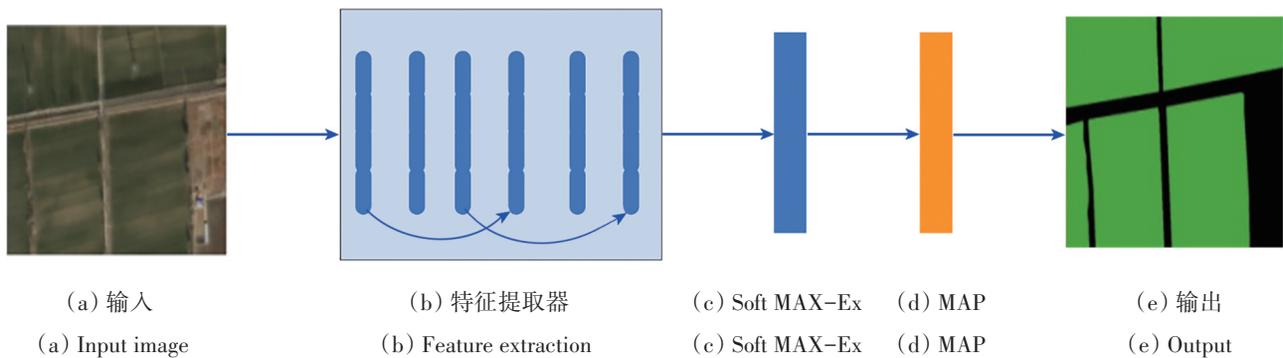


图3 WWRSE模型结构图

Fig.3 Structure of WWRSE

3.1.1 特征提取器

WWRSE模型以RefineNet的全卷积层为基础

构建特征提取器。RefineNet模型具有较强特征提取能力，该模型采用了一种被称之为“multipath”

的结构, 这种结构能够有效地融合细节丰富的低层特征和粗糙的高级特征, 得到的特征具有较强的区分能力, 从而有利于提高分类结果的精度 (Lin 等, 2016)。

考虑到而本研究使用的 GF-2 遥感影像共有 4 个波段, 我们对 RefineNet 的输入格式和卷积核结构进行了调整, 使其能够与输入图像相适应。

3.1.2 SoftMax-Ex

SoftMax-Ex 的主要作用是将卷积层提取得到的像素的特征向量转化为类别概率向量并初步确定像素类别。SoftMax-Ex 包括一个编码器和一个分类器。编码器为一个 $2 \times n$ 形式的矩阵, n 为特征向量的长度。设 x 表示像素的特征向量, w 表示编码器矩阵, r 表示编码结果向量, 计算过程如式 (1) 所示

$$\begin{bmatrix} r_1 \\ r_2 \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \end{bmatrix} \times \begin{bmatrix} x_1 & x_2 & \cdots & x_n \end{bmatrix}^T + \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} \quad (1)$$

式中, w 矩阵的每一行表示某类的一个拟合方程, b_1, b_2 为相应的偏置项, r_1, r_2 表示特征向量 x 在该类上的编码值。 w 矩阵通过训练过程确定。

分类器根据像素的编码值向量生成为类别概率向量, 并根据其中最大的概率所在的分量位置将像素划分为冬小麦像素或其他类别像素。对于每个像素的编码值向量, 本文使用式 (2) 将某个编码值向量 r 转换为类别概率向量 p (Lin 等, 2017)。

$$\begin{bmatrix} p_1 \\ p_2 \end{bmatrix} = \begin{bmatrix} \frac{e^{r_1}}{e^{r_1} + e^{r_2}} \\ \frac{e^{r_2}}{e^{r_1} + e^{r_2}} \end{bmatrix} \quad (2)$$

式中, 向量 p 为得到的类别概率向量, 每个分量表示像素归属相应类别的概率值。

分类器首先计算类别概率向量中的大者减小者的值, 将其作为置信度, 然后按照置信度确定输出内容, 当置信度大于给定的阈值时, 分类器的输出与传统 SoftMax 的输出一样, 输出像素的类别; 而当置信度小于给定的阈值时, 分类器将仅仅输出类别概率向量, 由 MAP 模型进一步确定像素的类别。本文以 0.28 作为置信度阈值。

3.1.3 MAP 层

MAP 层结合其他信息进一步确定置信度低级的像素的类别, 提高这一类像素类别判定的可靠性。以 CL 表示置信度, x 表示像素类别, 则 $P(x = wwlCL)$ 表示在已知置信的前提下, x 为冬小麦 WW (Winter Wheat) 的概率, 根据最大后验概率公式 (孟祥超 等, 2014; 陈俊杰和金小刚, 2015; 肖亮 等, 2007), 计算 $P(x = wwlCL)$ 的方法为

$$P(x = wwlCL) = \frac{P(CL|x)P(x)}{P(CL)} \quad (3)$$

式中, $P(CL|x)$ 表示冬小麦像素的置信度为 CL 的概率, $P(x)$ 表示像素为冬小麦的概率, $P(CL)$ 表示像素的置信度为 CL 的概率。 $P(CL|x)$ 、 $P(x)$ 和 $P(CL)$ 均通过统计方法获得, 以 m 表示正在处理的像素, 具体计算过程如下。

(1) 首先训练一个不带 MAP 层的 WWRSE 模型, 训练成功后, 使用 4 幅影像进行测试, 得到逐像素的分类结果;

(2) 将测试结果与人工标记进行逐像素比较, 像素统计分类结果信息 R , 包括: 像素类别、结果是否正确, 类别概率差值 3 个数据项;

(3) 以 m 为中心像素, 提取 $n \times n$ 大小的像素块, 这个像素块是卷积过程中, 提取像素 m 的特征时参与卷积运算的最大的像素块;

(4) 将 (3) 中提取的像素块中每个像素的 R 组成一个集合 RC 。对 RC 中像素类别为冬小麦的类别概率向量以置信度 CL 为标准进行分组, 获取每一组的向量数 N , 以 N 占冬小麦像素数的比例作为相应 CL 的 $P(CL|x)$; 以冬小麦像素数占整体像素数的比例作为 $P(x)$; 对 RC 以 CL 为标准进行分组, 获取每一组的向量数 N_a , 以 N_a 占整体像素数的比例作为相应 CL 的 $P(CL)$ 。

