

# 多尺度特征和多模型相融合的草原区牧畜遥感监测

肖如林<sup>1</sup>, 高吉喜<sup>1</sup>, 刘爱军<sup>2</sup>, 侯鹏<sup>1</sup>, 张文国<sup>1</sup>, 杨勇<sup>2</sup>,  
李运保<sup>3</sup>, 付卓<sup>1</sup>, 靳川平<sup>1</sup>, 杨栩<sup>1</sup>, 郑淑华<sup>2</sup>, 殷守敬<sup>1</sup>

1. 生态环境部卫星环境应用中心, 北京 100094;

2. 内蒙古自治区草原遥感及应急技术储备重点实验室, 呼和浩特 010020;

3. 绵阳市生态环境局信息中心, 绵阳 621050

**摘要:** 超载过牧是中国草原退化的主要原因之一, 而载畜情况是评估草畜平衡的关键。面向牧畜高效、精准监管工作需求, 针对牧畜“小(微)目标”监测的痛点难点, 基于亚米级卫星遥感数据, 综合利用牧畜“点”特征、“群”特征、“移动不固定”特征等多种特征, 融合深度学习、面向对象等多种识别技术方法, 构建了一种多尺度特征和多模型方法相融合的牧畜高分卫星遥感监测技术方法。该方法通过对牧畜弱信号的有效增强、“牧畜群”和“牧畜斑点”的分阶段检测与相互融合增强, 实现了对牧畜群分布、牧畜斑点分布和牧畜群规模的监测提取, 推动牧畜卫星遥感监测向“点数”式精细化监测迈进。锡林郭勒草原区域监测实验数据显示, 模型检出率约0.802, 误检率约0.244, 具有较好效果。该方法的应用, 可为草原区载畜情况的监测监管提供支撑, 也可为其他“小(微)目标”的遥感监测提供借鉴; 无论是在技术创新还是业务应用方面都具有十分重要的意义。

**关键词:** 牧畜, 遥感, 载畜, 草原, 小(微)目标

**中图分类号:** TP701/P2

**引用格式:** 肖如林, 高吉喜, 刘爱军, 侯鹏, 张文国, 杨勇, 李运保, 付卓, 靳川平, 杨栩, 郑淑华, 殷守敬. 2023. 多尺度特征和多模型相融合的草原区牧畜遥感监测. 遥感学报, 27(10): 2383–2394

Xiao R L, Gao J X, Liu A J, Hou P, Zhang W G, Yang Y, Li Y B, Fu Z, Jin C P, Yang X, Zheng S H and Yin S J. 2023. Remote sensing monitoring method of livestock in grassland based on multi-scale features and multi-models fusion. National Remote Sensing Bulletin, 27(10): 2383–2394 [DOI:10.11834/jrs.20222099]

## 1 引言

中国草地资源丰富, 畜牧业发达, 畜牧业在中国北方草原区国民经济中占有重要地位。然而草原超载过牧的问题也比较突出, 成为中国草原退化的主要原因之一(付国臣等, 2009)。载畜情况监测是禁牧区放牧活动监管、草畜平衡区载畜情况监测与草畜平衡评估分析的关键。因此, 高效、精准地获取牛、羊等草原典型牧畜的分布、规模等信息, 及时掌握禁牧区是否存在放牧、草畜平衡区是否过牧等情况, 实现对草原区牧畜的精准监管, 对维护草原区生态安全、国民经济可持续发展、社会稳定都具有重要意义。

在应用方面, 目前对放牧活动的监管主要依

托逐级填报统计(王庆等, 2007)、入户调查统计(王美兔和李迪强, 2017)、无人机或系留式空基遥感监测(中国科学院植物研究所, 2020; 汪琪等, 2021)、在线视频或穿戴式设备监控(张小栓等, 2019; 王奎等, 2020)等方式。其中, 逐级填报方式存在漏报、虚报、瞒报的可能, 数据质量难以保障; 入户调查统计方式以及无人机、系留式航空遥感监测方式由于成本高, 只能采取抽样估算, 难以全面实施; 在线视频或穿戴式设备方式通常只能安装在出入口、羊圈、头羊等位置, 可操作性差, 且投入和运维成本高。

在技术研究方面, 目前一些基于无人机、系留式空基遥感的动物或牧畜监测技术(邵全琴等, 2018; 郭兴健等, 2019; Peng等, 2020; 中国科

收稿日期: 2022-03-11; 预印本: 2022-10-19

基金项目: 国家重点研发计划(编号:2021YFB3901102)

第一作者简介: 肖如林, 研究方向为生态遥感监测评估、信息化等的研究与应用。E-mail: AlexanderShaw\_84@163.com

通信作者简介: 高吉喜, 研究方向为区域生态保护、生态资产评估、区域生态学等。E-mail: gjx@nies.org





学院植物研究所, 2020; 汪琪 等, 2021), 主要基于目标信息丰富、清晰的分米或亚分米级超高分辨率的航空遥感图像, 对米级或亚米级高分卫星遥感图像并不适用。目前实际载畜情况的卫星遥感监测研究和应用几乎处于空白, 主要还集中在理论载畜量估算、集成地面实际载畜资料数据和气象数据等的载畜平衡评估预警或草地状况关联分析方面(刘爱军 等, 2003; 刘爱军和韩建国, 2007; 李刚 等, 2014; 梁天刚 等, 2019; Pearson 等, 2021)。随着亚米级高分辨率卫星遥感、人工智能等技术的发展, 研究建立基于高分卫星遥感的草原典型牧畜监测技术, 对实现牧畜精准监管、拓展卫星遥感应用、促进小(微)目标遥感监测技术发展等方面, 都具有十分重要的意义。

