

引用格式: Qu Yang, Yuan Zhanliang, Zhao Wenzhi, *et al.* Crop Classification based on Multi-temporal Features and Convolutional Neural Network[J]. Remote Sensing Technology and Application, 2021, 36(2): 304-313. [屈炆, 袁占良, 赵文智, 等. 基于多时序特征和卷积神经网络的农作物分类[J]. 遥感技术与应用, 2021, 36(2): 304-313.]
doi:10.11873/j.issn.1004-0323.2021.2.0304

基于多时序特征和卷积神经网络的农作物分类

屈 炆^{1,2}, 袁占良¹, 赵文智², 陈学泓², 陈家阁³

(1. 河南理工大学测绘与国土信息工程学院, 河南 焦作 454003;

2. 北京师范大学地理科学学部, 北京 100875;

3. 国家基础地理信息中心, 北京 100830)

摘要:近年来,以卷积神经网络为主的深度学习模型在各种遥感应用中都显示出巨大的潜力。以加州帝国郡为研究区,以Landsat 8 OLI年内时序遥感影像计算时序植被指数NDVI、EVI、RVI以及TVI,组合后输入到构建的一维卷积神经网络模型,以实现作物的高精度精细分类。为了验证卷积模型的优越性,另搭建了基于递归神经网络及其变体的深度学习模型。结果表明:①引入其他时序特征后,能够有效地提高卷积神经网络的分类精度。NDVI+EVI+TVI+RVI组合特征总体精度和Kappa系数最高,分别是89.667 4%和0.856 0,对比NDVI时序特征总体精度和Kappa系数提高了近4%和0.6。②在与其他深度学习模型的对比中,一维卷积神经网络分类精度最高,能够从时序数据中较为准确捕捉作物时序特征信息,尽管递归神经网络被广泛应用于序列数据的研究,但分类结果要略差于卷积神经网络。实验表明在NDVI的基础上引入其他植被指数辅助,能够有效地提高分类精度。基于一维卷积神经网络的深度学习框架为长时间序列分类任务提供了一种有效且高效的方法。

关键词:农作物分类;一维卷积神经网络;时间序列;植被指数;Landsat 8 OLI

中图分类号: TP79 **文献标志码:** A **文章编号:** 1004-0323(2021)02-0304-10

1 引 言

农作物作为农业生产活动的主要载体,是土地利用中最重要的形式之一^[1]。随着高空间、高光谱和高时间分辨率遥感数据的出现,农业遥感技术在长时间序列作物长势动态监测、农作物种类细分、田间精细农业信息获取等关键技术方面得到了突破^[2]。遥感已经在国家经济建设,特别是重大灾害监测、评估以及宏观调控等方面,为国家和各级政府提供了大量的参考信息^[3],快速、准确地提取作物信息,对于制定农业政策、监测作物长势、产量估算、优化种植结构、解决生产问题等方面有着重要意义。同一区域,不同时相海量历史遥感数据的累积,使

得多时相遥感数据已经广泛应用于农作物特征、空间信息提取等方面的研究,但是如何充分挖掘和利用多时相遥感数据中隐含的作物光谱特征、纹理特征和空间特征等信息是当前遥感研究的热点之一^[4-8]。

在过去的几十年里,国内外学者相继提出各种各类基于多时相数据的农作物分类方法。马丽等^[9]基于多时相数据的光谱特征,有效地提取出了作物的空间信息。但是在构建较长时间序列时,使用全部光谱信息会导致数据计算复杂,且受到诸如大气效应或土壤背景反射率等混杂因素的影响,一定程度上影响了分类器的性能。为了解决这一问题,在一些研究提出使用植被指数(Vegetation Indices,

收稿日期:2019-10-25;修订日期:2020-12-31

基金项目:国家自然科学基金项目(41572341)。

作者简介:屈 炆(1995—),男,河南许昌人,硕士研究生,主要从事遥感信息识别与提取研究。E-mail:quyang95@126.com

通讯作者:赵文智(1990—),男,山东菏泽人,讲师,主要从事遥感信息识别与提取研究。E-mail:wenzhi.zhao@bnu.edu.cn

VI),能够最大程度地提高对植被变化的敏感性,同时将其其他混杂因素的影响降到最低^[10]。目前,已经提出了各种方法来处理和分析VI时间序列。郭昱杉等^[11]利用MODIS影像的NDVI时序特征,实现了农作物信息分类、识别,但是MODIS影像涵盖范围广,分辨率低,导致影像内会有大量混合像元,一定程度上限制了分类精度。李晓慧等^[12]使用了分辨率更高的Landsat 8 OLI影像作为数据源,根据不同时相作物NDVI的差异构建决策树,对于区分具有独特时空特征的作物类型有着不错的效果,但是可能忽略时间序列存在的序列关系。吴静等^[13]基于两种时序VI组合特征输入到随机森林中,得到了优于单一特征的分类精度,验证了多植被指数组合提高分类精度的可行性。苏腾飞等^[14]将更多的植被指数输入到传统分类方法中,实验结果表明更多的植被指数并不能有效的提高分类精度,可能是更多的特征反而导致数据维度过高,限制了分类精度。研究表明,卷积神经网络具有能够应对非线性、网络结构简单、可并行计算等能力^[15]。可解决传统分类方法处理在高光谱影像或高纬度数据分类时遇到难以计算的问题。

近些年,深度学习被认为是机器学习和数据挖掘领域具有突破性的技术^[16]。卷积神经网络(Convolutional Neural Networks, CNN)是深度学习方法中较为成熟的网络构架之一,相较于传统分类算法,卷积神经网络能够更好的提取出中高分辨时序影像隐含的特征信息,并对提取的信息进行更深层次学习^[17-18]。近些年,一些研究提出递归神经网络(Recurrent Neural Network, RNN)是专门管理多维时间序列的时间依赖性而设计的,可以从时间序列中准确捕捉到时间相关性^[19-21]。并且在这些研究中通常使用的是基于RNN框架拓展的长短期记忆网络(Long Short Term Memory, LSTM)模型来分析时间序列数据^[22]。基于此,为了探究卷积模型的性能,另构建了RNN模型,以及RNN的变体模型LSTM和GRU(Gated Recurrent Unit)来进行对比分析。