3.2 训练 WWRSE 模型

3.2.1 损失函数

训练 WWRSE 模型使用的损失函数基本计算单元仍使用交叉熵的定义, 交叉熵公式如式 (4) 所示 (范九伦和雷博, 2009)

$$H(p, q) = -\sum_{i=1}^2 q_i \log(p_i) \quad (4)$$

式中, $H(p, q)$, 为得到的交叉熵, p 为预测的概率分布, q 为真实的概率分布, i 为概率分布中的分

量序号，本文中，每个像素的预测类别为两类。

在此基础上，WWRSE模型使用的损失函数 $loss$ 定义为

$$loss = -\frac{1}{m} \sum_m \sum_{i=1}^2 q_i \log(p_i) \quad (5)$$

式中， m 为总样本数。

3.2.2 训练过程

为了增强模型的健壮性，我们选择了两个不同时期的遥感影像数据及其标记用于对模型进行训练。训练步骤如下：

(1) 将图像—标记文件组成的样本作为 WWRSE 的输入，并对网络参数进行初始化。

(2) 对样本中的图像执行一次前向传播计算。

(3) 计算一次损失函数，同时将计算结构使用反向传播算法传递给 WWRSE，使用随机梯度下降算法 SGD (Stochastic Gradient Descent) (Fu 等, 2017) 对 WWRSE 的参数进行一次更新。

(4) 不断重新上述步骤 (1) — (3)，直到损失函数小于预先确定的阈值。

在本文的训练过程中，使用了 SGD 算法对 WWRSE 的网络参数进行更新，更新方式为

$$W^{(n+1)} = W^{(n)} - k\Delta W^{(n+1)} \quad (6)$$

式中， $W(n)$ 表示旧的网络参数， $W(n+1)$ 表示新的网络参数， $\Delta W(n+1)$ 代表先后两次迭代运算的增量， k 表示两次冬小麦编码值的区间大小的比值，以反应权重更新对冬小麦编码的影响。 $\Delta W(n+1)$ 的计算公式为

$$\Delta W^{(n+1)} = \vartheta \left(d_w \cdot W^{(n)} + \frac{\partial J(W)}{\partial W^{(n)}} \right) + m \cdot \Delta W^{(n)} \quad (7)$$

式中， $J(W)$ 代表损失函数， ϑ 代表步长和学习速率， d_w 表示权值变化， m 表示系统动量。

3.3 使用训练好的模型进行提取

训练成功后，就可以使用 WWRSE 模型进行逐像素分类，按照我们的设计方案，分类结果将输出到一个新的波段文件中，这种方式可以避免原始数据遭到破坏。

3.4 对比实验方案

使用的实验环境为 Ubuntu 16.04，Ubuntu 是一个以桌面应用为主的开源 GNU/Linux 操作系统，支持 x86、amd64 (即 x64) 等多种架构，由 Canonical Ltd 发布。模型编码、训练和测试工作均以

TensorFlow 1.10 框架为基础，利用 Python 语言完成。

为了对本文提出的方法进行验证，选择了 SegNet、DeepLab 和 RefineNet 作为对比模型，使用的 SegNet 和 DeepLab 模型源码均来自于公开发表的文献。SegNet 和 DeepLab 是经典的图像语义分割模型，在图像处理方面取得了很好的效果，这两个模型的工作原理与 WWRSE 的工作原理基本相同，选择这两个模型作为比较模型，可以更好的体现 WWRSE 的优势。RefineNet 结构与 WWRSE 中使用的结构完全一致，进行这个对比实验是为了验证 MAP 的效果。此外，还分别将 SegNet 与 MAP 耦合 (命名为 SegNet-MAP)、DeepLab 与 MAP 耦合 (命名为 DeepLab-MAP)，与 WWRSE 进行对比。

SegNet、SegNet-MAP、DeepLab、DeepLab-MAP、RefineNet 等 5 个对比模型与 WWRSE 模型使用同一套训练样本和测试数据，并在实验完成后对结果进行对比和分析。本文没有修改 Segnet、Deeplab 和 Refinenet 模型原有的池化方式和激活函数，因此，6 个模型中，使用的池化均为最大池化方式，使用的激活函数均为 ReLU 函数 (Chen 等, 2018a; Lin 等, 2017)。

使用精度 (Accuracy)、准确率 (Precision)、查全率 (Recall) 和 $Kappa$ 系数作为评价方法的指标 (Zhang 等, 2018b)。

4 实验结果与分析

4.1 实验结果

在对比实验中，使用训练好的模型从 4 幅 GF-2 图像中提取冬小麦信息。这 4 幅图像仅用于测试，并没有参与训练。

对比实验使用的 SegNet 和 SegNet-MAP 使用了 8 个卷积层；DeepLab、DeepLab-MAP、RefineNet 和 WWRSE 均使用了具有 101 个卷积 Resnet 模块。SegNet-MAP 中 Map 模型使用的 $P(CL|x)$ 、 $P(x)$ 、 $P(CL)$ 为待处理像素为中心的 8×8 像素大小像素块的统计值，DeepLab-MAP 和 WWRSE 中 Map 模型使用的 $P(CL|x)$ 、 $P(x)$ 、 $P(CL)$ 为待处理像素为中心的 101×101 像素大小像素块的统计值，计算算法在 3.1.3 中进行了阐述。