2 原理与技术方法



2.1 机理分析

在草原区, 牛羊等牧畜与周边草地、荒漠等背景具有明显的对比度差异, 在亚米级高分卫星图像上表现为较明显的小斑点, 且呈现聚集成群的“点群”分布特征。由于牧畜的持续移动性, 牧畜“点群”不会固定不变, 在不同时相的影像上处于不同的位置、呈现不同的形态。小灌丛(树木)、裸露石(砂、沙、土)块、凹坑、残存的小雪迹、收割后的草捆等地物在高分影像上也表现为斑点群分布特征, 但一般位置和形态固定不变, 或者形状比较规则, 或者在规模、颜色上与牧畜群有差异。牧畜群及易混淆地物的解译标志具体如表1所示。

表1 牧畜群遥感识别特征分析  
Table 1 Recognition feature of livestock

类型	项目	内容
羊群	识别特征	1.椒盐状斑点群分布,群的形状多样、没有规则,长宽一般不超过300 m,分布密度一般不超过3群/km <sup>2</sup>
		2.斑点比较小,通常1—3个像元大小,难以区分羊个体
		3.斑点色调取决于羊的毛色,亮毛色呈现亮斑点,暗毛色呈现暗斑点。羊多为白色、灰色等亮色,黑色、棕色较少
		4.在阳光较好时的遥感影像上,顺着阳光方向的斑点旁边常伴有小暗色阴影
		5.在时序上呈现不固定特征(即同一位置其他时刻没有斑点群或斑点群形态不一样,如下示例图)
羊群	示例图	
		A时刻GF-2影像:有斑点群
		
		B时刻GF-2影像:无斑点群
		1.斑点群分布,且斑点分布相对较分散,群的形状多样、没有规则,长宽一般不超过300 m,分布密度一般不超过2群/km <sup>2</sup>
		2.斑点比羊斑点稍大(通常2~4个像元大小),大多可以区分到个体
		3.斑点色调取决于牛马的毛色,亮毛色呈现亮斑点,暗毛色呈现暗斑点。牛马多为黑色、棕色等暗色,白色较少
		4.在阳光较好时的遥感影像上,顺着阳光方向的斑点旁边常伴有小暗色阴影(当牛马本身为暗色时,阴影不明显)
		5.在时序上呈现不固定特征(即同一位置其他时刻没有斑点群或斑点群形态不一样,如下示例图)
牛马群	示例图	
		A时刻GF-2影像:有斑点群
		
		B时刻GF-2影像:无斑点群

续表

类型	项目	内容
区分特征		在高分遥感影像上也呈现斑点群分布特征,但斑点群形态一般固定不变(如下示例图),或者斑点分布比较规则,或者在规模、颜色上有所差异
易混淆地物	示例图	
		
		A时刻 GF-2 影像:有斑点群                      B时刻 GF-2 影像:也有斑点群,且形态分布一样

在草原区，牧畜的“小斑点形态”、“点群分布”、“变化不固定”等多种特征，是基于高分卫星影像的草原区牧畜群遥感监测提取技术的重要机理基础。

2.2 总体技术流程

规则集、面向对象等传统方法可综合各种知识和规则，机理性强，但对成像条件、经验知识、特征参数等非常敏感，普适性、可迁移性差。深度学习等机器学习方法是基于样本的自学习训练，可以弥补传统方法的不足，然而在“小目标”检测中的精度通常相对较低（刘晓楠 等，2019；梁鸿 等，2021；Tong 等，2020；赵景波和杜保帅，2023；Tong和Wu，2022），且多针对车辆、舰船、飞机等相对规则的目标（姚红革 等，2020；马志龙和倪佳忠，2022；沙苗苗 等，2022）。牛羊等牧畜在高分遥感影像上尺寸更小，通常仅3或4个像元大小，是典型的“弱信号”、“微目标”，而且牧畜群形态、聚散程度等复杂多样、不规则，检测识别难度则更大，现有基于深度学习的“小目标”检测技术难以适用。因此，仅依赖深度学习方法或传统方法中的一种实现牧畜精准监测难度很大，需将两者的优势相结合。在此，提出一种基于多时相亚米级高分遥感影像、结合深度学习和面向对象方法、融合“斑点+群体”分布特征和“移动不固定”变化特征的典型牧畜高分卫星遥感监测方法。具体技术框架如图1所示。首先，获取至少两期亚米级高分遥感影像，进行几何校正、图像增强等预处理，实现牧畜目标信号有效增强。其次，一方面基于牧畜“群体”分布特征，以“群”为单元，利用深度学习方法，实现牧畜分布区域

即牧畜“群”的初提取；另一方面基于两期图像上牧畜斑点的变化、不固定特征，利用两期影像梯度差的变化检测方法和面向对象的识别提取方法，提取牧畜“斑点”的分布数据。再次，利用牧畜“斑点”分布数据对牧畜“群”分布数据进行校正增强，形成增强的牧畜“群”分布数据。最后，再利用人工修边，形成最终的牧畜“群”及其内部所包含的牧畜“斑点”精细分布数据。

