

doi: 10.7621/cjarrp.1005-9121.20220727

• 技术方法 •

基于集成深度学习模型的耕地地块提取*

程锐, 魏妍冰, 陆苗[※], 吴文斌

(中国农业科学院农业资源与农业区划研究所, 北京 100081)

摘 要 [目的] 耕地地块空间分布是农业生产管理和农业政策制定的重要基础信息。我国农业耕作方式和种植结构复杂, 地块形状多样、均质性较低, 基于 Landsat 影像的传统方法难以实现地块的准确提取。[方法] 文章提出一种集成深度学习模型 (Ensemble Deep Learning, EDL), 可以在高分辨遥感影像中实现地块提取。首先通过随机可放回的 Bagging 抽样方法得到不同的训练集, 然后将训练集用于多个卷积神经网络 (FCN、PspNet、SegNet、Unet), 逐像素计算相应的耕地边界概率, 最后将概率图按照平均值进行集成, 获得耕地地块边界, 进而实现耕地地块的提取。[结果] 该文提出 EDL 方法提取耕地地块的总体精度达到 96%, 相较于 FCN、SegNet、Unet 提升了 1%, 相较于 PspNet 提升了 2%。相较于单个分类器, 集成深度学习模型可以减小偏差, 提高地块提取的准确率。[结论] 集成深度学习模型能够综合多个卷积神经网络的优点, 提高分类精度, 为耕地地块边界提取提供了新方法。

关键词 耕地地块 地块提取 卷积神经网络 Bagging 抽样 集成学习

中图分类号: S289; S281 **文献标识码**: A **文章编号**: 1005-9121[2022]07-0273-09

0 引言

耕地地块是农业经营管理的基本单元, 具有面积大小、空间分布、物理边界和几何形态等多维特征, 是衡量和表征耕地利用规模的重要指标, 为农作物监测、农业生产管理和农业政策制定提供了重要的基础信息^[1]。目前全世界已有多种耕地地块数据, 比如美国国家农业统计局 (National Agricultural Statistics Service) 基于监督分类的决策树方法使用 30 米分辨率的 Landsat 影像, 提供了 1997—2019 年覆盖全美的耕地地块数据 (Cropland Data Layer)^[2]。白俄罗斯的 OneSoil 公司基于机器学习算法使用 10m 分辨率的 Sentinel2 影像, 提供 2016—2020 年覆盖全欧洲与美国的耕地地块数据 One Soil Map (<https://onesoil.ai/en/>)。然而我国农业以小农经济为主体, 耕地细碎化显著, 约 95% 的农户耕地面积低于 2 hm², 户均经营规模 0.59 hm² (8.8 亩)^[3], 基于 Landsat 影像或 Sentinel 影像很难提取耕地地块。因此亟需探索基于高空间分辨率数据的耕地地块提取方法。

深度学习 (Deep Learning) 近年来发展迅速, 卷积神经网络 (Convolutional Neural Network, CNN) 作为一种应用广泛的深度学习模型, 能通过组合低层次特征形成更加抽象的高层次特征, 从而具有强大的特征提取能力^[4]。CNN 利用大数据来学习特征, 能够刻画数据丰富的内在信息^[4]。C. Persello 等利用 SegNet 网络、FCN (Fully Convolutional Networks) 网络分别获得耕地边界的概率结果图, 并将该图利用传统边缘方法 (分水岭分割、全局化边界概率算子等) 进行二次处理得到耕地地块^[5]。Sun 等利用 3 个具有层次性的神经网络分层次获得大地块、耕地地块与作物类别^[6]。这些研究仅应用单个 CNN 分类器提取地块, 而单