综上所述,以加州帝国郡为研究区,从两个方面开展研究,一是利用全年Landsat 8 OLI数据计算多种植被指数构建多特征时序数据集,从而保证数据源的综合性和全面性(即从不同角度、不同时间段充分反映农作物信息);二是采用基于多时序特征的卷积神经网络的方法进行研究,从而快速、高效

地深入挖掘多时序数据中隐藏的丰富信息(如物候特征、时序规律);最后,对结果进行基于混淆矩阵的精度评价,并与RNN、LSTM和GRU的分类结果进行对比。以探究卷积神经网络在农作物精细分类中所具有的优势和特点,同时也探索多时序特征对提高卷积神经网络分类精度的可行性。

2 研究区及数据

2.1 研究区

研究区位于加利福尼亚州帝国郡中部,位于33°05' N, 115°50' W(图1)。帝国郡位于科罗拉多沙漠低海拔地区,面积 $1.161 \times 10^4 \text{ km}^2$ (包括 $1.082 \times 10^4 \text{ km}^2$ 的陆地和 $7.9 \times 10^2 \text{ km}^2$ 的河流),其特点是农业生产力强,气候干燥炎热。研究区是热带沙漠气候,年内平均气温高于27℃,年温差非常大,夏季气温通常高于38℃,一般会在7月达到夏季的最高点,但从10月下旬到4月中旬,气温会相对的温和,其中冬季的最低点会在一月份,空气干燥,终年少雨,平均每年的降水量(75 mm)要远远低于美国平均每年降水量(700 mm)。

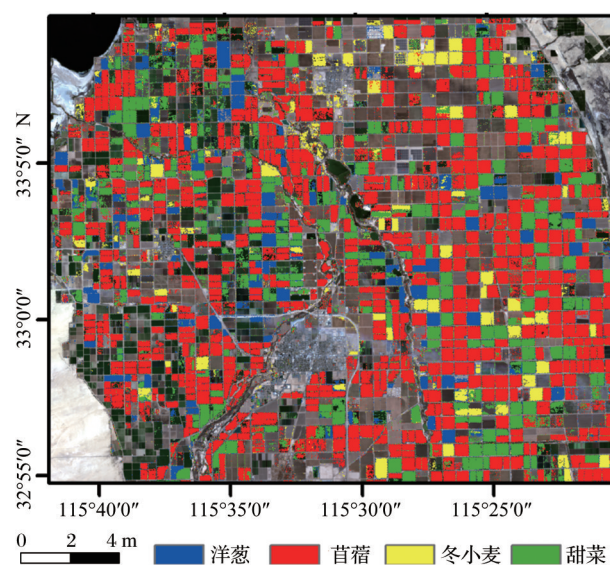


图1 研究区(2018年)

Fig.1 Study area

帝国郡因为作物漫长的生长周期、水资源贫乏和沙漠气候等原因,该地区的作物基本上是一年一季,不会在作物收获后再次种植其他作物,减少了其他作物特征的影响,使年内时序植被指数曲线能更准确展现出作物的物候特征。在加州,帝国郡是苜蓿和洋葱等作物产量最高的县之一。田间作物占帝国郡耕地面积的80%以上。该地区的作物呈

现出非常复杂的NDVI时序变化,冬小麦和洋葱具有类似的NDVI时序特征,3月达到NDVI最大值,其余时间的NDVI降低,由于苜蓿在该地区是全年定期生产和收获,故具有完全不规则的时序特征,甜菜在3月会达到NDVI的最大值,之后会持续降低,直到10月份后NDVI会又开始增加^[23]。

2.2 数据与预处理

Landsat 8 OLI遥感影像数据来自美国地质勘探局(United States Geological Survey, USGS)网站。Landsat 8 OLI能够提供30m分辨率数据以及16 d重返周期,在我国的资源与能源调查、灾害监测、大气观测、城市规划以及国家安全等方面发挥着重要作用^[24]。实现选取的是研究区从2018年1月5日至12月全年影像数据,剔除含云量过高的影像后,选出16景影像(表1)。验证数据和标签数据是美国农业部(United States Department of Agriculture, USDA)和国家农业统计局(National Agricultural Statistics Service, NASS)提供的2018年农田数据层^[25](Cropland Data Layer, CDL)。

由于获得的遥感数据会受到传感器、地形、太阳辐射等因素不同程度的影响,在进行分类前必须

表1 Landsat数据

Table 1 Landsat data

日期	含云量/%	日期	含云量/%
2018.01.05	0.13	2018.06.30	0.00
2018.02.06	0.10	2018.08.01	7.13
2018.02.22	11.12	2018.08.17	3.02
2018.03.26	6.88	2018.09.02	0.41
2018.04.11	5.64	2018.10.04	8.99
2018.04.27	0.00	2018.10.20	4.50
2018.05.13	0.64	2018.11.05	0.10
2018.05.29	5.21	2018.11.21	14.18

对下载的Landsat 8 OLI时序影像进行预处理,通过利用ENVI软件平台对时序影像进行了辐射定标、基于FLAASH模型^[26]的大气校正等预处理操作。其中部分影像内含有较多的水汽、云和云阴影,这些因素均会严重影响基于光学遥感影像所进行的研究,为了尽可能地消除影响,采用了FMASK算法^[27]对获取的Landsat-8 OLI时序影像进行了去云以及去除云阴影处理。