使用图 4 给出了 WWRSE 在 4 幅测试图像上得到的整体测试结果。

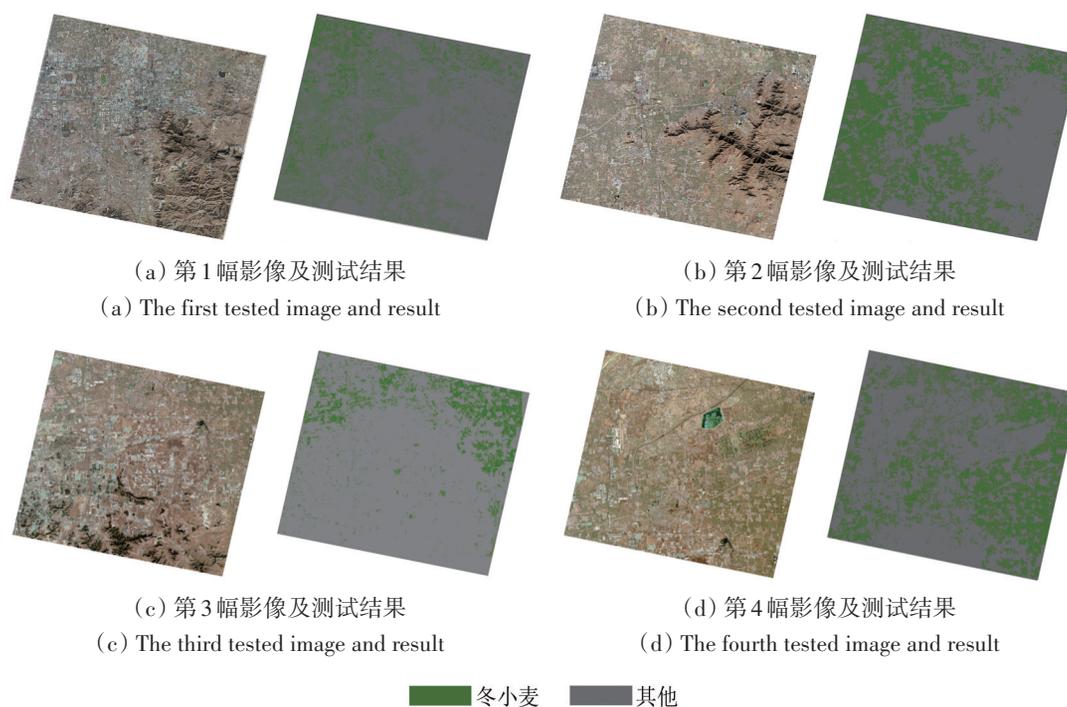


图4 WWRSE模型的测试结果

Fig. 4 Test results of the WWRSE model on four images

实验使用了二分类的方式，即冬小麦分为一类，其他地物均归为背景。在训练时，在使用总体精度作为训练的控制函数同时，对SGD算法进行了一些修改，使其在更新权重时考虑了冬小麦编码值的区间大小变化。

为了能够对SegNet、SegNet-MAP、DeepLab、DeepLab-MAP、RefineNet、WWRSE这6个模型的性能进行比较，选择了两个有代表性的小区域的实验结果进行对比，其中一个小区域以农田为主，另一个区域混杂有设施农业和建筑物，这两个区域能够代表实验区的土地利用结构，为了便于叙述，分别命名为实验1、实验2。在图5的每个子图中，第一列为实验1，第二列为实验2，图5(d)为segNet-MAP的提取结果，用红色标出了比图5(c)改进的区域；图5(f)为DeepLab-MAP的提取结果，用红色标出了比图5(e)改进的区域；图5(h)为WWRSE的提取结果，用红色标出了比图5(g)改进的区域。

表2给出了图5的混淆矩阵，混淆矩阵的每一列代表实际类别所占的比例，每一行代表预测类别所占的比例。从表2中可以看出，WWRSE模型获得了更好的分类性能，在上面的例子中，“冬小

麦”被错误地划分为“背景”的平均比例为0.0075。“背景”被错误地划分为“冬小麦”的平均比例为0.064，与对比模型相比有明显的提高。

表3给出了与图5对应的各个模型的评价结果。从实验结果看，6个模型的结果中，“背景”被错误地划分为“冬小麦”的平均比例均明显高于“冬小麦”被错误地划分为“背景”的平均比例，我们分析认为，这种现象应当与两个方面的原因有关，(1)在实验中对冬小麦的查全率要求较高，使得模型在训练SoftMAX-Ex分类器时，得到的回归参数有利于对冬小麦进行编码；(2)实验区域除了冬小麦外，还存在其他多种类型的地物，且部分区域内地物类别混杂情况较为严重。对SoftMAX-Ex分类器的模拟结果也有一定的影响。这种情况说明同类像素间的差异过大时，会降低分类器的性能，在这种情况下，可以将其分为若干小类进行提取。

分别将SegNet与SegNet-MAP、DeepLab与DeepLab-MAP、RefineNet与WWRSE作为一组对比，可以发现，加入MAP作为后处理后，“冬小麦”和“背景”的准确率均有不同程度的提高，这也证明了本文思想具有较强的适用性，可以应用于不同的卷积神经网络。

表2 与图5对应的混淆矩阵

Table 2 The confusion matrix corresponding to Fig.5

模型	实验编号	真实/预测	冬小麦	其他
SegNet	实验-1	冬小麦	0.790	0.148
		其他	0.030	0.032
	实验-2	冬小麦	0.560	0.180
		其他	0.060	0.200
SegNet-Map	实验-1	冬小麦	0.796	0.120
		其他	0.024	0.060
	实验-2	冬小麦	0.580	0.150
		其他	0.040	0.230
DeepLab	实验-1	冬小麦	0.730	0.070
		其他	0.090	0.110
	实验-2	冬小麦	0.550	0.130
		其他	0.070	0.250
DeepLab-Map	实验-1	冬小麦	0.780	0.060
		其他	0.040	0.120
	实验-2	冬小麦	0.611	0.100
		其他	0.009	0.280
RefineNet	实验-1	冬小麦	0.778	0.102
		其他	0.042	0.078
	实验-2	冬小麦	0.560	0.110
		其他	0.060	0.270
WWRSE	实验-1	冬小麦	0.812	0.068
		其他	0.008	0.112
	实验-2	冬小麦	0.613	0.060
		其他	0.007	0.320

4.2 结果分析

从第4.1节的实验结果可以看出，本文给出的方法能够显著提高冬小麦的提取精度。本节首先从遥感图像与自然图像的区别出发，讨论WWRSE模型结构的优势，然后分别与SegNet和DeepLab进行具体的对比分析。在4.1节中，已经结合实验结果，分析指出了同一类别像素间的差异是影响分类精度的一个重要因素，在本节中，将结合遥感影像上冬小麦的表现特点，进一步分析影响分类精度的其它因素。

4.2.1 WWRSE结构的优势

卷积神经网络在自然图像处理中已经取得了巨大的成功，启发了研究者将卷积神经网络应用于遥感图像逐像素分类。本文提出的WWRSE模型是在前人工作的基础上，进一步深入分析自然图像与遥感图像的本质区别的基础上取得的。与现