收稿日期: 2020-07-01

作者简介: 程锐 (1996—), 男, 四川资阳人, 硕士生。研究方向: 农业遥感

※通讯作者: 陆苗 (1984—), 女, 河南南阳人, 副研究员。研究方向: 农业遥感信息提取。Email: lumiao@caas.cn

* 资助项目: 国家自然科学基金项目“耕地规模化利用的多尺度智能遥感监测方法研究” (42071419); 中央级公益性科研院所基本科研业务费专项“地块尺度的耕地利用规模时空变化研究” (1610132020016); 科技基础资源调查专项“全球地表覆盖时空变化信息采集与知识建模” (2019FY202501)

个分类器各有优缺点，如表 1 所示。CNN 的网络结构丰富且各具特点，如何选择合适的网络结构是使用者首要解决的问题；同时，由于训练样本的局限性、网络参数设计等问题，CNN 易出现过拟合^[4]。

集成学习（Ensemble learning）将多个弱监督分类模型进行集成，结合各个模型的优势，得到一个强监督分类模型，其核心思想是如果某一个分类器得到了错误的预测，通过集成学习，其他分类器可以将错误纠正回来，减小偏差，提升预测效果^[7]。集成学习方法比单一分类器拥有更好的预测性能，常见集成模型有 Adaboost 模型、随机森林模型等^[8]。

表 1 单个 CNN 方法信息

类别	优点	缺点
FCN	端到端分割	损失细节信息易
SegNet	上采样与下采样位置一致;体量小	只存储最大值索引,易丢失部分信息
Unet	小样本环境下的准确率高	消耗内存大
PspNet	层次全局优先级;收敛速度快	上采样过程使用插值,易丢失位置信息

针对上述深度学习的网络选择和过拟合问题，文章将深度学习和集成学习相结合，基于 FCN、SegNet、PspNet 和 Unet 卷积神经网络，构建集成深度学习模型（Ensemble Deep Learning，EDL），进行耕地地块的提取。首先通过随机可放回的 Bagging 抽样方法在整体训练样本集中得到不同的训练样本子集，然后分别利用上述深度学习网络进行训练，预测耕地地块后验概率，最后根据预测后验概率的算术平均值获得提取结果，确定耕地地块。

1 研究区与数据概况

研究区位于黑龙江省富锦市前进镇（图 1a、b），富锦市是三江平原腹地的中心城市，2018 年该市的耕地总面积为 61.33 万 hm^2 （920 万亩），大部分耕地种植水稻，粮食总产达到 21 亿 kg，是国家重要的商品粮生产基地^[9]。选择的研究数据为 Maxar Technologies 公司免费提供的 WorldView 卫星影像，该影像的空间分辨率为 0.3m，共有 RGB 3 波段，成像时间为 2012 年 6 月 29 日（图 1c）。研究区的训练数据与验证数据都位于富锦市前进镇的创业农场，该地属于国营农场，耕地比较集中，以种植一年一熟的水稻为主。该文采用目视解译方法，选择深度学习所需要的训练和检验区域，其中 TR1、TR2 与 TR3 是各个 CNN 网络进行训练的区域，TS1、TS2 与 TS3 是各个 CNN 网络进行验证的区域（图 1c）。

2 研究方法

集成深度学习模型包括 3 个主要部分：Bagging 抽样、CNN 多模型训练和预测结果集成，如图 2 所示。实验使用了二分类的方式，即地块边界和非耕地边界。在训练时，使用 Bagging 筛选样本的方法随机获取数据，将总体精度作为训练的控制函数，使其各模型具有独立性，同时在更新权重时考虑了地块边界编码值的区间大小变化。该文首先建立整体样本集，在整体训练样本集中，通过 Bagging 随机可放回抽样得到相同数量的训练样本子集；然后使用不同的训练数据子集分别对 FCN、Unet、SegNet 和 PspNet 网络进行训练，得到各 CNN 的预测模型；最后基于 4 个预测模型得到地块边界的概率值，按取平均值的集成方式获得基于集成深度学习模型的耕地地块提取结果。