3 研究方法

实验的总体路线如图2所示。

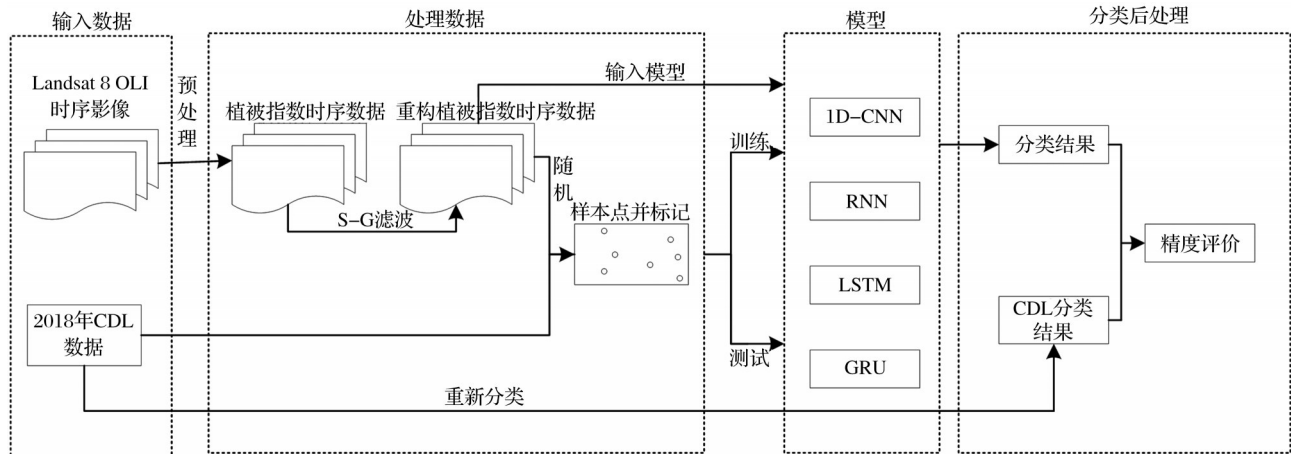


图2 技术流程图

Fig.2 Technique flow chart

首先,基于研究区全年Landsat 8 OLI时序影像进行预处理,然后计算得到4种植被指数,以NDVI为主,引入其他植被指数构建多时序特征组合的数据集,利用高斯滤波(Savitzky-Golay, S-G)对多时序特征数据集进行重构,同时处理2018年CDL数据,仅保留主要作物类别,并标记重构的时序影像数据;其次,从标记的数据集中按照不同类别随机抽出部分作为样本点。再以7:3的比例将抽出的样本点随机分为训练集和测试集,输入到卷积神经网络

中进行训练和测试;再次,将重构的时序影像输入训练后的一维卷积神经网络模型,依靠卷积神经网络对特征的深层次学习和影像准确地理解分析,从而实现主要作物的精细分类。最后,与RNN、LSTM和GRU的分类结果进行比较,并与CDL数据进行基于混淆矩阵的精度评价。

3.1 数据集

3.1.1 构建数据集

NDVI是广泛使用的一种植被指数,能够较好

地突显出农作物的物候特性,反映其长势或覆盖度等信息,所以选择NDVI作为基础分类特征。但是,当植被覆盖度达到一定程度时,NDVI达到峰值,对作物的敏感度降低,在覆盖度高的区域无法持续监测作物的长势,导致特征变化不明显^[28]。由于地形、水源、温度等条件的影响,部分作物的在生育期的曲线特征相似度较高,如冬小麦和洋葱等。这些作物的播种时间相同和NDVI时序变化规律相似,可能是由于NDVI易饱和的问题。此时仅依赖NDVI时序数据的变化特征,难以区分这些特征相似性高的作物。因此在实验中引入EVI、TVI和RVI 3种特征辅助NDVI识别作物信息(表2)。

表2 采用的植被指数及其计算公式
Table 2 Vegetation index and calculation formula

植被指数	计算公式
NDVI	$\frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}}$
EVI	$G \times \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + C_1 \rho_{red} - C_2 \rho_{blue} + L}$
TVI	$0.5 [120(\rho_{nir} - \rho_g) - 200(\rho_{red} - \rho_{green})]$
RVI	$\frac{\rho_{nir}}{\rho_{red}}$

注: ρ_{nir} 、 ρ_{red} 、 ρ_{blue} 、 ρ_{green} 表示近红外波段、红光波段、蓝光、绿光波段反射率, L 是土壤背景的调节系数,设置为1; C_1 和 C_2 是气溶胶系数,分别设置为6、7.5; G 为增益系数,设置为2.5

EVI是基于NDVI改进的植被指数,利用蓝光波段和土壤调节系数在一定程度上解决了NDVI高覆盖度时出现的敏感度降低的问题^[29];RVI与NDVI的特征相似,但对于冬小麦的变化特征较为敏感^[30];TVI应用于覆盖度较高的环境,对植被的敏感度随覆盖度增加而增加,弥补NDVI在高覆盖环境的敏感度低的缺陷^[31]。

TVI与RVI部分数值远大于1,与NDVI和EVI变化区间有较大的差异,直接使用会导致部分特征被掩盖,从而影响到农作物分类结果,这里使用的是min-max归一化方法,使TVI和RVI线性变化映射到(0,1)之间。

$$X = \frac{(X - X_{min})}{X_{max} - X_{min}} \quad (1)$$

其中: X_{max} 为植被指数时序数据的最大值, X_{min} 为植被指数时序数据的最小值。

3.1.2 重构数据集

在数据预处理过程中,对原始数据进行去云和云阴影操作,使得影像中云覆盖区域的像素值变为空值,且FMASK算法对于小块云、水汽和云阴影等

会出现错检漏检的情况,导致部分遥感数据仍会受到云的影响。由于云、云阴影的影响或某些时相的数据缺失,从而难以有效地进行时间序列的分析与应用,为了使时间序列数据尽可能在一个统一的标准上,同时也为保证时间序列数据的连续性、完整性。因此,需要对植被指数时序数据进行滤波重构,平滑时序数据中的断点以及异常点,获得相对符合作物实际生长物候特征的植被指数的时序变化曲线,参考边金虎等^[32]关于滤波处理植被指数的研究,选择了其中效果最好的S-G滤波重构植被指数时序数据集。