2.3 基于深度学习的牧畜群分布初提取

基于牧畜群在高分遥感影像上呈现的点群分布特征，进行牧畜群分布的初提取。考虑牧畜本身尺度非常小，直接以“牧畜斑点”为基本单元进行样本标注和训练，标注难度和工作量大，在技术上也不可行。因此采用以“牧畜群”为基本单元进行样本标注和训练，一方面实现样本信号的增强，样本的尺寸、内部纹理等信息都得到增加；另一方面也充分利用牧畜的“群”分布特征，实现基于“牧畜群”的深度学习，从而提高模型精度。为此，在锡林郭勒草原，利用4景GF-2影像上人工解译提取的312个羊群斑块作为原始标注样本。标注时，尽量将牧畜群的轮廓勾勒精细准确（图2）。鉴于原始标注样本数量较少，通过对原始标注样本做11次30°旋转，以实现样本数据的丰富和增强。鉴于牧畜群的尺度一般不大于500 m，因此采用重叠度为256像元、大小为512×512像元的8比特位无符号图片，将原始标注样本及其旋转样本导出为训练样本集。

由于高分影像上牧畜尺度比较小，通常仅3或4个像元大小，且不像车辆、舰船、飞机、人脸等具有规则的形状信息和丰富的内部纹理信息，同



时牧畜群也不具备规则形态,因此对象检测 (Object Detection) 和实例分割 (Instance Segmentation) 等类别的深度学习模型难以有效适用。同时,通过

实验发现,采用像素分类模型 (Pixel Classification) 要好于对象检测模型,其中,UNet像素分类模型具有较好的训练效果 (图3)。

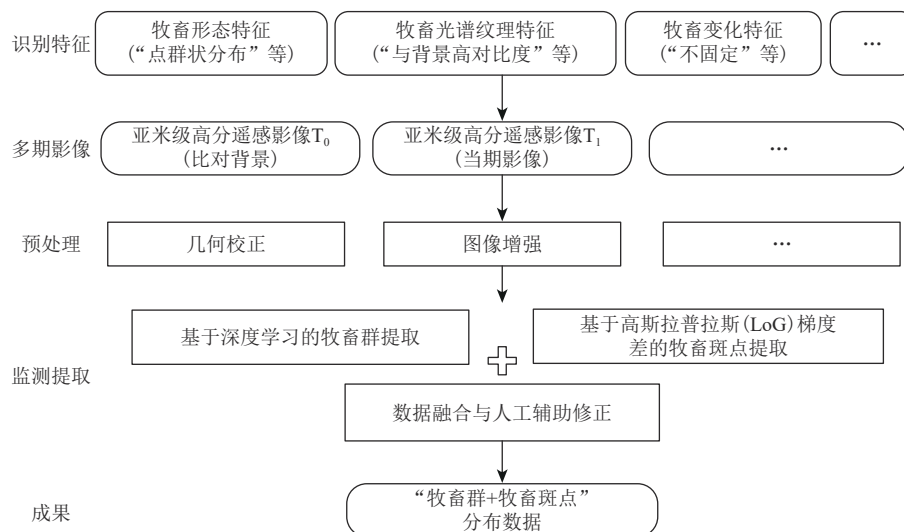


图1 总体技术路线图

Fig. 1 Technical roadmap



(a) 基于 GF-2 影像的典型羊群样本(时刻1)



(b) 基于 GF-2 影像的典型羊群样本(时刻2)

(a) Typical sample of sheep flock based on GF-2(at time 1) (b) Typical sample of sheep flock based on GF-2(at time 2)




图2 典型羊群样本(同一区域不同时刻)

Fig. 2 Typical sample of sheep flock(at different time in the same area)




图3 模型训练情况

Fig. 3 Analysis of the deep learning model training

基于训练好的模型,利用监测区域的同等分辨率的高分影像进行深度学习应用,输出最终监测区域的“牧畜群”分布初步检测数据。

## 2.4 基于高斯拉普拉斯 (LoG) 梯度差和面向对象的牧畜斑点提取方法

基于牧畜斑点群在两期影像上的变化特征,利用基于梯度差的变化分析方法和面向对象的方法提取潜在牧畜斑点分布数据。其主要流程如图4所示:

(1) 对两期数据进行滤波、灰度图和梯度图生成等预处理。通过对比分析发现,针对牧畜这种微目标,采用双边滤波算法 (Bilateral Filter) 效

果较好（图5），既能增强牧畜斑点，也能有效抑制噪声。将滤波后的图像转为灰度图（图6），然后利用高斯拉普拉斯（LoG）算子生成图像的梯度图。梯度图相对于原始图像，可以一定程度上屏蔽成像条件差异的影响，同时也能实现对羊斑点等弱信号的增强（图7）。通过研究和实验发现，在1 m分辨率高分影像上，5×5窗口的高斯拉普拉斯梯度算子对牧畜斑点增强效果较好，因为该窗口尺寸与大部分情形下牧畜斑点尺寸比较匹配。

（2）计算当期监测影像与比对影像的梯度差值，并选择梯度差大于（提取白色的羊等亮色牧畜目标）或小于（提取暗色的牛马等暗色牧畜目标）一定阈值的斑点对象作为潜在牧畜斑点。计算梯度差时，用当期影像像元的梯度减去该像元邻域内比对影像梯度的最大值（提取白色的羊等亮色牧畜目标）或最小值（提取暗色的牛马等暗色牧畜目标），以消除两期影像空间配准误差的影响。其计算公式为： $\Delta G_{i,j}=G_{i,j}^t-M(G_{N(i,j,r)}^o)$ ；其中 $G_{i,j}^t$ 表示行列号为*i*、*j*的像元在当期影像梯度值， $M(G_{N(i,j,r)}^o)$ 表示行列号为*i*、*j*的像元对应的半径为*r*的邻域范围内比对影像梯度的最大或最小值。阈

值可以基于梯度差图像的直方图统计数据进行设置（比如 $\mu+2\sigma$ 或者Top2.5%分位数等作为阈值），也可综合区域草地、牧畜的对比度差异等基于专家经验进行设置。