2.1 基于 Bagging 样本子集构建

首先，由于训练数据 TR1、TR2、TR3 像素数过大，超过了各个 CNN 模型所能加载的数量阈值，故将训练数据全部裁剪为 270 像素×270 像素×3 波段，一共获得 300 张的训练样本影像。因为卷积神经网络的训练需要大量训练样本，为提高分类准确率，防止模型过拟合，研究采用旋转、轴对称、添加噪声点等图像增强技术^[10]，扩大训练数据样本，共计获得了 2 000 张影像的样本数据库。




图1 研究区域

(a)富锦市空间位置图;(b)创业农场空间位置图;(c)研究区域WorldView影像(TR为训练区域,TS为验证区域)

然后,基于2 000张影像的训练样本集,利用Bagging随机可放回抽样方法得到1 000张影像的训练样本子集。Bagging方法,又叫袋装法,具有训练样本可放回抽样的特性,是一种在机器学习中常用的数据处理算法。假设从总体样本量 N 中有放回的随机选取 M 个样本作为子样本集,每个子样本集的 M 个样本是有放回随机选取的,因此每个样本不被选中的概率为:

$$P = \left(1 - \frac{1}{N}\right)^M \quad (1)$$

因此所有子样本集约包含原样本集总数的60.65%,其余39.35%的样本未被选中。在总体上,不同训练样本子集是相互独立的,样本子集的多样性保证了各个模型不会因为训练数据而产生偏倚^[10]。

Bagging在不稳定模型集合中表现较好,能在训练数据发生微小变化时产生不同泛化行为的模型,即增加了样本的多样性,又能有效解决CNN模型训练时的过拟合问题。

2.2 参与集成的CNN模型

集成深度学习使用4个不同的CNN模型,即FCN、SegNet、PspNet和Unet,分别提取耕地地块边界的概率值图,最后进行集成。经典的CNN通常在卷积层使用全连接层得到固定长度的特征向量进行分类,Long等在2015年提出的全卷积神经网络FCN(Fully Convolutional Networks)可以接受任意尺寸的输入图像,第一次实现了基于端到端的卷积神经网络的图像语义分割^[11]。FCN采用反卷积层对最后一个卷基层的特征图进行上采样,使它恢复到输入图像相同的尺寸,从而可以对每一个像素都产生一个预测,保留了原始输入图像中的空间信息。然而FCN的最大值池化层增大感受野的同时,使得图像损失了边缘位置信息^[11]。SegNet与FCN不同的地方是,SegNet采用的是vgg16全连接层前面的网络结构,并引入了更多的编码信息,使用的是池化索引(Pooling Indices),将下采样过程中池化的位置记录,在上采样中是使用该信息进行逆池化,使得每个filter都具有几个权重,可以得到在Pooling中相对Pooling filter的位置。这也使得SegNet具有更好的边缘检测的网络结构基础^[12]。PspNet网络(Pyramid Scene Parsing Network)则使用了两个Loss值来评价训练精度,上采样过程采用双线性内插算法,加快了训练数据的收敛速度,保留了更多

的非最大值池化的图像信息^[13]。Unet分为两个部分,前半部分作用是特征提取,后半部分是进行上采样。Unet采用了完全不同的特征集成方式:拼接,即Unet采用将特征在channel维度拼接在一起,形成更厚的特征。因此Unet具有多尺度识别的特点并且非常适合于小样本的训练,但易出现过拟合^[14]。

基于Bagging随机可放回抽样构建的训练样本子集,分别训练4个网络模型,得到相应的预测模型,然后进行地块概率预测。在训练CNN模型过程中,为控制实验变量,4个CNN训练参数设置为相同值,比如共同使用梯度下降法进行优化、交叉熵作为损失函数、相同的学习率与dropout等。