3.1.3 训练集与测试集

通过2018年的CDL,确定了主要作物苜蓿,冬小麦、甜菜和洋葱的空间分布信息,并选取了5个类别进行分析,包括苜蓿、冬小麦、甜菜、洋葱和其他,每个类别至少占研究区2%以上,其中其他类型内包含了除4种主要农作物外其余所有农业作物类型,具有极其复杂的地物特征,以测试分类模型对于复杂特征类型的信息识别能力。根据类别标签对数据集进行标记,然后随机抽出部分作为样本点。为了确保样本点具有一定的代表性,根据不同的标记分别提取出各类别的地块,在地块内随机抽出部分作为样本点。将抽出的样本以7:3分为两组完全独立的训练和验证样本。

3.2 基于一维卷积神经网络分类

在CNN结构的设计中,网络层数、卷积核的数量和尺寸以及激活函数等的选择都是较为重要。研究表明,在训练样本能够满足训练需求的情况下,增加网络深度和卷积核数,会使提取到的特征更加准确。但是一味的增加网络深度和卷积核,不仅会导致训练过程需要消耗更多时间,而且太多的网络结构会使模型过于复杂,会忽略掉底层提取的细节特征,导致无法精确识别地物轮廓。因此设计的模型的层数过多和过少均是不合适的,考虑于此本设计的分类模型共有11层,包括输入层、4个卷积层、4个最大池化层、一个全连接层、一个Dropout层以及一个Softmax分类层。以NDVI+EVI数据集为例,结构如图3所示。

图3中卷积为一维卷积,卷积层1、2、3、4分别含有8、16、32、64个尺寸为2和步长为1的卷积核、使用的激活函数均为ReLU,经过每个卷积层都会生成数量与卷积核个数相同的特征图。模型含有4个最大池化层,尺寸固定为2,对上一个卷积层的输出数据进行

下采样。Dropout是一种正则化的方法,可以随机将一些神经元丢弃,设置为0.5。全连接层经过Dropout

层后,输入 Softmax 层,最终输出 5 种类别的概率结果。5 组不同的特征组合的数据集均输入该模型。

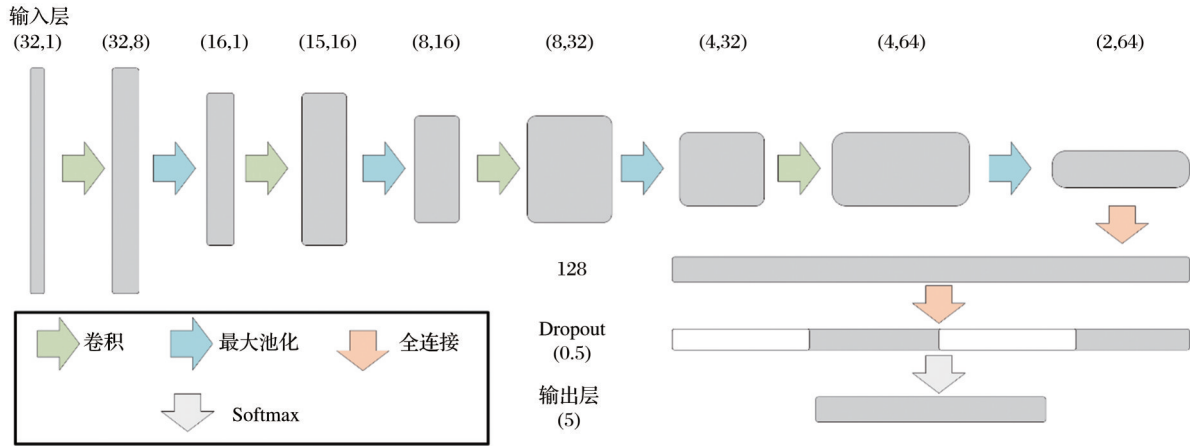


图3 一维卷积模型结构

Fig.3 1D-CNN model structure

3.3 RNN模型及其变体

RNN是专门用于时间序列分析的,可以保留上一时刻的信息,以保持序列相关性,从而提高从时间序列数据中学习和提取数据的能力。但是在研究中通常使用RNN的变体来提高学习效率和解决梯度消失问题,其中LSTM和GRU最为常用。在实验中分别构建了RNN、LSTM和GRU。与CNN相似,这3种模型的结构同样是非常重要的,设计的模型结构均包括2个网络层,隐藏层神经元个数为30,之后与全连接层、Dropout层相连,最后输入Softmax层,产生5种类别的分类结果。4种深度学习模型的均是使用的Adam优化器进行训练,参数固定为 $\beta_1=0.9$ 、 $\beta_2=0.999$ 、 $\epsilon=1E-0.8$ 和learn rate=0.001。

4 实验结果与分析

基于不同方法和特征组合的评价是基于混淆矩阵的分类精度评价,主要是从总体精度和Kappa系数、制图精度和用户精度对不同分类结果进行评价

4.1 不同时序特征的分类结果

在研究中,以NDVI为基础,引入其他植被指数,构建了5种时序特征组合的数据集,然后输入构建的卷积神经网络中实现农作物精细分类,分类结果如图4所示。不同植被指数时序数据组合的分类精度,如表3所示,单一时序特征卷积神经网络的总体精度和Kappa系数最低(分别是85.4807%和0.7986),并且制图精度和用户精度也是5种组合方