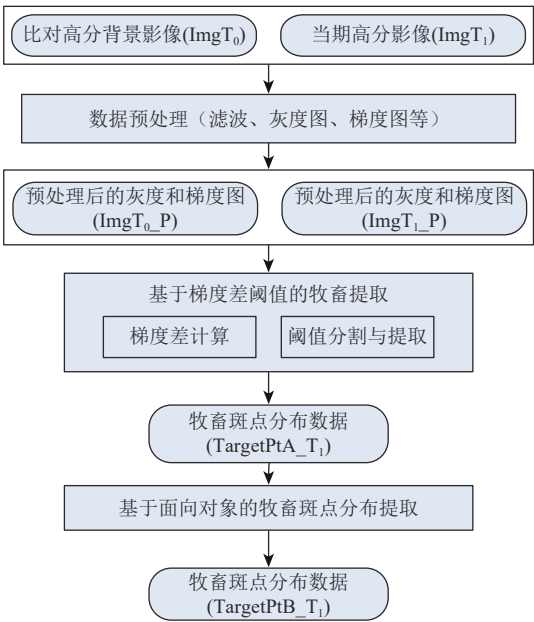


图4 基于LoG梯度差的牧畜斑点提取方法  
Fig. 4 Livestock block detection based on LoG Gradient Difference




图5 图像滤波(GF-2)  
Fig. 5 Image filtering(GF-2)

（3）利用面向对象的方法，从潜在牧畜斑点中，利用面积、邻居斑点数量、距最近邻居斑点距离、邻近斑点分布密度等特征，删除明显不符的斑点，形成“牧畜斑点”初步分布数据。

2.5 数据融合与人工辅助修正

利用牧畜斑点分布数据对深度学习检测的牧畜群分布数据进行校验和增强，主要是通过空间

叠加分析，基于包含斑点数量、面积、分布密度等特征，删除不符的牧畜群，形成增强的牧畜群分布数据，具体流程如图8。

由于深度学习提取的“牧畜群”矢量边界比较破碎、不够精准（图8），在此利用人工辅助修正，逐个对增强后的“牧畜群”矢量边界进行修边，形成最终的“牧畜群”分布成果数据；最后利用空间叠加分析，提取位于修正的“牧畜群”

边界内部的斑点,形成最终的“牧畜斑点”分布数据。在最终牧畜群和牧畜斑点数据的基础上,可基于斑点数量和面积,大体估算牧畜群的规模(即每个牧畜群中牧畜个体的大概数量),为区域实际载畜规模提供参考。




图6 灰度图

Fig. 6 Gray image




图7 LoG 梯度图

Fig. 7 LoG gradient image

此环节虽然需人工参与,但是通常牧畜群的分布密度不大,约1群/km<sup>2</sup>,一个监测区域内需要修正边界的牧畜群数量不多,人工参与的工作量在整个工作量中占比较小。

### 3 实验与分析

#### 3.1 实验区域

从应用角度,羊是最具代表性的牧畜类型,也是目前存栏量最大的牧畜类型;从科学角度,羊相对于牛马等体型更小,同等分辨率条件下遥感监测识别难度更大,因此选取羊作为实验对象。综合考虑监测对象类型和数据情况,选择位于内蒙古锡林浩特市的锡林郭勒草原保护区核心区所在区域为实验区域。考虑牧畜群移动变化特性,为保持牧场完整性和监测数据的可比性,基于GF-2遥感影像人工解译提取了核心区内草场边界作为具体的监测范围(面积约140.5 km<sup>2</sup>),详情如图9所示。实验数据采用覆盖该区域且成像时间间隔较近的2019-10-15和2019-11-08日两景GF-2遥感影像,以便结果数据之间的交互比对和验证。由于牧畜群的快速移动变化特性,基于卫星和地面的同步观测验证几乎不可能。为此,通过人工解译的方法提取了牧畜群的分布数据(2019-10-15影像有羊群35群,2019-11-08影像有羊群40群)、牧户的分布数据(约39个独立牧户点,1个集中牧户点),对实验结果进行评估验证。

