

doi:10.6041/j.issn.1000-1298.2019.04.021

基于无人机遥感与卷积神经网络的草原物种分类方法

杨红艳^{1,2} 杜健民¹ 王圆¹ 张燕斌¹ 张锡鹏¹ 康拥朝¹

(1. 内蒙古农业大学机电工程学院, 呼和浩特 010018; 2. 内蒙古工业大学机械工程学院, 呼和浩特 010051)

摘要: 基于无人机高光谱成像遥感系统, 在 400 ~ 1 000 nm 波段内采集低矮、混杂生长的荒漠草原退化指示物种的高光谱图像信息。分别在退化指示物种的开花期、结实期和黄枯期进行飞行实验, 飞行高度 30 m, 高光谱图像地面分辨率 2.3 cm。采用特征波段提取与深度学习卷积神经网络相结合的方式, 提出一种荒漠草原物种水平分类的方法, 结合植物物候给出了中国内蒙古中部荒漠草原物种分类的推荐时相, 总体分类精度和 Kappa 系数平均值分别达到 94% 和 0.91。研究表明, 无人机高光谱成像遥感技术及深度卷积神经网络可以较好地实现荒漠草原退化指示物种的分类, 与基于径向基核函数的支持向量机、基于主成分分析的深度卷积神经网络分类法相比, 基于特征波段选择的深度卷积神经网络分类法效果最好, 分类精度最高。无人机搭载高光谱成像仪低空遥感和卷积神经网络法提供了一种草原物种水平分类的途径。

关键词: 荒漠草原; 指示物种; 分类; 高光谱遥感; 无人机; 卷积神经网络

中图分类号: TP79 **文献标识码:** A **文章编号:** 1000-1298(2019)04-0188-08

Classification Method of Grassland Species Based on Unmanned Aerial Vehicle Remote Sensing and Convolutional Neural Network

YANG Hongyan^{1,2} DU Jianmin¹ WANG Yuan¹ ZHANG Yanbin¹ ZHANG Xipeng¹ KANG Yongchao¹

(1. College of Mechanical and Electrical Engineering, Inner Mongolia Agricultural University, Huhhot 010018, China

2. College of Mechanical Engineering, Inner Mongolia University of Technology, Huhhot 010051, China)

Abstract: Grassland degradation is an ecological problem facing the world. Investigating the species composition and species distribution of grassland is extremely important for judging the degradation process of grassland. At present, satellite remote sensing technology is difficult to meet the requirements of grassland species level classification due to the limitation of spatial resolution. Unmanned aerial vehicle (UAV) hyperspectral remote sensing technology provides images of centimeter level spatial resolution and nanoscale spectral resolution required for grassland species classification. Based on the UAV hyperspectral imaging remote sensing system, the hyperspectral image data of low and mixed growth desert grassland degradation indicator species were collected in the 400 ~ 1 000 nm spectral range. Flight experiments were carried out at the flowering, fruiting and yellow blight periods of the degraded indicator species. The flying height was 30 m and the ground resolution of the hyperspectral image was about 2.3 cm. Based on the combination of feature bands extraction and deep learning convolutional neural network (CNN), a method for classification of desert grassland species was proposed. The recommended phenological phase of species classification of desert grassland in central Inner Mongolia, China, was given in combination with plant phenology. The overall classification accuracy and Kappa coefficient reached 94% and 0.91, respectively. The results showed that the UAV hyperspectral imaging remote sensing technology and deep CNN can better classify the indicator species of desert grassland degradation. Compared with the support vector machine based on radial basis kernel function and the deep CNN based on principal component analysis, the deep CNN classification based on feature bands selection had the best effect and the highest classification accuracy. The method of CNN and the low-altitude remote sensing of UAV equipped with hyperspectral imager provided a new way to classify grassland species. The

收稿日期: 2018-12-13 修回日期: 2019-02-18

基金项目: 国家自然科学基金项目(31660137)

作者简介: 杨红艳(1974—), 女, 博士生, 内蒙古工业大学讲师, 主要从事无人机遥感和草原退化监测研究, E-mail: yhy13651288@126.com

通信作者: 杜健民(1960—), 男, 教授, 博士生导师, 主要从事农业资源环境遥感监测研究, E-mail: nndjwc202@imau.edu.cn

research result provided characteristic parameters for the judgment of grassland degradation succession process, and quantitative indicators for grassland ecological restoration management.