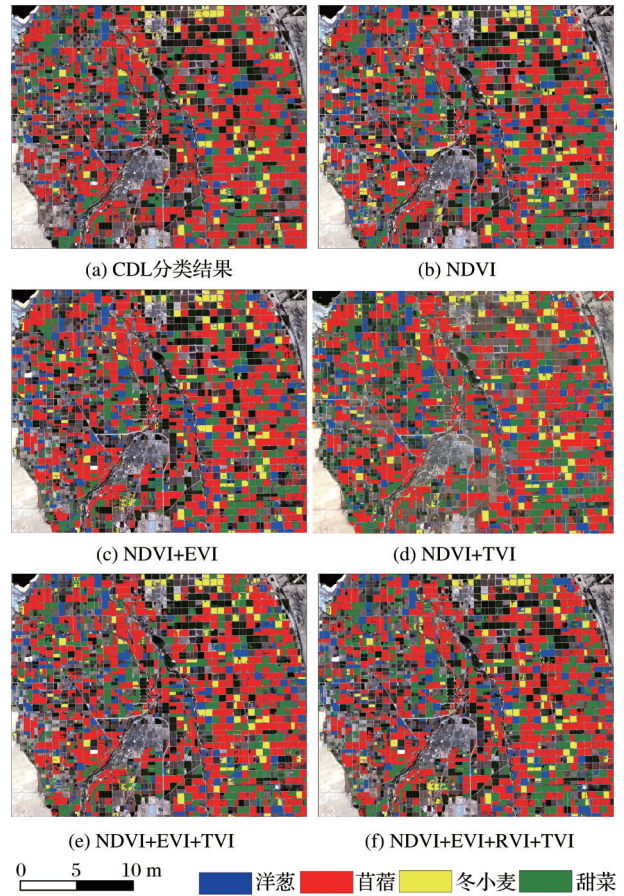


图4 不同特征组合分类结果

Fig.4 Classification results of different feature

案中相对较低的。可能是由于NDVI在植被覆盖度高时敏感地下降,无法对作物进行持续的监测,以及4种作物间NDVI时序变化相似性高,难以区分。引入EVI和TVI后,弥补了NDVI的不足,分类精

表 3 特征组合分类精度对比
Table 3 Classification accuracy of feature combinations

	类型	洋葱	苜蓿	冬小麦	甜菜	其他
NDVI特征卷积神经网络	洋葱	13 461	109	445	1 035	3 953
	苜蓿	0	30 399	0	611	1 061
	冬小麦	15	248	8997	877	1 135
	甜菜	132	2 195	3	24 441	5 444
	其他	183	3 449	230	2 169	59 855
	制图精度/%	97.61	83.51	92.99	83.89	83.77
	用户精度/%	70.83	94.79	79.82	75.87	90.85
	总体精度:85.480 7		Kappa系数:0.798 6			
NDVI+EVI特征卷积神经网络	洋葱	13 338	231	192	993	4 073
	苜蓿	0	31 112	27	847	909
	冬小麦	66	330	9 186	776	964
	甜菜	223	912	41	25 184	4 098
	其他	183	3 815	229	1 340	61 404
	制图精度/%	96.58	85.47	94.95	86.42	85.94
	用户精度/%	70.85	94.58	81.13	82.68	91.69
	总体精度/%:87.381 7		Kappa系数:0.824 5			
NDVI+TVI特征卷积神经网络	洋葱	13 597	639	351	436	2 895
	苜蓿	0	31 181	0	501	4 299
	冬小麦	11	413	9 200	541	1 328
	甜菜	33	638	13	26 445	4 100
	其他	169	3 534	111	1 190	58826
	制图精度/%	98.46	85.66	95.09	90.75	82.33
	用户精度/%	75.79	86.66	80.05	84.68	92.16
	总体精度/%:86.774 1		Kappa系数:0.817 0			
NDVI+EVI+TVI特征卷积神经网络	洋葱	13 653	602	341	444	2 585
	苜蓿	0	31 242	0	682	484
	冬小麦	1	259	9 238	512	2 156
	甜菜	21	1 214	7	26 136	4 406
	其他	135	3058	89	1 366	61 817
	制图精度/%	98.86	85.90	95.48	89.69	86.52
	用户精度/%	77.46	96.40	75.93	82.23	93.01
	总体精度/%:88.557 6		Kappa系数:0.841 0			
NDVI+EVI+TVI+RVI特征卷积神经网络	洋葱	13 662	241	326	656	3 344
	苜蓿	0	31 441	0	111	547
	冬小麦	0	455	9 302	409	989
	甜菜	3	600	1	26 804	3 885
	其他	145	3 663	46	1160	62 683
	制图精度/%	98.93	86.38	96.14	91.98	87.73
	用户精度/%	74.95	97.95	83.39	85.65	92.59
	总体精度/%:89.667 4		Kappa系数:0.856 0			

度有了一定的提高,其中EVI的贡献要略大于TVI。最多特征组合的总体精度和Kappa系数最高(分别是89.667 4%和0.856 0),引入RVI后,冬小麦识别能力得到了加强。从结果可以看出5种时序特征组合都会出现错分漏分的情况,但是引入其他时序特征后,情况有了一定程度的改善,证明多植

被指数的时序特征引入能够有效弥补NDVI的不足,提高卷积神经网络对于复杂特征的识别能力,一定程度上改善了农作物错分和漏分情况。

4.2 不同分类方法的结果对比

为了验证多时序特征卷积神经网络的优越性,使用相同的训练集和验证集(NDVI+EVI+TVI+

RVI组合特征)输入RNN、LSTM和GRU,分类精度如表4所示。

4种深度学习模型都表现出了不错的分类性能。分类结果对应各类农作物的用户精度均是苜蓿最高,洋葱最低。原因是该研究区内苜蓿种植面积广且密集,并且会在特定的时刻统一收割,在时序上有较为明显的变化,而洋葱种植分散,并且特征与其他作物相似,区分较为困难。CNN的分类精度最高,RNN在4种方法中总体精度和Kappa系数是最低的(分别是85.553 3%和0.797 7)。CNN在大多类别的制图精度、用户精度要稍高于其余3种

方法,在甜菜的识别中,LSTM、GRU的用户精度要略优于CNN。4种方法均有不同程度的错分、漏分现象,在洋葱的识别中,4种方法的用户精度都要远低于制图精度,漏分情况较为明显,但是CNN在剩余类别的分类中,情况会有所改善。4种方法的分类结果如图5所示。4种方法的分类结果整体上相似,但是在RNN的分类结果中,农田的边界保留最为破碎。而卷积神经网络对于地物轮廓的识别相较于其余3种方法更为准确,对农田边缘作物识别也相对完整,分类结果与作物真实的空间分布更加接近。