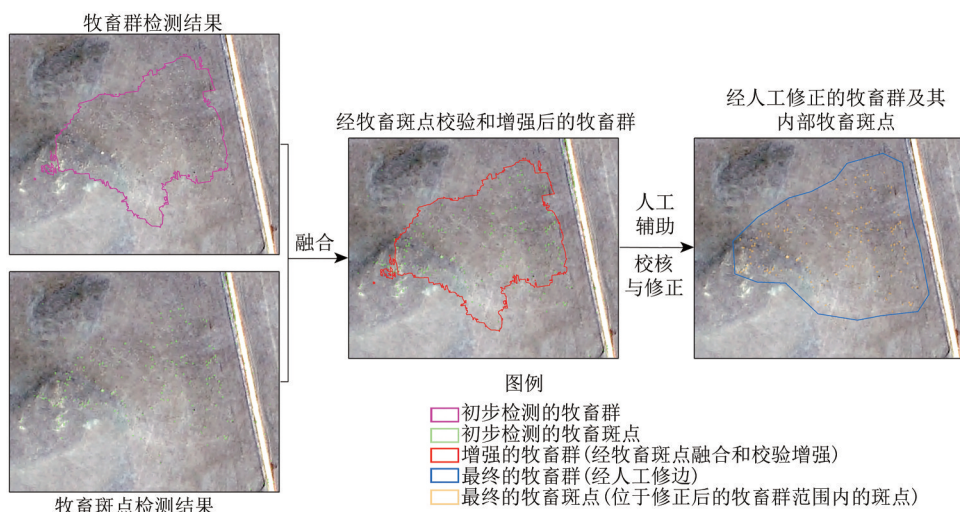


图8 数据融合与人工辅助修正流程

Fig. 8 Data fusion and manual correction process






图9 实验区域区位图  
Fig. 9 Map of the study area

3.2 实验结果

基于两期遥感影像，仅利用深度学习方法分

别检测出羊群 329 群和 868 群；再利用基于梯度差阈值提取的潜在羊斑点数据对深度学习提取的羊群数据进行校验增强，分别得到羊群 39 群和 48 群。如图 10 所示，以 2019-10-15 结果为例，图 10 (a) 中显示了原始深度学习的羊群检测结果和基于梯度差阈值提取的羊斑点检测结果，检出羊群数量和斑点数量都比较多；图 10 (b) 中显示了两融合增强后的综合检测结果，羊群数量缩减约 90%。

3.3 结果分析

由于模型检测的牧畜群与人工解译的牧畜群两者边界无法完全吻合，开展结果验证与精度分析时，采取以“群”为基本统计单元，通过空间叠加分析的方法进行评估分析：如果模型检测牧畜群与人工解译牧畜群之间存在空间重叠关系，即认定检测的牧畜群为正检出，否则为误检出或漏检出。此外，由于检测的牧畜群与人工解译的牧畜群为“ $n:m$ ”的对应关系，不适合利用 IoU 等综合精度进行评价，所以仅从正检、漏检、误检等 3 个方面分别进行精度评估分析。

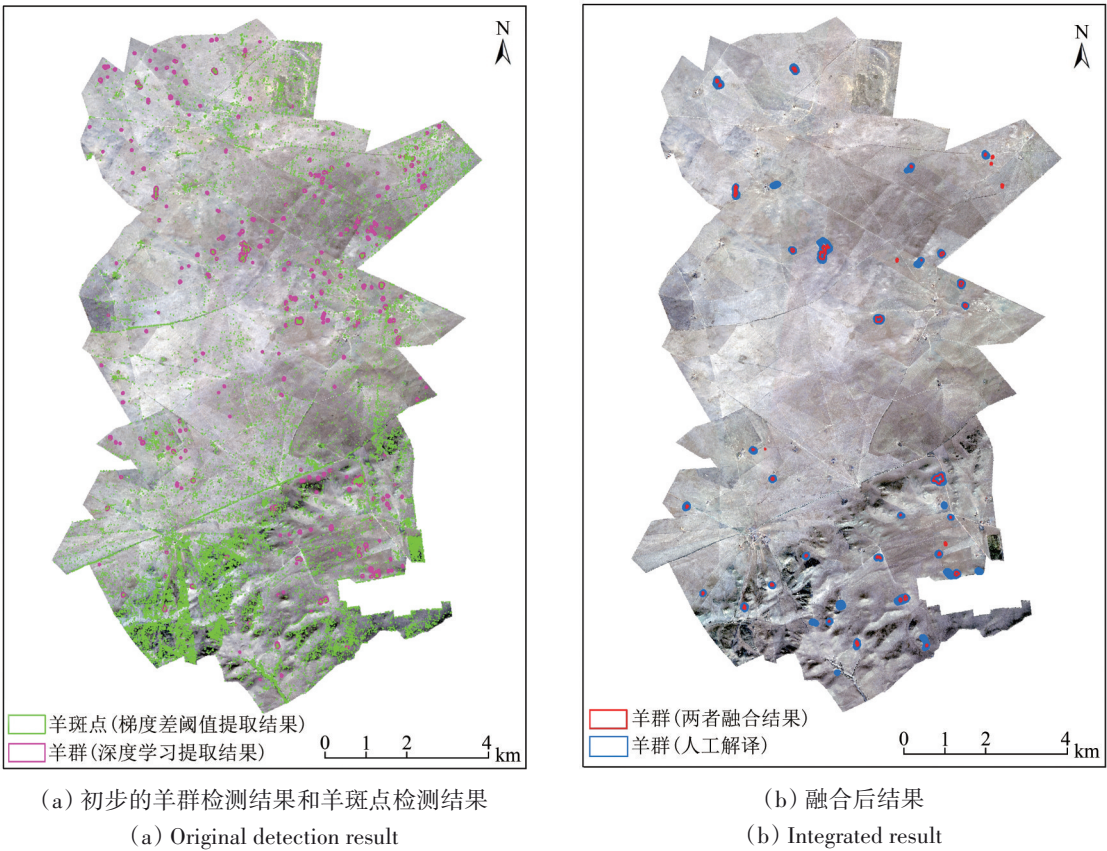


图 10 羊群检测结果分布数据(以 2019-10-15 结果为例)  
Fig. 10 The map of sheep flocks detection result (2019-10-15)

如表2、表3所示，分别为2019-10-15和2019-11-08两期影像的检测结果分析。数据显示，深度学习方法的检出率分别为0.886和0.775（平均约0.831），同时误检率分别为0.860和0.954（平均约0.907）。通过基于梯度差的牧畜斑点检测结果对深度学习的检测结果进行融合增强后，检出率分别为0.829和0.775（平均约0.802），误检率分别为0.154和0.333（平均约0.244）。两者增强融合后误检率由0.907大幅下降至0.244，检出率由0.831小幅下降至0.802，总体精度较好。