Key words: desert grassland; indicator species; classification; hyperspectral remote sensing; unmanned aerial vehicle; convolutional neural network

0 引言

草原是重要的地球生态系统,在全球气候变化和全球生态平衡中起着关键作用^[1]。草原退化导致土地退化、沙化,沙尘暴等自然灾害频发,严重影响环境质量和生态平衡^[2]。草原退化的一个显著特征是优势物种的改变,即在群落中可食、多年生的物种比例减少,不可食、一年生的物种比例增加^[3]。研究表明,某些物种对草原退化具有重要的指示意义。例如,中国内蒙古东部典型草原的主要类型为针茅草原、克氏针茅草原和羊草草原,在过度放牧下出现不同程度的退化,最终趋向于以冷蒿为主的草原。中国内蒙古西部荒漠草原的主要类型为针茅草原和短花针茅草原,在过度放牧和干旱的共同作用下,冷蒿和无芒隐子成为群落中的优势物种。在退化程度更高的地区,猪毛菜和栉叶蒿等一年生物种逐渐在群落中占据优势^[3-5]。虽然经过几十年的生态治理,草原生态环境已得到一定改善,但草原生态恢复仍任重道远。在草原退化程度加剧之前通过指示物种的监测发出预警,为草原生态环境管理提供动态和定量的监测数据具有重要意义。

遥感方法适用于大面积动态监测。多光谱遥感技术已实现草原植被群落水平的分类^[6],然而,群落水平的分类只能反映草原退化的现状,不能反映与退化程度密切相关的物种构成,因而难以对草原生态的进一步恶化发出预警。高光谱遥感的光谱分辨率达1~10 nm,许多在多光谱遥感中无法探测的物质,在高光谱遥感中能被探测到,并能对相似地物利用连续的光谱数据寻找光谱差异进行区分。利用高光谱遥感技术进行农作物病虫害监测和生化参数估算已取得一定研究成果^[7-9],但由于卫星遥感空间分辨率的限制和草原物种结构低矮、细小和混杂生长的特性,使卫星高光谱遥感在草原监测方面难以实现物种水平的分类。

无人机遥感技术具有时间、空间分辨率高的优点,与高光谱遥感技术结合,克服了卫星高光谱遥感的缺点,在精细农业监测和生态环境研究等领域发挥着越来越重要的作用^[10-15]。如CAO等^[16]采用多旋翼无人机搭载高光谱成像传感器获取遥感图像,鉴别了红树林物种。在草原监测方面,SCHMIDT等^[17]实现了利用无人机高光谱遥感技术

监测草原矮化灌木的分布。LU等^[18]使用多旋翼无人机搭载数码相机,获得加拿大安大略南部科夫勒科学保护区的厘米级空间分辨率的遥感图像,识别出影响北美帝王蝶数量的乳草属植物。然而,对于草原优势物种、建群物种等物种水平的遥感监测,还未见报道。

高光谱成像的复杂过程导致数据非线性,使高光谱遥感图像分类仍较困难。深度学习中的卷积神经网络具有自主学习能力,善于处理复杂的多维非线性问题,能够自动分层次地提取特征,在图像分类中表现出更高有效性和更强鲁棒性。在遥感图像分类领域,卷积神经网络也显示出巨大潜力^[19-20]。KUSSUL等^[21]利用Landsat-8和Sentinel-1A卫星遥感图像对异质环境中的农作物(小麦、玉米、向日葵、大豆和甜菜)进行分类,通过对比卷积神经网络、全连接的多层感知器和随机森林分类方法,发现卷积神经网络的分类精度最高,作物的分类精度均超过85%。CHEN等^[22]利用卷积神经网络实现了在不同高光谱数据集(Indian Pines data set、University of Pavia data set和KSC data set)的地物分类,证实卷积神经网络在高光谱图像领域的普遍适用性。

根据荒漠草原物种水平分类的需求,本文运用无人机高光谱遥感技术,采集荒漠草原植被高光谱图像,建立一种基于卷积神经网络的荒漠草原物种水平遥感分类的计算方法,以期实现荒漠草原重要生态物种分类,确定各物种的最佳识别物候期,为荒漠草原的退化监测提供基础数据。

1 材料和方法

1.1 研究区概况

试验在内蒙古农牧科学院四子王旗基地(41°46'43.6"N,111°53'41.7"E)开展,如图1所示。基地位于内蒙古自治区乌兰察布市四子王旗中南部的格根塔拉草原,该地区属于典型的中温带大陆性气候,年平均降水量280 mm,其中5—9月(植被生长季)的降水量约占年总降水量的80%以上。年平均温度3.4℃,其中6—8月平均气温最高^[23]。格根塔拉草原属于荒漠草原,植被低矮、稀疏,平均高度为8 cm,覆盖率为12%~25%,主要由20多种植物组成。建群种为短花针茅,优势种为冷蒿和无芒