表3 与图5对应的的评价指标

Table 3 The Index corresponding to Fig. 5

方法	指标	实验-1	实验-2	平均	
SegNet	精度	Accuracy	0.822	0.760	0.791
	准确率	Precision	0.679	0.763	0.721
	查全率	Recall	0.571	0.715	0.643
	Kappa	Kappa	0.486	0.584	0.535
SegNet-MAP	精度	Accuracy	0.856	0.810	0.833
	准确率	Precision	0.792	0.823	0.807
	查全率	Recall	0.652	0.770	0.711
	Kappa	Kappa	0.572	0.656	0.614
DeepLab	精度	Accuracy	0.840	0.800	0.820
	准确率	Precision	0.731	0.795	0.763
	查全率	Recall	0.751	0.772	0.762
	Kappa	Kappa	0.581	0.645	0.613
DeepLab-Map	精度	Accuracy	0.900	0.891	0.896
	准确率	Precision	0.839	0.914	0.877
	查全率	Recall	0.809	0.861	0.835
	Kappa	Kappa	0.705	0.788	0.747
RefineNet	精度	Accuracy	0.856	0.830	0.843
	准确率	Precision	0.767	0.827	0.797
	查全率	Recall	0.691	0.807	0.749
	Kappa	Kappa	0.586	0.691	0.639
WWRSE	精度	Accuracy	0.924	0.933	0.929
	准确率	Precision	0.928	0.945	0.936
	查全率	Recall	0.806	0.915	0.861
	Kappa	Kappa	0.758	0.866	0.812

有研究相比，WWRSE模型最主要优势在于考虑到了类别概率向量的差值所代表的深层含义，首先确定差值大的，即置信度高的像素类别，而对于差值小的，即置信度低的像素，从冬小麦种植区域固有特点出发，引入了其他信息，提高了类别归属判断的可靠性。训练后的WWRSE的特征提取器具有较强的提取能力，保证了从属于同一类型但光谱信息差别相大的像素中提取出的特征向量间的距离尽可能相近，从光谱信息相近但归属于不同类别的像素中提取出的特征向量间尽可能远离，从而能够较好地适应高空间分辨率遥感影像的数据特征。

为了便于描述，图6—图8中，以冬小麦类别概率值减去背景类别概率值作为置信度。图6给出了RefineNet模型和WWRSE模型提取结果的分布情况，其中横坐标为置信度，纵坐标为某一置信度包含的像素数量。

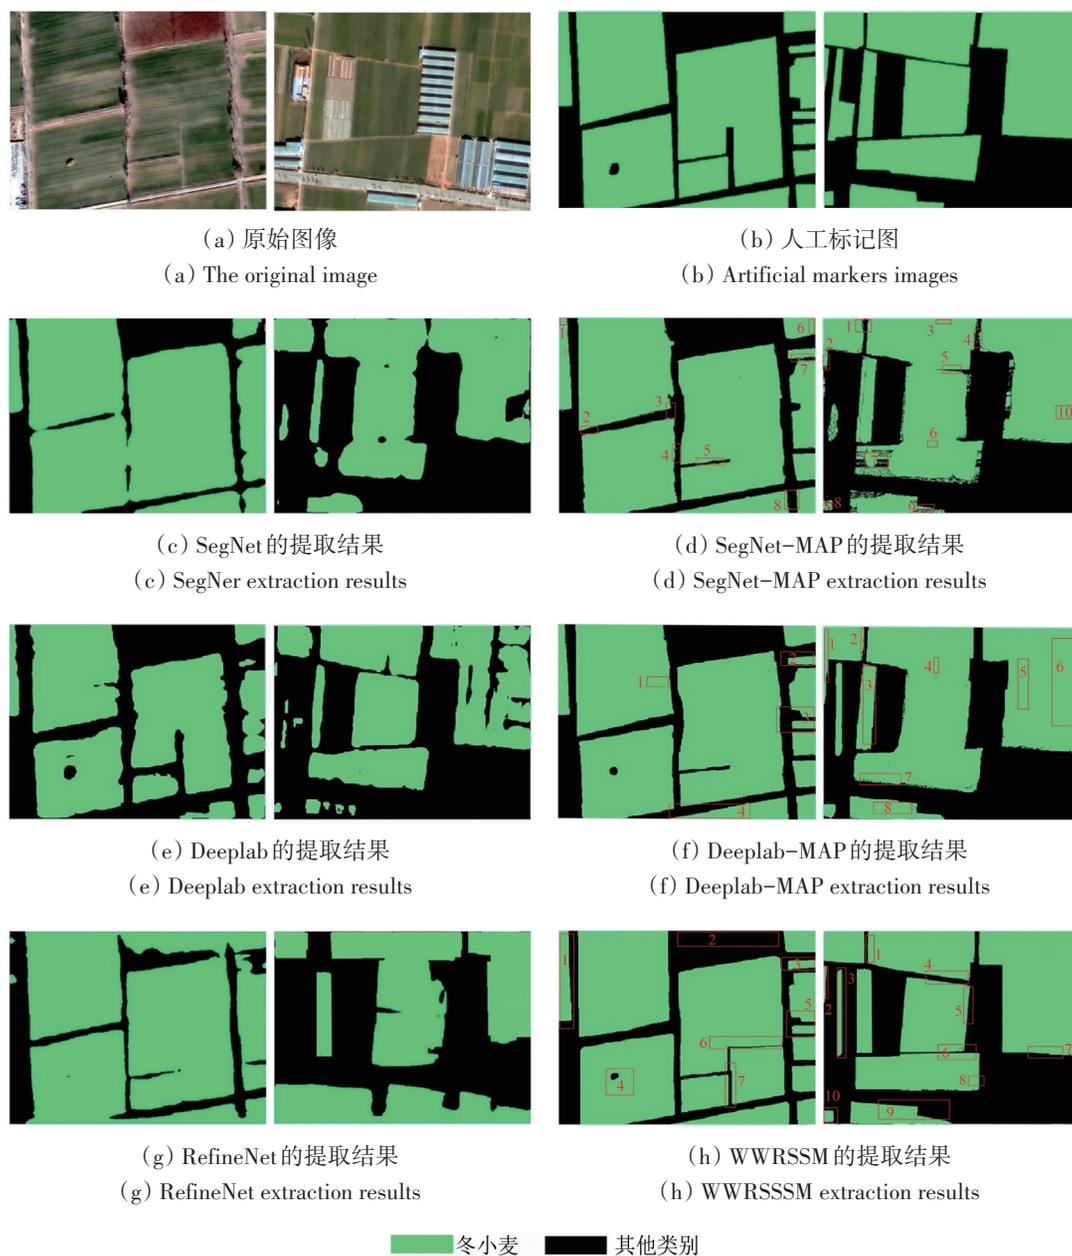


图5 GF-2影像分割结果

Fig. 5 Segmentation results for GF-2 images

从图中可以看出, WWRSE模型显著改善了置信度较低的像素的归类判断结果的可靠性;同时可以看出,分类错误的像素主要是集中在置信度较低的区域。

4.2.2 WWRSE与SegNet对比分析

SegNet模型也是在FCN模型的基础上发展起来的,但SegNet模型仅是利用了高层语义特征,而没有使用低层特征,这是SegNet模型与RefinetNet模型的最主要的区别。这种处理方式在