表2 2019-10-15影像的羊群检测结果分析			
Table 2 Analysis of the result (2019-10-15)			
指标		指标值	
真值 (人工解译)	总体情况	35 群	
	大型情况(外围包络面 面积>5000 m <sup>2</sup> )	24 群	
原始深度学 习检测结果	总体	329 群	
	正检出	总体情况	46 群(对应人工解译的 31 群)
		大型情况	38 群(对应人工解译的 23 群)
	漏检出	总体情况	35-31=4 群
		大型情况	24-23=1 群
	误检出	总体情况	329-46=283 群
		大型情况	0 群
	检出率	总体情况	31/35=88.6%
		大型情况	23/24=95.8%
	漏检率	总体情况	4/35=11.4%
		大型情况	1/24=4.2%
	误检率	总体情况	283/329=86.0%
		大型情况	0/(0+38)=0
综合检 测结果	总体	39 群	
	正检出	总体情况	33 群(对应人工解译的 29 群)
		大型情况	26 群(对应人工解译的 22 群)
	漏检出	总体情况	35-29=6 群
		大型情况	24-22=2 群
	误检出	总体情况	39-33=6 群
		大型情况	0 群
	检出率	总体情况	29/35=82.9%
		大型情况	22/24=91.7%
	漏检率	总体情况	6/35=17.1%
		大型情况	2/24=8.3%
	误检率	总体情况	6/39=15.4%
		大型情况	0/(0+26)=0

(1) 正检出情况：检出率总体约0.802，尤其对于大型羊群，检出率约0.937。方法对规模大、聚集度适中、斑点特征明显、周边背景简单的羊群检测效果更好，如图11所示。

表3 2019-11-08影像的羊群检测结果分析			
Table 3 Analysis of the result (2019-11-08)			
指标		指标值	
真值 (人工解译)	总体情况	40 群	
	大型情况(外围包络面 面积>=5000 m <sup>2</sup> )	23 群	
原始深度学 习检测 结果	总体	868 群	
	正检出	总体情况	40 群(对应人工解译的 31 群)
		大型情况	31 群(对应人工解译的 22 群)
	漏检出	总体情况	40-31=9 群
		大型情况	23-22=1 群
	误检出	总体情况	868-40=828 群
		大型情况	7 群
	检出率	总体情况	31/40=77.5%
		大型情况	22/23=95.7%
	漏检率	总体情况	9/40=22.5%
		大型情况	1/23=4.3%
	误检率	总体情况	828/868=95.4%
		大型情况	7/(7+31)=18.4%
综合检测 结果	总体	48 群	
	正检出	总体情况	32 群(对应人工解译的 31 群)
		大型情况	24 群(对应人工解译的 22 群)
	漏检出	总体情况	40-31=9 群
		大型情况	23-22=1 群
	误检出	总体情况	48-32=16 群
		大型情况	4 群
	检出率	总体情况	31/40=77.5%
		大型情况	22/23=95.7%
	漏检率	总体情况	9/40=22.5%
		大型情况	1/23=4.3%
	误检率	总体情况	16/48=33.3%
		大型情况	4/(4+24)=14.3%

(2) 漏检出情况：漏检率总体约0.198。如图12所示，漏检出的大多位于牧户房子、道路等复杂背景周边，多为小规模羊群（图12）或聚集度较高的羊群（图12（c））。漏检出的主要原因是背景复杂导致牧畜斑点特征不明显，同时模型训练时该情形的训练样本少，降低了深度学习模型对该情形羊群的检测精度。后续可以通过增加该情形的训练样本数量、复杂背景区域对比度拉伸等方法进一步提升精度。

(3) 误检出情况：误检率总体约0.244。误检出的大多为裸露的小岩石、砂（砂、土）堆或者残存的雪迹等易混淆地物，其在图像上也表现为斑



点群形态, 且在不同期影像上由于成像角度、光照等差异也偶尔会呈现梯度变化, 从而造成误检出 (图 13)。后续可通过增加对两期检测的牧畜群

数据、牧畜斑点数据的交互校验和融合, 剔除两期均被检出, 且重叠度较高、斑点群形态分布相近的易混淆地物, 实现精度的进一步提高。

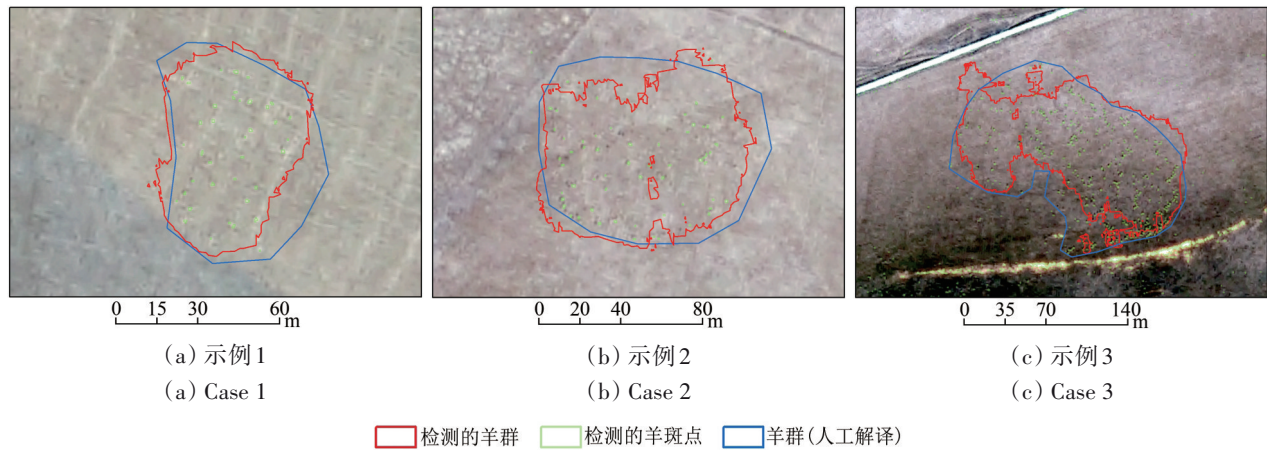


图 11 正检出的羊群示例(群正检出、且斑点正检出)