隐子草,伴生种包括猪毛菜、栉叶蒿、银灰旋花、阿尔泰狗娃花、羊草等^[24]。




图1 研究区卫星图像

Fig.1 Google satellite image of study site

1.2 无人机高光谱遥感图像采集系统

使用深圳大疆技术有限公司的 Matrice 600Pro 型六旋翼无人机。该机的最大有效载荷为 6 kg,满载时的飞行持续时间为 16 min。采用专业级 A3Pro 飞行控制系统,配有 3 套惯性测量单元和全球导航卫星系统模块,用于精确定位和飞行姿态调整。使用成都四川双利合谱技术有限公司的 GaiaSky-mini 型高光谱成像仪,其光谱波长范围为 400 ~ 1 000 nm,有 256 个光谱通道,光谱分辨率为 3.5 nm。镜头焦距为 17 mm,横向视场角为 29.6°,空间维图像为 696 像素 × 700 像素。光谱仪质量 1.3 kg,用于控制飞行中图像采集和存储的采集控制器质量 0.65 kg。无人机和高光谱成像仪如图 2 所示。



图2 无人机和高光谱遥感图像采集系统

Fig.2 UAV and hyperspectral imaging system

1.3 无人机遥感系统数据采集及野外调查

短花针茅是中国荒漠草原的主要牧草,在蒙古和俄罗斯也有少量分布。冷蒿是一种耐牧、抗旱的牧草,具有北温带草原种的特性,在中国典型草原和荒漠草原均有分布,在退化的荒漠草原上成为优势物种^[25]。短花针茅和冷蒿在群落中数量的增减对于判断荒漠草原退化程度具有重要意义。由于过度放牧和干旱的作用,近几年猪毛菜的数量在格根塔拉荒漠草原有明显增多的趋势,对荒漠草原退化过程的判断具有一定的指导意义。因此,本研究选择格根塔拉荒漠草原的建群种短花针茅、优势种冷蒿和伴生种猪毛菜作为研究对象。研究区(图1中黑

色框区域)占地面积 4.61 hm²,从 2002 年开始禁牧。在研究区内,设置 150 个样方,按 10 m 间隔等距分布,共 15 行 10 列。单个样方面积 1 m × 1 m。选择短花针茅样方 45 个,冷蒿样方 45 个,猪毛菜样方 45 个作为数据采集对象。样方的类别由样方内大于草总量 90% 的草的类别来确定,样方内其余 10% 的草为混杂生长的其他牧草。

无人机高光谱数据采集于研究对象的开花期(2017 年 6 月 17—24 日)、结实期(2017 年 7 月 17—24 日)和黄枯期(2017 年 9 月 17—24 日),2017 年 8 月,由于当地空域限制,无法进行采集。无人机高光谱成像系统采用无人机悬停、光谱仪内置推扫采集图像的工作方式。无人机飞行高度 30 m,图像空间分辨率约 2.3 cm。选择无风或风力小于 2 级,晴朗无云或云量小于 2 的气象条件,在 10:00—14:00 之间飞行采集数据。无人机每个架次飞行前后均进行标准参考白板校正。

野外地面调查包括样方植被组成、植被覆盖度和植被冠层图像采集。试验的前一年(2016 年)降水充足,主要集中在 6 月和 7 月,6 月的日最大降水量达到 38 mm。整个植被生长季的累积降水量达到 332.9 mm,高于多年平均降水量(280 mm),属于丰水年,植被生长状况非常好,特别是 6 月的降水使得猪毛菜的生长非常旺盛。试验年(2017 年)降水量较少,主要集中在 8 月和 9 月,日最大降水量为 13.6 mm。整个植被生长季累积降水量仅为 153 mm,低于多年平均降水量(280 mm),属于干旱年^[23]。野外调查和无人机高光谱数据采集同时开展,野外调查样方类别作为无人机采集图像物种分类结果验证的真值。

1.4 无人机采集图像数据预处理

首先通过人工目视检查图像质量,去除因阵风引起的变形图像;其次使用 SpecView 软件进行图像辐射校正,消除数据获取和传输过程产生的辐射失真或畸变,得到地物真实的反射率数据;最后采用线性平滑高斯滤波法进行图像降噪。

2 基于卷积神经网络的荒漠草原物种分类

2.1 荒漠草原物种特征波段选择

高光谱数据有上百个波段,波段间距窄,提供了丰富的地物光谱信息。但波段越多,波段间的相关性就越大,数据的冗余度也越大,同时也带来了海量数据存储和处理的技术难题^[26]。特征波段选择用于从原始波段中提取能够有效代表地物特征、信息量大、相关性小且地物可分离性大的波段子集,本文通过分步法来寻找满足上述要求的波段组合。

因高光谱相邻波段间相关性大,距离远的波段间相关性小,但距离远的波段组合,其信息量可能并不大。为避免此类情况,首先将所有波段按其相关性分为 6 个相关性较弱的子集,在各子集内寻找特征波段(如反射率光谱曲线的极值点、拐点等)即信息量大的波段作为子集的代表波段。在选出的 6 个代表波段中,以任意 3 个波段为 1 组,计算 20 组波段组合的最佳指数因子 (Optimal index factor, OIF)。将 20 组波段组合分别合成假彩色图像,用 Jeffreys Matusita (JM) 距离计算各类地物(短花针茅、冷蒿、猪毛菜、裸土、样方框)的可分性,最后选择 OIF 值最大且 JM 值大于等于 1.8、相关系数小于等于 0.3 的一组波段作为最佳特征波段组合。