处理自然图像时,由于图像的细节多,信息量大,两个模型的差异并不是很明显,但在遥感图像上,由于图像的细节少,信息量小,在这种情况下,SegNet模型的劣势就显现出来了,从模型的评价结果表也可以看出这一问题。因此,模型能否充分利用各级特征,也是影响分割精度的一个重要原因。尽管如此,从图7仍然可以看出,加入MAP模型作为后处理后,整体结果仍然有较明显的改善。

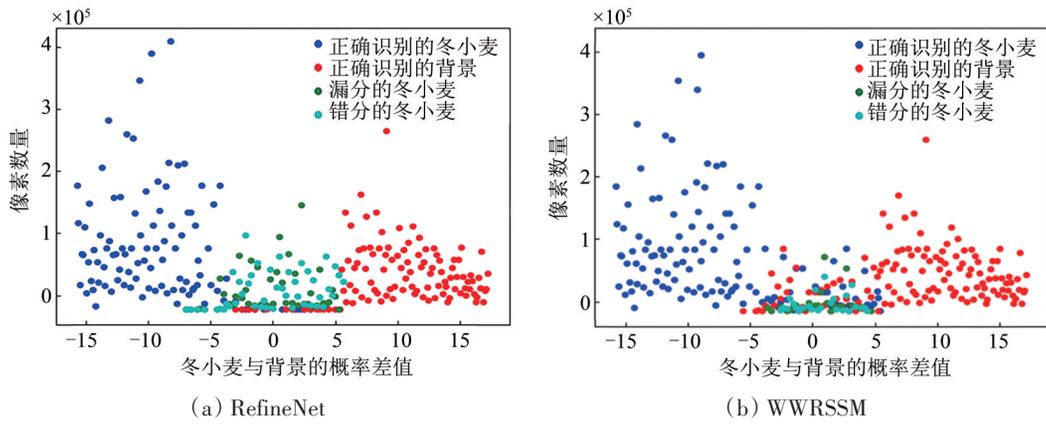


图6 Refine Net模型与WWRSE模型的对比

Fig.6 Compare Refine Net model with WWRSE model

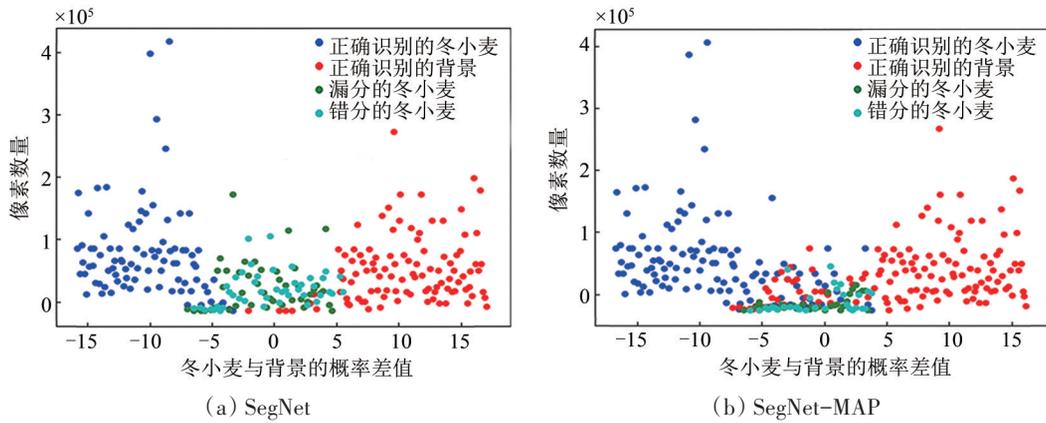


图7 SegNet模型及其与MAP耦合后的对比

Fig.7 SegNet model and its comparison with MAP coupling

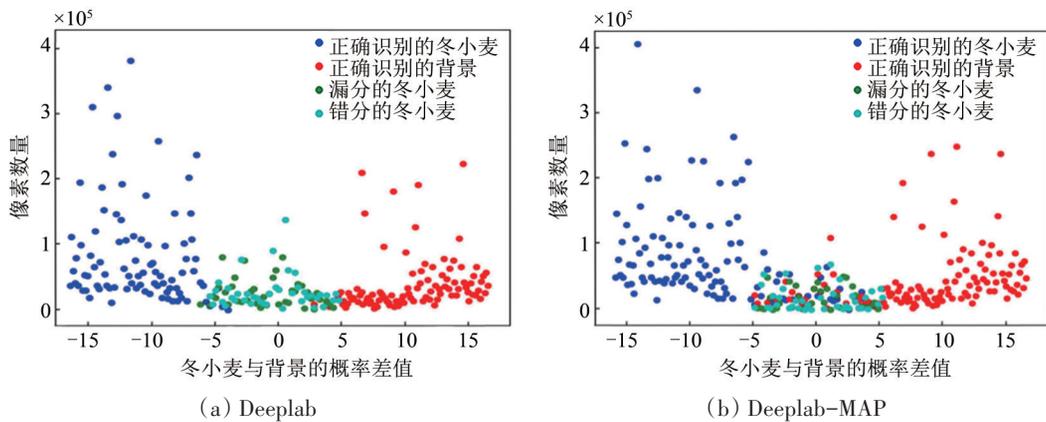


图8 Deeplab模型及其与MAP耦合后的对比

Fig. 8 Deeplab model and its comparison with MAP coupling

4.2.3 WWRSE与DeepLab对比分析

从公开文献来看, 识别建筑物等较大对象时, DeepLab在边界处优势比较明显, 这是因为DeepLab更好地利用了影像的细节信息和较大范围内的像素的空间相关性。但将DeepLab用于识别冬