图2 集成深度学习模型流程

(a)Bagging抽样、(b) CNN多模型训练,和(c)预测结果集成

2.3 预测结果集成

基于4个CNN分类器的训练,得到其耕地边界相应的概率值(0~100%)。然后将4个CNN网络得到的概率值设置相同权重,并按式(2)方法获取平均值得到最后的概率结果,获得基于集成深度学习的预测影像,这部分流程如图2c。该实验数据经过集成深度学习模型,可以兼顾各个CNN模型的优势,大概率保证了即使某一个分类器出现错误,最后集成结果也是正确的,从而使得耕地地块更接近于真实的耕地空间分布情况。

$$P = \frac{\sum_{i=1}^n P_i}{n} \quad (2)$$

式(2)中, P 是指在集成深度学习模型中每个像素被分类为地块边界的概率, P_i 是指在第*i*个CNN模型中像素为边界的概率, n 为分类器的总数量。

2.4 精度评价

该文将得到的地块边界预测结果与验证区域的标签图进行对比, 计算用户精度 (UA, User's Accuracy)、生产者精度 (PA, Producer's Accuracy)、总体精度 (ACC, Overall Accuracy)、KAPPA 系数以及 P-R 曲线。用户精度是指从分类结果中任取一个随机样本, 其所具有的类型与地面实际类型相同的条件概率。生产者精度是指耕地边界类别的地面真实参考数据被正确分类的概率。

$$P_0 = \frac{\sum_{i=1}^n m_i}{M} \quad (3)$$

式 (3) 中, M 是所有样本的个数, m_i 为在第 i 类中被正确分类的个数, n 为总样本个数, P_0 为总体分类精度, 表示每一类正确分类的样本数量之和除以总样本数, 表示对每一个随机样本, 所分类的结果与检验数据类型相一致的概率。

$$Pe = \frac{\sum_{i=1}^n a_i \times b_i}{n \times n} \quad (4)$$

$$K = \frac{P_0 - Pe}{1 - Pe} \quad (5)$$

式 (4) (5) 为 KAPPA 系数的计算过程, a_i 分别是每一类的真实样本个数, b_i 分别是每一类的预测样本个数, n 代表地物类别数量, K 就是 KAPPA 系数, 值越高, 则分类效果越好。

P-R 曲线是显著性检测评价曲线, 以召回率 (Recall) 作为横坐标轴, 精确率 (Precision) 作为纵坐标轴, 这是在机器学习中常用的二分类问题精度评价方法。当分类算对样本进行分类时, 置信度表示该样本是某种类别的概率。通过置信度就可以对所有样本进行排序, 再逐个阈值地选择样本, 比阈值大的都属于耕地地块边界, 比阈值小的都属于非耕地地块边界, 形成不同阈值条件下的混淆矩阵。精确率 Precision 和召回率 Recall 从混淆矩阵中计算而来。精确率 Precision 能够体现地块边界分类正确的比例, 即分类为地块边界的样本, 分正确的概率的公式为:

$$\text{Precision} = \text{TP}/(\text{TP} + \text{FP}) \quad (6)$$

式 (6) 中, TP (True Positive) 为将地块边界预测为地块边界的数量, FP (False Positive) 将非地块边界预测为地块边界的数量。召回率 Recall 又称查全率为:

$$\text{Recall} = \text{TP}/(\text{TP} + \text{FN}) \quad (7)$$

式 (7) 中, FN (False Negative) 表示把非地块边界正确地分类为非地块边界的数量。通过设置不同的正类概率阈值, 就可得到一系列的 Precision 与 Recall 值, 从而形成显著性检测评价 P-R 曲线。