最佳指数因子的原理是:波段间相关性越小,波段的标准差越大,波段组合的信息量就越大。OIF 计算公式为^[27-28]

$$O = \frac{\sum_{i=1}^n S_i}{\sum_{i=1}^n \sum_{j=1}^n |R_{ij}|} \quad (1)$$

式中 O ——最佳指数因子
 S_i ——第 i 个波段的标准差
 R_{ij} ——第 i 波段和第 j 波段的相关系数
 n ——在所有波段中要选取的波段数

OIF 值越大,所选择波段的结果越优。JM 距离是基于条件概率理论的光谱可分性指标,其计算公式为^[29]

$$J = \int_X \left(p\left(\frac{X}{\omega_i}\right) - p\left(\frac{X}{\omega_j}\right) \right)^2 dX \quad (2)$$

式中 J ——JM 距离 X ——像元
 ω_i, ω_j ——类别号
 $p(X/\omega_i), p(X/\omega_j)$ ——类条件概率密度,即第 i, j 个像元属于第 ω_i, ω_j 个类别的几率

JM 值在 0~2 之间,其值越大代表像元的可分性越大^[30]。

分步法特征波段选择的流程如图 3 所示。

2.2 卷积神经网络分类

基于无人机平台的低空高光谱图像采集方法,使得得到的高光谱图像的空间分辨率增高,细小地物构成的组合图案的纹理结构增强。经特征波段合成

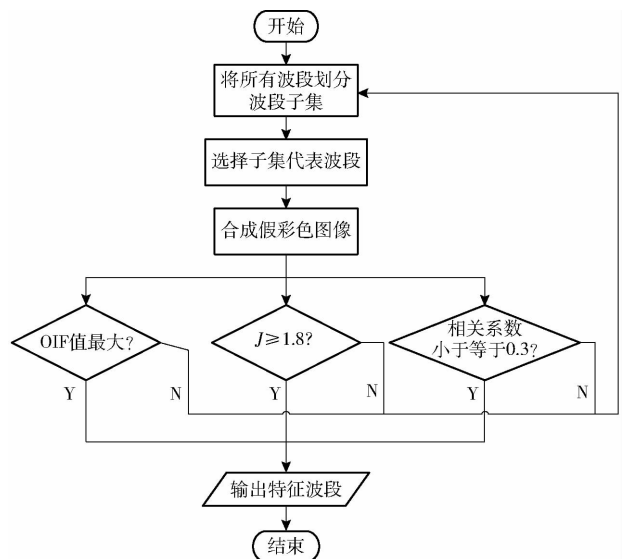


图 3 分步法特征波段选择流程图

Fig. 3 Flow chart of feature bands selection by step-by-step method

的假彩色图像的色彩差别增强。纹理结构和色彩差别的增强使得从航空影像上对荒漠草原物种分类成为可能。

卷积神经网络通过模仿人类视觉逐层认知物体的方式,很适合图像分类。卷积神经网络由卷积层、池化层和全连接层组成。卷积层与池化层配合,组成多个卷积组,逐层提取图像特征。网络底层识别图像边缘,上层识别特定形状,再高层识别特征^[31]。卷积神经网络通过卷积的权值共享及池化降低网络参数的数量,使需要训练的参数数量大大减少,在缺乏大量训练数据的高光谱图像领域中具有极大优势^[22]。

随机生成卷积神经网络模型的初始参数,使用梯度下降法使损失函数(交叉熵代价函数)最小化来逐层反向调节所有参数,通过多次迭代不断提高模型的精度,网络学习到的特征结合 Softmax 回归分类器实现图像分类。输入图像为特征波段选择后的 3 波段 100 像素 × 100 像素的像元邻域,经过 4 层卷积和 4 层池化后,输入图像变为 128 维的矢量输入全连接层,经 2 层全连接层后输出,输出为样本的类别标签。训练过程中,使用小批量反向传播方法,每一批样本数为 10,学习速率设为 0.001,迭代次数为 30,网络结构的具体参数如表 1 所示,表中 C 表示卷积层, P 表示池化层, F 表示全连接层。

表 1 卷积神经网络结构

Tab. 1 CNN structure

参数	层名									
	C2	P3	C4	P5	C6	P7	C8	P9	F10	F11
核尺寸	5 × 5	2 × 2	5 × 5	2 × 2	3 × 3	2 × 2	3 × 3	2 × 2	全连接	全连接
特征图数	32	32	64	64	128	128	128	128	1024	512