表 4 不同分类方法的分类精度
Table 4 Accuracy of different classification methods

	类型	洋葱	苜蓿	冬小麦	甜菜	其他
递归神经网络(RNN)	洋葱	12 975	931	375	608	3 860
	苜蓿	5	28 982	0	613	1 603
	冬小麦	341	149	8 127	876	924
	甜菜	159	1 998	199	25 044	2 899
	其他	330	4 340	974	1 999	62 162
	制图精度/%	93.95	79.62	84.00	85.94	87.00
	用户精度/%	69.20	92.88	78.02	82.66	89.05
	总体精度/%:85.553 3		Kappa系数:0.797 7			
长短期记忆网络(LSTM)	洋葱	13 206	927	111	696	3 570
	苜蓿	44	30 410	20	256	794
	冬小麦	115	308	9 266	845	1 502
	甜菜	267	933	28	24 669	2 440
	其他	178	3 822	250	2 674	63 142
	制图精度/%	95.63	83.54	95.77	84.66	88.37
	用户精度/%	71.35	96.47	76.99	87.06	90.12
	总体精度/%:87.673 9		Kappa系数:0.827 5			
GRU	洋葱	13 164	248	263	639	4 747
	苜蓿	2	30 337	0	552	1 008
	冬小麦	143	236	8 833	752	1 038
	甜菜	328	256	79	25 043	2 102
	其他	173	5 323	500	2 154	62 553
	制图精度/%	95.32	83.34	91.30	85.94	87.55
	用户精度/%	69.06	95.10	80.29	90.06	88.47
	总体精度/%:87.198 5		Kappa系数:0.820 4			

5 结论和讨论

5.1 结 论

利用研究区全年 landsat 8 OLI影像构建多特征数据集,通过多时序特征卷积神经网络方法,实现了研究区内主要作物的空间信息提取,并对比分析了另3种深度学习模型的农作物分类结果。

(1)引入EVI、TVI和RVI时序数据后,分类精

度要明显高于单一时序特征的分类精度。不同时序特征组合的分类实验表明,提出的想法取得了较好的效果,引入了EVI和RVI植被指数后,弥补了NDVI在高覆盖区域易饱和导致的特征相似问题,使农作物的特征更加明显,引入RVI对冬小麦识别有较大的贡献。一定程度上改善了错分漏分的情况,提高了分类精度。

(2)通过两种深度学习模型的分类结果,证明

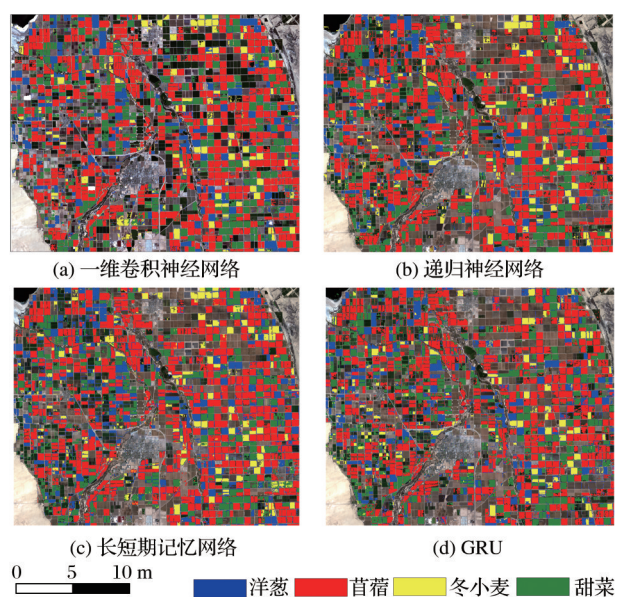


图5 不同分类方法的分类结果

Fig.5 Classification results of different classification methods

多时序特征卷积神经网络分类方法可以很好地识别出主要作物类别,并且对于农田轮廓和交界处混合农作物识别更好,边界保留较为完整,表现出了相较于RNN及其变体更优的分类性能。尽管RNN最初是为了时间序列相关的研究开发的,但它在实验中并未表现出更好的分类性能,可能是因为序列短或作物特征复杂。由此可见,卷积神经网络在农作物精细分类的研究中具有巨大潜力。

5.2 讨论

传统的分类方法在农作物分类方面已经取得了很好的效果,但是高维数据难处理、泛化能力不理想、现象明显等问题一直难以解决,卷积神经网络能一定程度改善这些现象,从实验中可以看出更多的植被指数特征能够提高卷积神经网络的分类精度,更能体现出农作物真实空间分布,但仍然会出现错分和漏分现象,有可能是研究区内种植作物的类别特征相似性高,不仅是NDVI易饱和导致的,仅使用植被特征难以区分,需要引入其他数据。在实验中,利用卷积神经网络高效处理高维度数据的特点,尝试加入多种植被指数以探索提高分类精度的可能。由于引入的植被指数较少,可能并不是最佳的特征组合。但仍能够证明加入其他时序特征对提高卷积神经网络分类精度有一定效果。虽然CNN在遥感领域中最早且应用最广的用途是在空间维度,但在与RNN模型的对比实验中,证明了CNN在时间序列特征提取方面也有较好的表现,在

时间序列分类任务的众多方法中,使用一维卷积模型也是一个不错的选择。实验只采用了影像时间维度上的变化特征,如果与其他更高分辨率影像结合,加入高分辨的纹理特征或加密时间序列,能进一步提高分类精度,会在之后的工作中探讨。

参考文献(References):