3 结果与分析

3.1 地块边界提取

使用训练好的 FCN、SegNet、PspNet、Unet 和 EDL 从测试影像中提取耕地地块边界概率图, 各个方法提取的结果如图 3 所示。4 个 CNN 网络都能有效提取耕地地块, 但是不同 CNN 具有各自的局限性。FCN 能满足提取地块边界的信息特征维度要求, 提取的地块边界清晰, 拼接痕迹不明显, 但碎斑在地块内分布较多, 预测效率也较低。SegNet 的地块边界较清晰, 但在预测过程中保留了多余的边缘信息, 导致拼接痕迹较明显、碎斑分布较多。PspNet 的地块边界清晰, 虽然碎斑较少, 但是碎斑的概率值较高, 拼接痕迹较明显, 预测效率也较低。Unet 的地块边界不明显, 碎斑的概率云图分布较少, 拼接痕迹较轻, 但由于自身的网络特性, 损失较多的耕地地块的边缘信息, 因此地块边界存在较多不连通的情况。EDL 则综合了各个 CNN 的优势, 能保证获取到合适、足量的特征信息, 在一定程度上可以纠正分类错误的类别、降低碎斑的概率值和淡化影像切片的边缘。因此 EDL 提取的地块边界清晰、碎斑的概率云图分布较少、拼接痕迹较淡, 总体来说 EDL 的提取效果最好。

使用 EDL 提取整个研究区的地块边界, 经过拓扑错误检查以及去除碎斑后, 使其与真实耕地数据进




图3 FCN、SegNet、PspNet、Unet和EDL在验证区域的提取结果

(a)第一行为验证区TS1各个方法的提取结果,(b)第二行为验证区TS2各个方法的提取结果,(c)第三行为验证区TS3各个方法的提取结果

行叠加分析,获得基于EDL的耕地地块数据,如图4所示。再将其与耕地数据面积验证,耕地重叠率为96.93%,如表3所示。

3.2 精度评价

将验证区的地块边界概率图转为二值图之后,各方法的精度评价如表4所示。从用户精度来看,FCN的用户精度最高,PspNet用户精度最低,也侧面反映了提取FCN非地块边界的能力最好。从生产者精度来看,PspNet用户精度最低,FCN、SegNet、Unet精度依次升高,EDL的生产者精度最高,这说明EDL提取地块边界的能力最好。从总体精度来看,EDL的效果最好,FCN、Unet、PsPNet的效果次之。从KAPPA系数来看,EDL的值最高,也说明了EDL的综合分类性能最好。需要注意的是PspNet的4个指标都较低,这可能是两个原因:(1)地块边界是一个二分类问题,PspNet采用了非最大值池化的方式,提取不出地块边界与地块的差异;(2)PspNet碎斑的概率云图概率值较大,这些碎斑易被归纳为地块边界。总的来说,EDL的精度存在显著提升,具有最高的生产者精度、总体精度以及KAPPA系数。精度评价结果表明集成深度学习EDL确实可以改善分类结果,提高耕地地块边界提取的准确率。

EDL预测结果位于P-R曲线的最右上角,同时其BEP为最大值。集成深度学习方法的提取效果最好,Unet与SegNet表现效果几乎一致,而FCN表现更次一等,PSP网络表现最差。

表3 耕地面积对比

EDL提取面积 (km ²)	耕地实际面积 (km ²)	耕地面积精度 (%)
31.97	32.99	96.93

表4 各方法的精度对比

方法	用户精度	生产者精度	总体精度	KAPPA系数
FCN	0.58	0.79	0.95	0.65
SegNet	0.57	0.81	0.95	0.65
PspNet	0.42	0.67	0.94	0.48
Unet	0.57	0.82	0.95	0.65
EDL	0.56	0.87	0.96	0.66




图4 EDL提取研究区耕地地块流程

4 讨论与结论

4.1 讨论

单个CNN网络各有特点,对于地块边界的分类具有偏向性。虽然从分类精度来看,各个CNN提取结果相似,但是在每个CNN模型中,对于同一地物其所得到的置信度是不同的。集成学习可以将多个CNN模型进行集成,使得集成结果兼顾各个CNN的结果特征,去除掉一部分被错分的地物。在4个CNN训练过程中,需要从同一训练库中选取样本,使用Bagging法可放回抽样的特性,保证各个训练样本子集相互独立。