由于多层卷积和池化能够提取对多种变形具有高度不变性的非线性特征,故可以通过对原始图像的拉伸、旋转来增加样本数量。本文 100 像素 × 100 像素 × 3 原始假彩色图像 405 个,其中测试集 180 个,其余图像通过拉伸、旋转增加至 864 个作为训练集和验证集,训练集、验证集样本数之比为 4:1。

3 分类结果与讨论

3.1 分类结果

采用分步法得到的特征波段如表 2 所示。

基于无人机高光谱遥感技术与卷积神经网络的

表 2 荒漠草原物种光谱特征波段选择结果

Tab.2 Bands selection results for desert grassland species

物候期	波长/nm		
开花期	581.1	755.5	995.6
结实期	585.9	823.1	972.0
黄枯期	504.0	652.8	818.0

荒漠草原物种分类结果如表 3 所示。将野外调查样方的实测类别作为分类真实值,对采用上述特征波段选择与卷积神经网络方法分类结果进行精度评价,不同物候期的整体分类准确率平均值为 94%, Kappa 系数平均值为 0.91。

表 3 基于特征波段与卷积神经网络分类的混淆矩阵

Tab.3 Confusion matrix based on feature bands and CNN classification

物候期		预测				生产者精度/%	Kappa 系数
		短花针茅	冷蒿	猪毛菜	合计		
开花期	实际	短花针茅	19	0	1	20	0.88
		冷蒿	4	16	0	20	
		猪毛菜	0	0	20	20	
		合计	23	16	21	60	
		用户精度/%	83	100	95	92	
结实期	实际	短花针茅	19	1	0	20	0.96
		冷蒿	0	20	0	20	
		猪毛菜	1	0	19	20	
		合计	20	21	19	60	
		用户精度/%	95	95	100	97	
黄枯期	实际	短花针茅	19	0	1	20	0.90
		冷蒿	0	18	2	20	
		猪毛菜	0	1	19	20	
		合计	19	19	22	60	
		用户精度/%	100	95	86	93	

草原不同植物物种有着各自不同的生、繁、衰、枯的物候节律,在其光谱和图像上也有体现,结合光谱和物候特征,可提高相似物种的分类精度^[32]。从物候角度来看,影响分类结果的因素如下:

(1)开花期指短花针茅处于开花期,此时冷蒿处于营养期,猪毛菜处于萌芽期。短花针茅圆锥花序狭窄,卷积神经网络从遥感图像上很难捕捉到此特征,可能是这一时期冷蒿和短花针茅图像相近的原因。一年生物种猪毛菜受降雨影响大,此时猪毛菜以枯枝(2016 年生长的猪毛菜植株枯萎后的枯枝)为主,其反射率光谱、图像纹理和色彩与短花针茅、冷蒿区别大,容易区分。图 4 为不同物候期物种的特征波段合成的假彩色图像,图中开花期的红色代表绿色植被,白色代表猪毛菜枯枝。

(2)结实期指短花针茅处于结实期,此时冷蒿、猪毛菜处于营养期。随着气温升高及几次降雨,各

牧草生长迅速,覆盖度增大。猪毛菜对水分供应高度敏感且对水资源利用效率高而生长最迅速,植株高度和地面覆盖度都超过了短花针茅和冷蒿。在纹理上形成大片丛生密集的形态结构;在色彩上和短花针茅、冷蒿有了明显区别。此时,冷蒿和猪毛菜相比,植株小且呈半匍匐状形态,从图 4 中可以看到,冷蒿的纹理为均匀分布的小颗粒状。图 4 中结实期的红色代表绿色植被,绿色代表裸土。

(3)黄枯期指短花针茅处于黄枯期,此时冷蒿处于结实期,猪毛菜处于黄枯期。此时猪毛菜茎秆的紫红色条纹愈加显著,与其它两种植被有明显的差异;短花针茅叶片逐渐开始枯黄;冷蒿的衰退最晚,从图像上看与上一时期相差不大。图 4 中黄枯期的紫色代表绿色植被。

本研究中,猪毛菜在开花期、结实期的分类精度均较高,结实期的猪毛菜生长旺盛,是分类的最好时




图 4 特征波段合成的假彩色图像

Fig. 4 False color images synthesized by feature bands

期;冷蒿在结实期的分类精度较高,此时冷蒿释放的强烈挥发性气味导致家畜不喜采食^[33-34],因而是获得冷蒿分布的最佳时期;短花针茅在黄枯期的分类精度较高,此时适于遥感监测其分布。

3.2 讨论

由表 3 分类结果可知,本文提出的基于特征波段的卷积神经网络方法的分类精度较高。卷积神经网络分类精度高的原因有以下几方面。

对于高光谱数据的非线性,通过在每个卷积层后连接非线性激活函数 ReLU 来增加网络的非线性能力,从而较好地拟合非线性过程。此外,ReLU 函数在一定程度上能够防止梯度消失,函数的单侧抑制性使得卷积神经网络中的神经元具有了稀疏激活性^[35]。