小麦时, 由于冬小麦种植区域的像素块内细节变化不大, 可供利用的信息较少, 而且农田在大范围内的空间相关性并不强, 导致DeepLab的作用并没有充分发挥出来。

WWRSE不仅充分利用了像素自身的特征, 而

且充分利用了像素之间的统计特征,能够很好地适应冬小麦种植区域的数据特点。有效地避免了DeepLab方法的缺陷,保证分割精度。从4.1节的结果和对比可以看出,WWRSE在边缘区域的分割精度要比DeepLab方法好得多。

图8给出了DeepLab模型和DeepLab-Map模型提取结果的分布情况,可以看出,加入MAP模型作为后处理后,整体结果有较明显的改善。

5 结论

本文提出冬小麦遥感提取模型WWRSE,形成了较为完整的从GF-2遥感图像中获取高精度的冬小麦空间分布信息的方法。通过对RefineNet进行改进,建立了适应冬小麦检测的网络结构和特征向量编码方法;充分挖掘了类别概率向量所包含的信息,建立了适用于冬小麦检测的Map层,显著提高了低置信度像素的类别归属判断的准确性,明显提高了结果精度;通过将WWRSE的提取结果与SegNet、SegNet-MAP、DeepLab、DeepLab-MAP、RefineNet的结果进行对比,验证了WWRSE的提取能力。

我们的模型仍存在一些缺陷,主要有两个方面:(1)目前的分类器仍使用比较简单的回归算法对特征向量编码,需要探索一种能够有效表示特征值之间复杂关系的回归方式。(2)在对置信度低的像素进行判断时,没有利用同类中置信度高的像素的空间分布信息。我们将在下一步工作对模型进行改进,获得更好的提取结果。

参考文献(References)

Badrinarayanan V, Kendall A and Cipolla R. 2017. SegNet: a deep convolutional encoder-decoder architecture for imagesegmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12): 2481-2495 [DOI: 10.1109/TPAMI.2016.2644615]

Chen J, Chen T Q, Mei X M, Shao Q B and Deng M. 2014. Hilly farmland extraction from high resolution remote sensing imagery based on optimal scale selection. *Transactions of the Chinese Society of Agricultural Engineering*, 30(5): 99-107 (陈杰, 陈铁桥, 梅小明, 邵权斌, 邓敏. 2014. 基于最优尺度选择的高分辨率遥感影像丘陵农田提取. *农业工程学报*, 30(5): 99-107) [DOI: 10.3969/j.issn.1002-6819.2014.05.013]

Chen J J and Jin X G. 2015. Binary volume optimization based on maximum a posteriori-Markov random field. *Journal of Computer-Aided Design and Computer Graphics*, 27(7): 1203-1210 (陈俊杰, 金小刚. 2015. 基于最大后验概率-马尔科夫随机场的二进

制体数据优化. *计算机辅助设计与图形学学报*, 27(7): 1203-1210 [DOI: 10.3969/j.issn.1003-9775.2015.07.008]

Chen L C, Papandreou G, Kokkinos I, Murphy K and Yuille A L. 2018a. DeepLab: semantic image segmentation with deep convolutional nets, Atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4): 834-848 [DOI: 10.1109/TPAMI.2017.2699184]

Fan J L and Lei B. 2009. Two-dimensional cross-entropy linear-type threshold segmentation method for gray-level images. *Acta Electronica Sinica*, 37(3): 476-480 (范九伦, 雷博. 2009. 灰度图像的二维交叉熵直线型阈值分割法. *电子学报*, 37(3): 476-480) [DOI: 10.3321/j.issn:0372-2112.2009.03.009]

Feng M C, Yang W D, Zhang D Y, Cao L L, Wang H F and Wang Q. 2009. Monitoring planting area and growth situation of irrigation-land and dry-land winter wheat based on TM and MODIS data. *Transactions of the CSAE*, 25(3): 103-109 (冯美臣, 杨武德, 张东彦, 曹亮亮, 王慧芳, 王芊. 2009. 基于TM和MODIS数据的水旱地冬小麦面积提取和长势监测. *农业工程学报*, 25(3): 103-109)

Fu G, Liu C J, Zhou R, Sun T and Zhang Q J. 2017. Classification for high resolution remote sensing imagery using a fully convolutional network. *Remote Sensing*, 9(6): 498 [DOI: 10.3390/rs9050498]

Guo W Q, Ren J Q, Liu X R, Chen Z X, Wu S R and Pan H Z. 2018. Winter wheat mapping with globally optimized threshold under total quantity constraint of statistical data. *Journal of Remote Sensing*, 22(6): 1023-1041 (郭文茜, 任建强, 刘杏认, 陈仲新, 吴尚蓉, 潘海珠. 2018. 统计数据总量约束下全局优化阈值的冬小麦分布制图. *遥感学报*, 22(6): 1023-1041) [DOI: 10.11834/jrs.20187468]

Hao W P, Mei X R, Cai X L, Du J T and Liu Q. 2011. Crop planting extraction based on multi-temporal remote sensing data in Northeast China. *Transactions of the CSAE*, 27(1): 201-207 (郝卫平, 梅旭荣, 蔡学良, 杜建涛, 刘勤. 2011. 基于多时相遥感影像的东北三省作物分布信息提取. *农业工程学报*, 27(1): 201-207) [DOI: 10.3969/j.issn.1002-6819.2011.01.033]

He H, Zhu X F, Pan Y Z, Zhu W Q, Zhang J S and Jia B. 2008. Study on scale issues in measurement of winter wheat plant area by remote sensing. *Journal of Remote Sensing*, 12(1): 168-175 (何浩, 朱秀芳, 潘耀忠, 朱文泉, 张锦水, 贾斌. 2008. 尺度变化对冬小麦种植面积遥感测量区域精度影响的研究. *遥感学报*, 12(1): 168-175) [DOI: 10.3321/j.issn:1007-4619.2008.01.022]

Hu F, Xia G S, Hu J W and Zhang L P. 2015. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. *Remote Sensing*, 7(11): 14680-14707 [DOI: 10.3390/rs71114680]