- [1] Liu Jiuyan, Shao Quanqin, Yan Xiaodong, *et al.* Geobiophysical Effects of Land Use Change on Climate Change[J]. Chinese Journal of Nature, 2014, 36(5): 356-363. [刘纪远, 邵全琴, 延晓冬, 等. 土地利用变化影响气候变化的生物地球物理机制[J]. 自然杂志, 2014, 36(5): 356-363.]
- [2] Shi Zhou, Liang Zongzheng, Yang Yuanyuan, *et al.* Status and Prospect of Agricultural Remote Sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(2): 247-260. [史舟, 梁宗正, 杨媛媛, 等. 农业遥感研究现状与展望[J]. 农业机械学报, 2015, 46(2): 247-260.]
- [3] Tian Guoliang. Present Situation, Problems and Suggestions of Remote Sensing Application in China[J]. Remote Sensing Information, 2003(2): 2-5. [田国良. 我国遥感应用现状、问题与建议[J]. 遥感信息, 2003(2): 2-5.]
- [4] Wang Wenjing, Zhang Xia, Zhao Yindi, *et al.* Cotton Extraction Method of Integrated Multi-features based on Multi-temporal Landsat 8 Images[J]. Journal of Remote Sensing, 2017, 21(1): 115-124. [王文静, 张霞, 赵银娣, 等. 综合多特征的Landsat 8时序遥感图像棉花分类方法[J]. 遥感学报, 2017, 21(1): 115-124.]
- [5] Zhang Rongqun, Wang Sheng'an, Gao Wanlin, *et al.* Remote Sensing Classification Method of County-level Agricultural Crops Using Time-series NDVI[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(S1): 246-252. [张荣群, 王盛安, 高万林, 等. 基于时序植被指数的县域作物遥感分类方法研究[J]. 农业机械学报, 2015, 46(增刊1): 246-252.]
- [6] Gu Xianghui, Zhang Ying, Sang Huiyong, *et al.* Research on Crop Classification Method based on Sentinel-2 Time Series Combined Vegetation Index[J]. Remote Sensing Technology and Application, 2020, 35(3): 702-711. [谷祥辉, 张英, 桑会勇, 等. 基于哨兵2时间序列组合植被指数的作物分类研究[J]. 遥感技术与应用, 2020, 35(3): 702-711.]
- [7] Xue Huazhu, Wang Changjing, Zhou Hongmin, *et al.* BP Neural Network based on Simulated Annealing Algorithm for High Resolution LAI Retrieval[J]. Remote Sensing Technology and Application, 2020, 35(5): 1057-1069. [薛华柱, 王昶景, 周红敏, 等. 基于模拟退火算法的BP神经网络模型估算高分辨率叶面积指数[J]. 遥感技术与应用, 2020, 35(5): 1057-1069.]
- [8] Wang Yingjie, Liu Liangyun, Wang Zhihui. Land Covermapping based on Landsat Time-series Stacks in Sanjiang Plain[J]. Remote Sensing Technology and Application, 2015, 30

- (5):959-968.[王颖洁,刘良云,王志慧.基于时序 Landsat 数据的三江平原植被地表类型变化遥感探测研究[J].遥感技术与应用,2015,30(5):959-968.]
- [9] Ma Li, Xu Xingang, Jia Jianhua, *et al.* Crop Classification Method Using Multi-temporal TM Images[J]. Transactions of the Chinese Society of Agricultural Engineering, 2008, 24 (S2):191-195.[马丽,徐新刚,贾建华,等.利用多时相 TM 影像进行作物分类方法[J].农业工程学报,2008,24(增刊 2):191-195.]
- [10] Liang S, Fang H. Leaf Area Index Models☆[J]. Encyclopedia of Ecology, 2008, 77(5):2139-2148.
- [11] Guo Yushan, Liu Qingsheng, Liu Gaohuan, *et al.* Extraction of Main Crops in Yellow River Delta based on MODIS NDVI Time Series[J] Journal of Natural Resources, 2017, 32(10): 1808-1818.[郭昱杉,刘庆生,刘高焕,等.基于 MODIS 时序 NDVI 主要农作物种植信息提取研究[J].自然资源学报, 2017,32(10):1808-1818.]
- [12] Li Xiaohui, Wang Hong, Li Xiaobing, *et al.* Study on Crops Remote Sensing Classification based on Multi-temporal Landsat 8 OLI Images[J], Remote Sensing Technology and Application, 2019,34(2):389-397.[李晓慧,王宏,李晓兵,等.基于多时相 Landsat 8 OLI 影像的农作物遥感分类研究[J].遥感技术与应用,2019,34(2):389-397.]
- [13] Wu Jing, Lü Yu'na, Li Chunbin, *et al.* Fine Classification of County Crops based on Multi-temporal Images of Sentinel-2A [J], Transactions of the Chinese Society for Agricultural Machinery, 2019,50(9):194-200.[吴静,吕玉娜,李纯斌,李全红.基于多时相 Sentinel-2A 的县域农作物分类[J].农业机械学报,2019,50(9):194-200.]
- [14] Su Tengfei, Liu Quanming, Su Xiuchuan, Crop Remote Sensing Classification based on Multi Vegetation Index Time Series and Machine Learning[J], Jiangsu Agricultural Sciences, 2017,45(16):219-224.[苏腾飞,刘全明,苏秀川.基于多种植被指数时间序列与机器学习的作物遥感分类研究[J].江苏农业科学,2017,45(16):219-224.]
- [15] Zhao W, Du S. Spectral-spatial Feature Extraction for Hyperspectral Image Classification: A Dimension Reduction and Deep Learning Approach[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(8):4544-4554.
- [16] Li Yandong, Hao Zongbo, Lei Hang. Survey of Convolutional Neural Network [J]. Journal of Computer Applications, 2016,36(9):2508-2515,2565.[李彦冬,郝宗波,雷航.卷积神经网络研究综述[J].计算机应用,2016,36(9):2508-2515,2565.]
- [17] Dong Yunya, Zhang Qian. A Survey of Depth Semantic Feature Extraction of High-Resolution Remote Sensing Images based on CNN[J]. Remote Sensing Technology and Application, 2019,34(1):1-11.[董蕴雅,张倩.基于 CNN 的高分遥感影像深度语义特征提取研究综述[J].遥感技术与应用, 2019,34(1):1-11.]
- [18] Zhou Zhuang, Li Shengyang, Zhang Kang, *et al.* Crop Mapping Using Remotely Sensed Spectral and Context Features based on CNN[J] Remote Sensing Technology and Application, 2019,34(4):694-703.[周壮,李盛阳,张康,等.基于 CNN 和农作物光谱纹理特征进行作物分布制图[J].遥感技术与应用,2019,34(4):694-703.]
- [19] Ienco D, Gaetano R, Dupaquier C, *et al.* Land Cover Classification via Multitemporal Spatial Data by Deep Recurrent Neural Networks[J]. IEEE Geoscience and Remote Sensing Letters, 2017;14(10):1685-1689.
- [20] Ndikumana E, Ho Tong Minh D, Baghdadi N, *et al.* Deep Recurrent Neural Network for Agricultural Classification Using Multitemporal SAR Sentinel-1 for Camargue, France[J]. Remote Sensing, 2018, 10 (8): 1217. <https://doi.org/10.3390/rs10081217>.
- [21] Interdonato R, Ienco D, Gaetano R, *et al.* DuPLO: A DUAL View Point Deep Learning Architecture for Time Series Classification[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 149:91-104.
- [22] Xie Yi, Zhang Yongqing, Xun Lan, *et al.* Crop Classification based on Multi-source Remote Sensing Data Fusion and LSTM Algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(15): 129-137.[解毅,张永清,荀兰,等.基于多源遥感数据融合和 LSTM 算法的作物分类研究[J].农业工程学报,2019,35(15):129-137.]
- [23] Belgiu M, Csillik O. Sentinel-2 Cropland Mapping Using Pixel-based and Object-based Time-weighted Dynamic Time Warping Analysis[J]. Remote Sensing of Environment, 2018, 204:509-520.
- [24] Chu Qingwei, Zhang Hongqun, Wu Yewei, *et al.* Application Research of Landsat-8[J]. Remote Sensing Information, 2013,28(4):110-114.[初庆伟,张洪群,吴业伟,等.Landsat 8 卫星数据应用探讨[J].遥感信息,2013,28(4):110-114.]
- [25] Boryan C, Yang Z, Mueller R, *et al.* Monitoring US Agriculture: the US Department of Agriculture[J]. National Agricultural Statistics Service, Cropland Data Layer Program. Geocarto Int, 2011, 26: 341-358.
- [26] Hao Jianting, Yang Wunian, Li Yuxia, *et al.* Atmospheric Correction of Multi-spectral Imagery ASTER [J]. Remote Sensing Information, 2008(1):78-81.[郝建亭,杨武年,李玉霞,等.基于 FLAASH 的多光谱影像大气校正应用研究[J].遥感信息,2008(1):78-81.]
- [27] Yan L, Roy D P. Automated Crop Field Extraction from Multi-temporal Web Enabled Landsat Data[J]. Remote Sensing of Environment, 2014,144:42-64.
- [28] Rouse J, Haas R, Schell J, *et al.* Monitoring Vegetation Systems in the Great Plains with ERTS[R]. Third ERTS Symposium, NASA (1973): 309-317.
- [29] Wang Zhengxing, Liu Chuang, Chen Wenbo. Preliminary Comparison of MODIS-NDVI and MODIS-EVI in Eastern Asia [J]. Geomatics and Information Science of Wuhan University, 2006(5):407-410,427.[王正兴,刘闯,陈文波,等.MODIS 增强型植被指数 EVI 与 NDVI 初步比较[J].武汉大学学报(信息科学版),2006(5):407-410,427.]