由于高光谱图像难以获得大量训练样本,常常在训练样本上能得到很好的分类结果,但在测试样本上的分类结果却不好,也即出现了过拟合。本研究通过在网络最后几层全连接层的损失函数后增加

L2 正则化项,使权重衰减来避免过拟合。此外,Dropout 策略也被用来防止过拟合,即在模型训练过程中设置一定比例的隐藏层节点,使其暂时不参与训练^[36]。

高光谱图像数据特征的提取与卷积神经网络的权重密切相关,通过可视化可以观察权重在特征提取中如何起作用,图 5 为开花期荒漠草原物种的遥感图像经过 4 层卷积、池化的一个特征图权重的变化。图中颜色越浅,表明该点权重利用率越高。初始权重看起来杂乱无序,学习后的权重开始出现连续性和相关性。经过卷积后的图像对原图像有特征增强和降低噪声的效果;池化层利用图像的局部相关性,在保留有用信息的同时,使原图像的长和宽减半,减小数据量。

为进一步探索本文提出方法的适用性,比较了 3 种分类方法:基于主成分分析的卷积神经网络 (PCA_CNN)、基于径向基核函数的支持向量机 (SVM)、本文提出的基于特征波段选择的卷积神经网络 (BS_CNN)。在 PCA_CNN 中提取前 3 个主成分,合成 3 波段假彩色图像作为卷积神经网络的输入。在 SVM 中,参数 C 和 γ 采用网格搜索在 C 为 1×10^3 、 5×10^3 、 1×10^4 、 5×10^4 、 1×10^5 和 γ 为 0.000 1、0.000 5、0.001、0.005、0.01、0.1 的范围内进行参数优选。3 种方法的分类精度对比如图 6 所示。

由图 6 可知,基于特征波段选择的卷积神经网络分类在总体分类精度、平均分类精度和 Kappa 系数 3 种评价方式下均得到最好结果。以开花期为例,BS_CNN 比 SVM 的总体分类精度、平均分类精度和 Kappa 系数分别提高了 9.73、9.48、14.55 个百分点,比 PCA_CNN 的总体分类精度、平均分类精度和 Kappa 系数分别提高了 10、10、15 个百分点。

分析 3 种分类方法,SVM 处理小规模样本效果




图 5 短花针茅、冷蒿、猪毛菜在 4 层卷积、池化后的权重可视化

Fig. 5 Visualization of weights after four convolution and pooling layers




图6 3种分类方法的分类精度比较

Fig. 6 Classification accuracy comparison of three classification methods

较好,在处理如高光谱图像的大规模高维数据时,效果稍差。对非线性问题,核函数的选择更困难。使用CNN的两种方法中,PCA_CNN通过多维正交线性变换,将主要信息集中在前几个波段上。虽然保留了数据的主要信息,但保留的不一定是利于物体分类的特征。BS_CNN是根据分类对象的可分离性和波段的相关性选择的波段,因而保证了所选波段信息量大且利于物体分类,使其分类精度较高。

本文提出的基于特征波段选择的卷积神经网络分类方法,适用于大样本、高维、非线性数据的特征提取,应用于无人机高光谱低空遥感获得的高空间分辨率和高光谱分辨率的数据,能够对草原优势物种、伴生种(具有一定的聚集数量)进行分类识别,结合植物物种的物候,将有效提高其分类精度。草原物种分类的实现,为草原物种覆盖度的估算提供了必要的基础。在草原生态进一步恶化前,根据毒杂草,一、两年生适口性差的牧草的增加量及适口性好的优良牧草的减少量,对退化程度做出正确判断,及时采取有效措施,调整草原畜牧经营模式,并为草原生态恢复提供基础数据。

4 结论

(1)使用无人机搭载高光谱成像仪低空飞行采集图像的手段,获得了光谱、空间、时间分辨率均较高的遥感图像,利用高光谱特征提取和深度学习技术,实现了对内蒙古自治区格根塔拉荒漠草原退化指示物种的分类。

(2)充分利用植被的物候信息,有助于提高物种分类精度,尤其对于易混淆物种的区分。

(3)对比了BS_CNN、PCA_CNN和SVM3种分类方法,其中BS_CNN分类精度最高。使用BS_CNN分类法,短花针茅在黄枯期分类精度最高,生产者精度95%,用户精度100%;冷蒿在结实期分类精度最高,生产者精度100%,用户精度95%;猪毛菜在结实期分类精度最高,生产者精度95%,用户精度100%。

(4)高光谱特征波段选取了3个波段。波段选择并不唯一,是在限定条件下的最优化。当采用更多波段作为特征时,可能会提高精度。但波段增加,波段间的相关性和运算复杂性将增大,最适宜的波段个数需要在进一步的研究中分析确定。