Fig. 11 Positive detection case(positive detection both by sheep flock detection and blob detection)




图 12 漏检出的羊群示例(群漏检出, 但斑点正检出)

Fig. 12 Missed detection case(sheep flock missed detection and sheep blob positive detection)

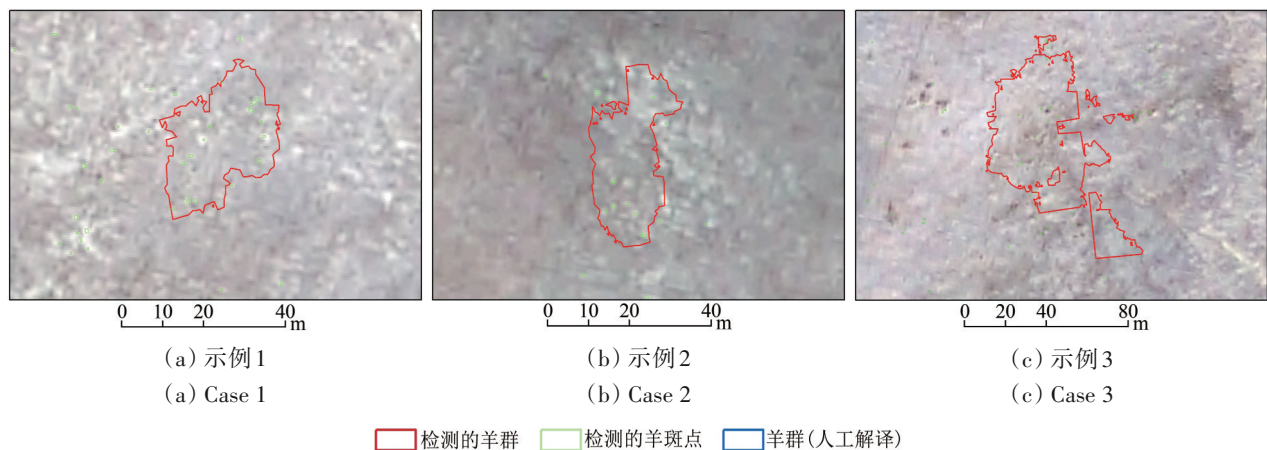


图 13 误检出的羊群示例(群误检出, 且斑点误检出)

Fig. 13 False detection case(sheep flock false detection and sheep blob false detection)

## 4 结 论

本研究面向草原区牧畜活动监管、草畜平衡、草原生态环境保护监管等相关领域的迫切需求,针对牧畜“小(微)目标”监测的难点痛点,综合利用牧畜“点”特征、“群”特征、“移动不固定”等多种特征以及融合深度学习、面向对象等多种技术方法,构建了一种多尺度特征和多模型方法相融合的牧畜高分卫星遥感监测技术方法。它通过对牧畜弱信号的有效增强,“牧畜群”和“牧畜斑点”的分阶段检测与相互融合增强,实现了牧畜群分布、牧畜斑点分布和牧畜群规模的监测提取。虽然目前精度仍不够高、实验范围较小,但后续可通过补充不同类型、不同时刻、不同区域、不同形态等不同情形的牧畜群样本,进一步提高模型的精度和普适性。本研究初步实现了基于亚米级卫星影像的直观的“点数”式、精细化牧畜监测,可为草原区载畜情况的监测监管(特别是禁牧区或禁牧时节禁牧落实情况的监管)提供技术支持。同时,本研究中相关的弱信号图像增强、基于LoG梯度差的变化分析、基于数据驱动的深度学习与基于机理驱动的面向对象相结合等技术方法和策略也可为其他典型“小(微)目标”的遥感监测提供借鉴和参考。因此,无论是在技术创新还是业务应用方面都具有十分重要的意义。

目前本研究还处于初期阶段,后续亟需在影像空间分辨率、区域和季节、羊的种类、羊的年龄、羊群聚集度、羊群规模、区域背景复杂度等对模型检测精度影响机理和影响程度的量化评估分析,大范围应用中不同牧畜群辨识和去重,同步观测难的情况下如何利用无人机“准同步观测”和地面牧场区划数据进行“同名牧群”验证和标定,牧畜群中牧畜个体数量精准计算等多个方面开展更深入细致的研究。

## 参考文献(References)

Fu G C, Yang W and Song Z H. 2009. Preliminary discussion on current situation of meadows and main reasons of degradation of China. *Inner Mongolia Environmental Sciences*, 21(4): 32-35 (付国臣, 杨韞, 宋振宏. 2009. 我国草地现状及退化的主要原因. *内蒙古环境科学*, 21(4): 32-35) [DOI: 10.3969/j.issn.1007-0370.2009.04.008]

Guo X J, Shao Q Q, Yang F, Li Y Z, Wang Y C and Wang D L. 2019.