Huang J X, Luo Q, Liu X X and Zhang J. 2016. Winter wheat yield forecasting based on time series of MODIS NDVI. *Transactions of the Chinese Society for Agricultural Machinery*, 47(2): 295-301 (黄健熙, 罗倩, 刘晓暄, 张洁. 2016. 基于时间序列MODIS NDVI的冬小麦产量预测方法. *农业机械学报*, 47(2): 295-301) [DOI: 10.6041/j.issn.1000-1298.2016.02.039]

Li D R, Zhang L P and Xia G S. 2014. Automatic analysis and mining of remote sensing big data. *Acta Geodactica et Cartographica Sini-*

- ca, 43(12): 1211-1216 (李德仁, 张良培, 夏桂松. 2014. 遥感大数据自动分析与数据挖掘. 测绘学报, 43(12): 1211-1216)[DOI: 10.13485/j.cnki.11-2089.2014.0187]
- Lin G S, Milan A, Shen C H and Reid I. 2016. RefineNet: multi-path refinement networks for high-resolution semantic segmentation. arXiv: 1611.06612
- Liu H N, Shi Z W and Zou Z X. 2017. Maritime semantic labeling of optical remote sensing images with multi-scale fully convolutional network. *Remote Sensing*, 9(5): 480 [DOI:10.3390/rs9050480]
- Liu C, Hong L, Chen J, Chu S S and Deng M. 2015. Fusion of pixel-based and multi-scale region-based features for the classification of high-resolution remote sensing image. *Journal of Remote Sensing*, 19(2): 228-239 (刘纯, 洪亮, 陈杰, 楚森森, 邓敏. 2015. 融合像素—多尺度区域特征的高分辨率遥感影像分类算法. 遥感学报, 19(2): 228-239)[DOI: 10.11834/jrs.20154035]
- Liu D W, Han L and Han X Y. 2016. High spatial resolution remote sensing image classification based on deep learning. *Acta Optica Sinica*, 36(4): 298-306 (刘大伟, 韩玲, 韩晓勇. 2016. 基于深度学习的高分辨率遥感影像分类研究. 光学学报, 36(4): 298-306) [DOI: 10.3788/AOS201636.0428001]
- Mas J F and Flores J J. 2008. The application of artificial neural networks to the analysis of remotely sensed data. *International Journal of Remote Sensing*, 29(3): 617-663 [DOI: 10.1080/01431160701352154]
- Meng X C, Shen H F, Zhang H Y, Zhang L P and Li H F. 2014. Maximum a posteriori fusion method based on gradient consistency constraint for multispectral/panchromatic remote sensing images. *Spectroscopy and Spectral Analysis*, 34(5):1332-1337 (孟祥超, 沈焕锋, 张洪艳, 张良培, 李慧芳. 2014. 基于梯度一致性约束的多光谱/全色影像最大后验融合方法. 光谱学与光谱分析, 34(5): 1332-1337) [DOI: 10.3964/j.issn.1000-0593(2014)05-1332-06]
- Mountrakis G, Im J and Ogole C. 2011. Support vector machines in remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3): 247-259[DOI: 10.1016/j.isprsjprs.2010.11.001]
- Pringle M J, Denham R J and Devadas R. 2012. Identification of cropping activity in central and southern Queensland, Australia, with the aid of MODIS MOD13Q1 imagery. *International Journal of Applied Earth Observation and Geoinformation*, 19: 276-285 [DOI: 10.1016/j.jag.2012.05.015]
- Qian X L, Li J, Cheng G, Yao X W, Zhao S N, Chen Y B and Jiang L Y. 2018. Evaluation of the effect of feature extraction strategy on the performance of high-resolution remote sensing image scene classification. *Journal of Remote Sensing*, 22(5): 758-776 (钱晓亮, 李佳, 程焱, 姚西文, 赵素娜, 陈宜滨, 姜利英. 2018. 特征提取策略对高分辨率遥感图像场景分类性能影响的评估. 遥感学报, 22(5): 758-776) [DOI: 10.11834/jrs.20188015]
- 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, Germany: 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]
- Sun Z R. 2015. Estimation of Winter Wheat Area and Drought Monitoring Research Based on Remote Sensing Data in Beijing-Tianjin-Hebei Region. Beijing: Beijing Forestry University(孙振蓉. 2015. 京津冀地区冬小麦面积估算和旱情遥感监测研究. 北京: 北京林业大学)
- Visin F, Romero A, Cho K, Matteucci M, Ciccone M, Kastner K, Bengio Y and Courville A. 2016. ReSeg: a recurrent neural network-based model for semantic segmentation//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops. Las Vegas: IEEE: 426-433[DOI: 10.1109/CVPRW.2016.60]
- Wang J, Song J W, Chen M Q and Yang Z. 2015. Road network extraction: a neural-dynamic framework based on deep learning and a finite state machine. *International Journal of Remote Sensing*, 36(12): 3144-3169 [DOI: 10.1080/01431161.2015.1054049]
- Wang L M, Liu J, Yao B M, Ji F H and Yang F G. 2018. Area change monitoring of winter wheat based on relationship analysis of GF-1 NDVI among different years. *Transactions of the Chinese Society of Agricultural Engineering*, 34(8): 184-191 (王利民, 刘佳, 姚保民, 季富华, 杨福刚. 2018. 基于GF-1影像NDVI年度间相关分析的冬小麦面积变化监测. 农业工程学报, 34(8): 184-191) [DOI: 10.11975/j.issn.1002-6819.2018.08.024]
- Wu C L, Chau K W and Fan C. 2010. Prediction of rainfall time series using modular artificial neural networks coupled with data-preprocessing techniques. *Journal of Hydrology*, 389(1/2): 146-167 [DOI: 10.1016/j.jhydrol.2010.05.040]
- Wu M Q, Yang L C, Yu B, Wang Y, Zhao X, Niu Z and Wang C Y. 2014. Mapping crops acreages based on remote sensing and sampling investigation by multivariate probability proportional to size. *Transactions of the Chinese Society of Agricultural Engineering*, 30(2): 146-152 (邬明权, 杨良闯, 于博, 王玉, 赵昕, 牛铮, 王长耀. 2014. 基于遥感与多变量概率抽样调查的作物种植面积测量. 农业工程学报, 30(2): 146-152) [DOI: 10.3969/j.issn.1002-6819.2014.02.019]
- Xiao L, Wei Z H and Wu H Z. 2007. A generalized variational image restoration model based on map and robust estimation. *Journal of Computer Research and Development*, 44(7): 1105-1113 (肖亮, 韦志辉, 吴慧中. 2007. 基于最大后验概率和鲁棒估计的图像恢复推广变分模型. 计算机研究与发展, 44(7): 1105-1113)
- Xu Q Y, Yang G J, Long H L, Wang C C, Li X C and Huang D C. 2014. Crop information identification based on MODIS NDVI time-series data. *Transactions of the Chinese Society of Agricultural Engineering*, 30(11): 134-144 (许青云, 杨贵军, 龙慧灵, 王崇倡, 李鑫川, 黄登成. 2014. 基于MODISNDVI多年时序数据的农作物种植识别. 农业工程学报, 30(11): 134-144) [DOI: 10.3969/j.issn.1002-6819.2014.11.017]
- You J, Pei Z Y, Wang F, Wu Q and Guo L. 2016. Area extraction of winter wheat at county scale based on modified multivariate texture and GF-1 satellite images. *Transactions of the Chinese Society of Agricultural Engineering*, 32(13): 131-139 (游炯, 裴志远,