- [30] Chen Xueyang, Meng Jihua, Du Xin, *et al.* The Monitoring of the Winter Wheat Leaf Area Index based on HJ-1 CCD Data[J]. Remote Sensing for Land & Resources, 2010(2):55-58,62.[陈雪洋,蒙继华,杜鑫,等.基于环境星 CCD 数据的冬小麦叶面积指数遥感监测模型研究[J].国土资源遥感,2010(2):55-58,62.]
- [31] Broge N H, Leblanc E. Comparing Prediction Power and Stability of Broadband and Hyperspectral Vegetation Indices for Estimation of Green Leaf Area Index and Canopy Chlorophyll Density[J]. Remote Sensing of Environment, 2001, 76(2):156-172.
- [32] Bian Jinhu, Li Ai'nong, Song Mengqiang, *et al.* Reconstruction of NDVI Time-series Datasets of MODIS based on Savitzky-Golay Filter[J]. Journal of Remote Sensing, 2010, 14(4):725-741.[边金虎,李爱农,宋孟强,等.MODIS 植被指数时间序列 Savitzky-Golay 滤波算法重构[J].遥感学报,2010,14(4):725-741.]

Crop Classification based on Multi-temporal Features and Convolutional Neural Network

Qu Yang^{1,2}, Yuan Zhanliang¹, Zhao Wenzhi², Chen Xuehong², Chen Jiage³

(1.School of Surveying and Land Information Engineering, Henan Polytechnic University,

Jiaozuo 454003, China;

2.Faculty of Geographical Science, Beijing Normal University, Beijing 100875, China;

3.National Geomatics Center of China, Beijing 100830, China)

Abstract: Recently, Convolutional Neural Network (CNN) shows great potential in various remote sensing applications. Taking Imperial County of California as the study area, and calculating vegetation index NDVI, EVI, RVI and TVI from Landsat-8 OLI time series remote sensing images. Then, input it into the constructed CNN model to achieve crop classification. In order to verify the superiority of the convolution model, a deep learning model based on recurrent neural networks and its variants was built. The results show that: ① Adding other time series features can effectively improve the classification accuracy of CNN. The overall accuracy and Kappa coefficient of NDVI+EVI+TVI+RVI combination features are best, respectively 89.6674% and 0.8560, which is nearly 4% and 0.6 higher than the single time series features. ② Convolutional neural networks have the highest classification accuracy in comparison with other deep learning models. It can capture crop timing feature information more accurately from time series data. Although RNN is widely used for sequential data representation, but the classification results are slightly worse than the convolutional neural network. Experiments show that the introduction of other vegetation index assistance on the basis of NDVI can effectively improve the classification accuracy. A deep learning framework based on 1D convolutional neural networks provides an effective and efficient method for Multi-Temporal classification tasks.

Key words: Crop classification; CNN; Time series; Vegetation index; Landsat 8 OLI