该文使用集成深度学习的方法进行地块提取,从提取结果图5看,EDL的耕地边界清晰、碎斑较少。从分类精度来看,EDL的生产者精度为97%,总体精度为96%,kappa系数为0.66,均高于其余4个CNN网络。从P-R曲线看,EDL的平衡点均大于其余4个CNN网络,具有更好的提取性能。相较于单个CNN网络,利用集成深度学习在高分辨率影像中提取耕地地块,可以有效提高提取精度。

但是该文所使用的CNN为基于像素的分割网络模型,因此提取的地块边界结果存在碎片、边界不连续的情况,下一步工作将放在地块边界连通性上。此外,该文仅在东北的三江平原提取地块,但我国幅员辽阔,如何将该方法应用于我国其他地理条件不同的区域,值得进一步的探索。




图5 多方法的P-R曲线对比

4.2 结论

针对目前深度学习中存在的 CNN 网络选择困难以及过拟合问题, 该文提出基于集成深度学习模型的耕地地块提取方法, 该方法首先使用 Bagging 法实现样本随机抽样, 然后使用 4 个 CNN 网络进行训练, 得到各自的预测模型, 最后通过集成学习提取到耕地地块。结果表明了集成深度学习模型相较于单个 CNN 网络具有更高的提取精度, 实现了基于高分辨率遥感影像的地块提取, 这为我国地块提取研究提供了新的方法与思路。

参考文献

- [1] Wu Y, Xi X, Tang X, et al. Policy distortions, farm size, and the overuse of agricultural chemicals in China. *Proceedings of the National Academy of Sciences*, 2018, 115(27): 7010–7015.
- [2] Boryan C, Yang Z, Mueller R, et al. Monitoring US agriculture: the US department of agriculture, national agricultural statistics service, cropland data layer program. *Geocarto International*, 2011, 26(5): 341–358.
- [3] 张学彪. 中国小农户经营规模变迁与生产效率研究 [博士论文]. 北京: 中国农业科学院, 2018.
- [4] Zhu X X, Tuia D, Mou L, et al. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 2017, 5(4): 8–36.
- [5] Persello C, Tolpekin V A, Bergado J R, et al. Delineation of agricultural fields in smallholder farms from satellite images using fully convolutional networks and combinatorial grouping. *Remote Sensing of Environment*, 2019, 231: 111253.
- [6] Sun Y, Luo J, Xia L, et al. Geo-parcel-based crop classification in very-high-resolution images via hierarchical perception. *International Journal of Remote Sensing*, 2020, 41(4): 1603–1624.
- [7] Huynh T, Gao Y, Kang J, et al. Estimating CT image from MRI data using structured random forest and auto-context model. *IEEE Transactions on Medical Imaging*, 2015, 35(1): 174–183.
- [8] Chen Y, Wang Y, Gu Y, et al. Deep learning ensemble for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(6): 1882–1897.
- [9] 黑龙江统计局. 黑龙江统计年鉴. 北京: 中国统计出版社, 2018.
- [10] Breiman L. Bagging predictors. *Machine Learning*, 1996, 24(2): 123–140.
- [11] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation//*Proceedings of the IEEE conference on computer vision and pattern recognition*. IEEE, USA, 2015: 3431–3440.
- [12] Vijay S, Kendall A, Cipolla R. A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015 (39): 2481.
- [13] Zhao H, Shi J, Qi X, et al. Pyramid scene parsing network//*Proceedings of the IEEE conference on computer vision and pattern recognition*. IEEE, USA, 2017: 2881–2890.
- [14] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation//*International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015: 234–241.