- 王飞, 吴全, 郭琳. 2016. 基于改进多元纹理信息模型和 GF-1 影像的县域冬小麦面积提取. 农业工程学报, 32(13): 131-139 [DOI: [10.11975/j.issn.1002-6819.2016.13.019](https://doi.org/10.11975/j.issn.1002-6819.2016.13.019)]
- Zhang C M, Gao S, Yang X X, Li F, Yue M R, Han Y J, Zhao H, Zhang Y N and Fan K Q. 2018a. Convolutional neural network-based remote sensing images segmentation method for extracting winter wheat spatial distribution. Applied Sciences, 8(10): 1981 [DOI: [10.3390/app8101981](https://doi.org/10.3390/app8101981)]
- Zhang C M, Liu J P, Yu F, Wan S J, Han Y J, Wang J and Wang G. 2018b. Segmentation model based on convolutional neural networks for extracting vegetation from Gaofen-2 images. Journal of Applied Remote Sensing, 12(4): 042804 [DOI: [10.1117/1.JRS.12.042804](https://doi.org/10.1117/1.JRS.12.042804)]
- Zhang J H, Feng L L and Yao F M. 2014. Improved maize cultivated area estimation over a large scale combining MODIS - EVI time series data and crop phenological information. ISPRS Journal of Photogrammetry and Remote Sensing, 94: 102-113 [DOI: [10.1016/j.isprsjprs.2014.04.023](https://doi.org/10.1016/j.isprsjprs.2014.04.023)]
- Zhao L J and Tang P. 2016. Scalability analysis of typical remote sensing data classification methods: a case of remote sensing image scene. Journal of Remote Sensing, 20(2): 157-171 (赵理君, 唐婷. 2016. 典型遥感数据分类方法的适用性分析-以遥感图像场景分类为例. 遥感学报, 20(2): 157-171) [DOI: [10.11834/jrs.20164279](https://doi.org/10.11834/jrs.20164279)]

Extracting winter wheat spatial distribution information from GF-2 image

SONG Dejuan¹, ZHANG Chengming^{1,2}, YANG Xiaoxia¹, LI Feng³, HAN Yingjuan⁴, GAO Shuai⁵, DONG Haiyan¹

1. College of Information Science & Engineering, Shandong Agricultural University, Tai'an 271018, China;

2. Shandong Technology and Engineering Center for Digital Agriculture, Tai'an 271018, China;

3. Shandong Provincial Climate Center, Jinan 250031, China;

4. Key Laboratory for Meteorological Disaster Monitoring and Early Warning and Risk Management of Characteristic Agriculture in Arid Regions, CMA, Yinchuan 750002, China;

5. The Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China

Abstract: Winter wheat is one of the main food crops in China. The accurate spatial distribution information of winter wheat is crucial for yield estimation and food security. However, existing methods for extracting the spatial distribution information of winter wheat using a full convolutional neural network ignore the remote sensing imagery characteristics. The influence of differences among probabilities in the coded class probability vector on the judgment of pixel class attribution can lead to misclassification or missing points at the edge, which can affect the accuracy of the result. In this study, the RefineNet model is coupled with maximum a posteriori probability (MAP), and the WWRSE (Winter Wheat Remote Sensing Extraction) model is developed to create a method for extracting the spatial distribution information of winter wheat from a Gaofen-2 remote sensing image.

The WWRSE uses the convolution RefineNet network structure to extract pixel features. An improved SOFTMAX model is used to obtain the pixel category probability vector. With the winter wheat category probability value and other categories as a poor probability vector, differences can be divided into small pixels and differences among large pixels according to the category probability vector. For large differences among pixels, the biggest probability category can be used directly as the pixel category. Small differences among pixels can be combined with the MAP model to determine the type of each pixel. Next, the model is trained using the stochastic gradient method, and the spatial distribution information of winter wheat is extracted from the remote sensing image using the successfully trained model.

SegNet, DeepLab, and RefineNet were selected as comparison models. Experimental results showed that WWRSE accuracy improved by 4.2%, 7.6%, and 8.6%, compared with the comparison models. Moreover, overall extraction accuracy reached 93%, thereby indicating that the method proposed in this study has certain advantages in proposing the spatial information distribution of winter wheat.

This method deeply explores the information contained in the class probability vector of the output of the full convolutional network and determines that the classification error is closely related to the small component difference in the class probability vector. Based on this finding, the classification result of the full convolution network is revised. The effectiveness and feasibility of the proposed method are proven by the experiments.

Key words: GF-2, full convolutional neural networks, RefineNet, maximum a posteriori probability, winter wheat, spatial distribution, Zhangqiu

Supported by Natural Science Foundation of Shandong (No. ZR2017MD018); Key Research and Development Program of Ningxia (No. 2019BEH03008); National Key Research and Development Program of China (No. 2017YFA0603004); Open Research Project of the Key Laboratory for Meteorological Disaster Monitoring, Early Warning and Risk Management of Characteristic Agriculture in Arid Regions (No. CAMF-201701, CAMF-201803); Arid Meteorological Science Research Fund Project by the Key Open Laboratory of Arid Climate Change and Disaster Reduction of CMA (No. IAM201801)