参 考 文 献

- [1] HAN Z, SONG W, DENG X, et al. Grassland ecosystem responses to climate change and human activities within the Three-River Headwaters region of China[J]. Scientific Reports, 2018, 8(1): 9079.
- [2] WU X, REN G, DONG Q, et al. Above- and belowground response along degradation gradient in an alpine grassland of the Qinghai-Tibetan Plateau[J]. Clean-soil Air Water, 2014, 42(3): 319-323.
- [3] 刘钟龄, 王炜, 郝敦元, 等. 内蒙古草原退化与恢复演替机理的探讨[J]. 干旱区资源与环境, 2002, 16(1): 84-91. LIU Zhongling, WANG Wei, HAO Dunyuan, et al. Probes on the degeneration and recovery succession mechanisms of Inner Mongolia steppe[J]. Journal of Arid Land Resources & Environment, 2002, 16(1): 84-91. (in Chinese)
- [4] LI J, LIN S, TAUBE F, et al. Above and belowground net primary productivity of grassland influenced by supplemental water and nitrogen in Inner Mongolia[J]. Plant & Soil, 2011, 340(1-2): 253-264.
- [5] ZHANG Q, DING Y, MA W, et al. Grazing primarily drives the relative abundance change of C4 plants in the typical steppe grasslands across households at a regional scale[J]. Rangeland Journal, 2014, 36(6): 565-572.
- [6] LEHNERT L W, MEYER H, MEYER N, et al. A hyperspectral indicator system for rangeland degradation on the Tibetan Plateau: a case study towards spaceborne monitoring[J]. Ecological Indicators, 2014, 39(4): 54-64.
- [7] XU X, YANG G, YANG X, et al. Monitoring ratio of carbon to nitrogen (C/N) in wheat and barley leaves by using spectral slope features with branch-and-bound algorithm[J]. Scientific Reports, 2018, 8(1): 10034.
- [8] 张爱武, 鄢文艳, 郭超凡. 基于高光谱图像的牧草粗蛋白含量反演模型[J]. 农业工程学报, 2018, 34(3): 188-194. ZHANG Aiwu, YAN Wenyan, GUO Chaofan. Inversion model of pasture crude protein content based on hyperspectral image[J]. Transactions of the CSAE, 2018, 34(3): 188-194. (in Chinese)
- [9] 谢亚平, 陈丰农, 张竞成, 等. 基于高光谱技术的农作物常见病害监测研究[J]. 光谱学与光谱分析, 2018, 38(7): 2233-2240. XIE Yaping, CHEN Fengnong, ZHANG Jingcheng, et al. Study on monitoring of common diseases of crops based on hyperspectral technology[J]. Spectroscopy & Spectral Analysis, 2018, 38(7): 2233-2240. (in Chinese)