CROPLAND FIELD EXTRACTION BASED ON ENSEMBLE DEEP LEARNING MODEL *

Cheng Rui, Wei Yanbing, Lu Miao^{*}, Wu Wenbin

(Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences, Beijing 100081, China)

Abstract The spatial distribution of cropland field is an important basic information for agricultural production management and agricultural policy making. The traditional methods based on landsat images are difficult to achieve accurate extraction of field parcels due to the high fragmentation of cropland and complex planting structures in China. In this study, an ensemble deep learning (EDL) model was proposed. Firstly, the various training sets were obtained by random Bagging sampling method, and then the training sets were applied to multiple

convolution neural networks (FCN、PspNet、SegNet、Unet) to obtain the cultivated land boundary probability map. Finally, the probability maps were integrated according to the average value to obtain the field parcels. The results showed the overall accuracy of EDL reached 96%, which was 1% higher than FCN, SegNet and Unet, and 2% higher than PspNet. Compared with a single classifier, EDL could reduce the deviation and improve the accuracy of cropland field extraction. It concludes that the EDL model integrates the advantages of multiple convolutional neural networks with better performance, and it can provide an effective method for field parcels boundary extraction in China.

Keywords cropland field; farmland extraction; convolution neural network; Bagging; Ensemble Deep Learning

·资讯·

5G网络时代下乡村振兴与农村就地现代化

5G技术重新定义了信息传输速度、网络通信响应速度及同时接入网络的设备数量,5G技术带来的信息化的颠覆式变革及为各个领域提供的更优质的平台所孕育的新事物、新机遇将是突破想象的。我国正值“十四五”关键期和全面推进乡村振兴蓄势待发之际,农业农村农民问题依然是关系国计民生的根本性问题,第五代移动通信技术赋能乡村建设,为实现农业农村现代化创造了信息科技基础条件,必将引领乡村振兴迈向更高层次、更深程度。

5G网络时代下智慧农业的发展推进了乡村振兴与农村就地现代化实现农业高质高效的重要目标。现代农业是乡村最为重要的产业支撑,智慧农业集多种新兴技术于一体,是农业发展的高级阶段。5G网络时代的到来不是单纯的速度提升,而是全新维度的飞跃与突破,能最大程度地解决大规模机器通信的数据传输不畅、信息获取耗时长、网络容量不足等问题。在解决了乡村地区信息闭塞问题后,提高农业生产效率、提升农作物产量和品质、提高农业机械化水平成为推动现代农业发展的主攻方向。5G作为基础设施可与多种技术结合构建融合服务,使得农业生产、农业管理场景摆脱带宽的桎梏,极大缩短各类采集农田信息的探头、传感器、探测器的数据获取和数据传输时间,上传到云端的海量农业大数据分析处理结果的精准度也将借助5G超高可靠、低时延通

信的特征得到进一步提升。除种植过程、种植技术更加精准化,农业管理更加智能化以外,5G网络时代还将推动机械代替人工和人力成本的极大缩减,即用更少的人实现更庞大的管理。可见,相应的生产力水平及相应的生产关系下,5G技术产生的巨大能动性即将推动农业生产全要素的升级换代,为农村就地现代化注入了强劲动力。如,近日中国移动携手四川省乐山市沐川县农业农村局共建5G+智慧农业物联网综合管理云平台,该平台运用5G、无人机、物联网、大数据、云计算等新技术为牛郎坪茶叶现代农业园区打造了统一监控、统一报警、统一调度多功能管理指挥监控中心,不仅能够24小时不间断地实时在线监测整个茶园,而且能够通过分析收集到的各类数据能为生产管理决策提供科学依据。可以说,围绕5G技术的信息化建设实现了对整个农业活动的跟踪、监测及自动化分析,这一合作为牛郎坪园区茶园实现智慧发展注入了新动能。

5G网络时代下农村电商的发展推进了乡村振兴与农村就地现代化实现农民富裕富足的重要目标。乡村振兴与农村就地现代化要充分激发农民致富内生动力,电商模式改变了传统农业产销渠道,5G网络时代下的“内容供应链+产品供应链”体系打破了束缚农产品运营的时空限制和“信息鸿沟”,为农产品上行带来了新的契机。借助短视频、

(下转第293页)