- [10] TOKEKAR P, HOOK J V, MULLA D J, et al. Sensor planning for a symbiotic UAV and UGV system for precision agriculture [J]. *IEEE Transactions on Robotics*, 2016, 32(6): 1498 – 1511.
- [11] YOKOYA N, CHAN J C, SEGL K. Potential of resolution-enhanced hyperspectral data for mineral mapping using simulated EnMAP and Sentinel-2 images[J]. *Remote Sensing*, 2016, 8(3): 172.
- [12] PIRCHER M, GEIPEL J, KUSNIEREK K, et al. Development of a hybrid UAV sensor platform suitable for farm-scale applications in precision agriculture[J]. *ISPRS—International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2017, XLII-2/W6: 297 – 302.
- [13] 陈鹏飞. 无人机在农业中的应用现状与展望[J]. *浙江大学学报(农业与生命科学版)*, 2018, 44(4): 399 – 406.
CHEN Pengfei. Applications and trends of unmanned aerial vehicle in agriculture[J]. *Journal of Zhejiang University(Agric. & Life Sci.)*, 2018, 44(4): 399 – 406. (in Chinese)
- [14] 杨敏, 徐栋, 王新胜, 等. 面向岛礁应急监测的多手段组网设计与实验[J]. *海洋科学*, 2018, 42(1): 32 – 38.
YANG Min, XU Dong, WANG Xinsheng, et al. Design and experiment on multi-means networking scheme for emergency monitoring of islands and reefs[J]. *Marine Sciences*, 2018, 42(1): 32 – 38. (in Chinese)
- [15] 牛亚晓, 张立元, 韩文霆, 等. 基于无人机遥感与植被指数的冬小麦覆盖度提取方法[J/OL]. *农业机械学报*, 2018, 49(4): 212 – 221.
NIU Yaxiao, ZHANG Liyuan, HAN Wenting, et al. Fractional vegetation cover extraction method of winter wheat based on UAV remote sensing and vegetation index[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(4): 212 – 221. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20180424&flag=1. DOI:10.6041/j.issn.1000-1298.2018.04.024. (in Chinese)
- [16] CAO J, LENG W, LIU K, et al. Object-based mangrove species classification using unmanned aerial vehicle hyperspectral images and digital surface models[J]. *Remote Sensing*, 2018, 10(1): 89.
- [17] SCHMIDT J, FASSNACHT F E, NEFF C, et al. Adapting a Natura 2000 field guideline for a remote sensing-based assessment of heathland conservation status[J]. *International Journal of Applied Earth Observation & Geoinformation*, 2017, 60: 61 – 71.
- [18] LU B, HE Y. Species classification using unmanned aerial vehicle (UAV)-acquired high spatial resolution imagery in a heterogeneous grassland[J]. *ISPRS Journal of Photogrammetry & Remote Sensing*, 2017, 128: 73 – 85.
- [19] ZHANG L, ZHANG L, DU B. Deep learning for remote sensing data: a technical tutorial on the state of the art[J]. *IEEE Geoscience & Remote Sensing Magazine*, 2016, 4(2): 22 – 40.
- [20] WANG L, ZHANG J, LIU P, et al. Spectral—spatial multi-feature-based deep learning for hyperspectral remote sensing image classification[J]. *Soft Computing*, 2017, 21(1): 213 – 221.
- [21] KUSSUL N, LAVRENIUK M, SKAKUN S, et al. Deep learning classification of land cover and crop types using remote sensing data[J]. *IEEE Geoscience & Remote Sensing Letters*, 2017, 14(5): 778 – 782.
- [22] CHEN Y, JIANG H, LI C, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2016, 54(10): 6232 – 6251.
- [23] 韩梦琪. 短花针茅荒漠草原物种多样性及生产力对不同载畜率的响应[D]. 呼和浩特: 内蒙古农业大学, 2018.
HAN Mengqi. Response of species diversity and productivity to different stocking rates in the *Stipa breviflora* desert steppe [D]. Huhhot: Inner Mongolia Agricultural University, 2018. (in Chinese)
- [24] 潘占磊, 王忠武, 韩国栋, 等. 短花针茅荒漠草原甲烷通量对增温和施氮的响应[J]. *生态环境学报*, 2016, 25(2): 209 – 216.
PAN Zhanlei, WANG Zhongwu, HAN Guodong, et al. Responses of methane fluxes on warming and nitrogen addition in *Stipa breviflora* desert steppe[J]. *Ecology & Environmental Sciences*, 2016, 25(2): 209 – 216. (in Chinese)
- [25] 宛涛, 卫智军. 谈冷蒿特性与冷蒿草场的利用[J]. *内蒙古农牧学院学报*, 1991, 12(2): 48 – 52.
WAN Tao, WEI Zhijun. Characters and utilization of Fringed sagebrush[J]. *Journal of Inner Mongolia Institute of Agriculture & Animal Husbandry*, 1991, 12(2): 48 – 52. (in Chinese)
- [26] YUAN Y, ZHENG X, LU X. Discovering diverse subset for unsupervised hyperspectral band selection[J]. *IEEE Transactions on Image Processing*, 2017, 26(1): 51 – 64.
- [27] CHAVEZ P S. Statistical method for selecting LANDSAT MSS ratios[J]. *Journal of Applied Photographic Engineering*, 1982, 8(1): 23 – 30.
- [28] QI C, WANG Y, TIAN W, et al. Multiple kernel boosting framework based on information measure for classification[J]. *Chaos Solitons & Fractals*, 2016, 89: 175 – 186.
- [29] SU H, YONG B, DU Q. Hyperspectral band selection using improved firefly algorithm[J]. *IEEE Geoscience & Remote Sensing Letters*, 2016, 13(1): 68 – 72.
- [30] GHIYAMAT A, SHAFRI H Z, MAHDIRAJI G A, et al. Hyperspectral discrimination of tree species with different classifications using single- and multiple-endmember [J]. *International Journal of Applied Earth Observation & Geoinformation*, 2013, 23(23): 177 – 191.
- [31] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436 – 444.
- [32] GOTZE C, GERSTMANN H, GLASER C, et al. An approach for the classification of pioneer vegetation based on species-specific phenological patterns using laboratory spectrometric measurements[J]. *Physical Geography*, 2017, 38(6): 524 – 540.
- [33] LI X F, WANG J, HUANG D, et al. Allelopathic potential of *Artemisia frigida* and successional changes of plant communities in the northern China steppe[J]. *Plant and Soil*, 2011, 341(1 – 2): 383 – 398.
- [34] ZHANG R M, ZUO Z J, GAO P J, et al. Allelopathic effects of VOCs of *Artemisia frigida* Willd. on the regeneration of pasture grasses in Inner Mongolia[J]. *Journal of Arid Environments*, 2012, 87(12): 212 – 218.
- [35] MHASKAR H N, POGGIO T. Deep vs. shallow networks: an approximation theory perspective[J]. *Analysis & Applications*, 2016, 14(6): 829 – 848.
- [36] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C] // International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2012: 1097 – 1105.