Using UAV remote sensing for a population census of blue sheep (*Pseudois nayaur*) in Maduo county, source region of the Yellow River. *Journal of Natural Resources*, 34(5): 1054-1065 (郭兴健, 邵全琴, 杨帆, 李愈哲, 汪阳春, 王东亮. 2019. 无人机遥感调查黄河源玛多县岩羊数量及分布. *自然资源学报*, 34(5): 1054-1065)

Institute of Botany, The Chinese Academy of Sciences. 2020. Method and system for recognizing cattle and sheep based on remote sensing image. China, 202010111366.1 (中国科学院植物研究所. 2020. 一种基于遥感影像识别牛羊的方法和系统. 中国, 202010111366.1)

Li G, Sun W L, Zhang H and Gao C Y. 2014. Balance between actual number of livestock and livestock carrying capacity of grassland after added forage of straw based on remote sensing in Tibetan Plateau. *Transactions of the Chinese Society of Agricultural Engineering*, 30(17): 200-211 (李刚, 孙伟琳, 张华, 高春雨. 2014. 基于秸秆补饲的青藏高原草地载畜量平衡遥感监测. *农业工程学报*, 30(17): 200-211) [DOI: 10.3969/j.issn.1002-6819.2014.17.026]

Liang H, Wang Q W, Zhang Q and Li C X. 2021. Small object detection technology: a review. *Computer Engineering and Applications*, 57(1): 17-28 (梁鸿, 王庆玮, 张千, 李传秀. 2021. 小目标检测技术研究综述. *计算机工程与应用*, 57(1): 17-28) [DOI: 10.3778/j.issn.1002-8331.2009-0099]

Liang T G, Cui X, Feng Q S, Wang Y and Xia W T. 2019. Remotely sensed dynamics monitoring of grassland aboveground biomass and carrying capacity during 2001-2008 in Gannan pastoral area. *Acta Prataculturae Sinica*, 18(6): 12-22 (梁天刚, 崔霞, 冯琦胜, 王莺, 夏文韬. 2019. 2001-2008年甘南牧区草地上生物量与载畜量遥感动态监测. *草业学报*, 18(6): 12-22) [DOI: 10.3321/j.issn:1004-5759.2009.06.002]

Liu A J and Han J G. 2007. The study of method about monitoring grazing intensity in Xilingol rangeland using RS data. *Chinese Journal of Grassland*, 29(2): 70-74 (刘爱军, 韩建国. 2007. 利用遥感技术监测锡林郭勒天然草原利用强度方法初探. *中国草地学报*, 29(2): 70-74) [DOI: 10.3969/j.issn.1673-5021.2007.02.013]

Liu A J, Xing Q, Gao W, Yang G Q, Su R N, Ha S and An M Z. 2003. Productivity monitoring and livestock capacity calculation of natural grassland in Inner Mongolia in 2003. *Inner Mongolia Prataculture*, 15(4): 1-3 (刘爱军, 邢旗, 高娃, 杨国奇, 苏日娜, 哈斯, 安卯柱. 2003. 内蒙古2003年天然草原生产力监测及载畜能力测算. *内蒙古草业*, 15(4): 1-3)

Liu X N, Wang Z P, He Y T and Liu Q. 2019. Research on small target detection based on deep learning. *Tactical Missile Technology*, (1): 100-107 (刘晓楠, 王正平, 贺云涛, 刘倩. 2019. 基于深度学习的小目标检测研究综述. *战术导弹技术*, (1): 100-107) [DOI: 10.16358/j.issn.1009-1300.2019.8.522]

Ma Z L and Ni J Z. 2022. A vehicle detection method for remote sensing image. *Beijing Surveying and Mapping*, 36(5): 547-551 (马志龙, 倪佳忠. 2022. 一种遥感图像车辆检测方法. *北京测绘*, 36(5): 547-551) [DOI: 10.19580/j.cnki.1007-3000.2022.05.004]

Pearson C, Filippi P and González L A. 2021. The relationship between satellite-derived vegetation indices and live weight changes of beef cattle in extensive grazing conditions. *Remote Sensing*, 13(20):

- 4132 [DOI: 10.3390/rs13204132]
- Peng J B, Wang D L, Liao X H, Shao Q Q, Sun Z G, Yue H Y and Ye H P. 2020. Wild animal survey using UAS Imagery and deep learning: modified faster R-CNN for kiang detection in Tibetan Plateau. *ISPRS Journal of Photogrammetry and Remote Sensing*, 169: 364-376 [DOI: 10.1016/j.isprsjprs.2020.08.026]
- Sha M M, Li Y and Li A. 2022. Multiscale aircraft detection in optical remote sensing imagery based on advanced Faster R-CNN. *National Remote Sensing Bulletin*, 26(8): 1624-1635 (沙苗苗, 李宇, 李安. 2022. 改进 Faster R-CNN 的遥感图像多尺度飞机目标检测. *遥感学报*, 26(8): 1624-1635) [DOI: 10.11834/jrs.20219365]
- Shao Q Q, Guo X J, Li Y Z, Wang Y C, Wang D L, Liu J Y, Fan J W and Yang F. 2018. Using UAV remote sensing to analyze the population and distribution of large wild herbivores. *Journal of Remote Sensing*, 22(3): 497-507 (邵全琴, 郭兴健, 李愈哲, 汪阳春, 王东亮, 刘纪远, 樊江文, 杨帆. 2018. 无人机遥感的大型野生食草动物种群数量及分布规律研究. *遥感学报*, 22(3): 497-507) [DOI: 10.11834/jrs.20187267]
- Tong K, Wu Y Q and Zhou F. 2020. Recent advances in small object detection based on deep learning: a review. *Image and Vision Computing*, 97: 103910 [DOI: 10.1016/j.imavis.2020.103910]
- Tong K and Wu Y Q. 2022. Deep learning-based detection from the perspective of small or tiny objects: a survey. *Image and Vision Computing*, 123: 104471 [DOI: 10.1016/j.imavis.2022.104471]
- Wang K, Wu P, Xuan C Z, Yu W B and Su H. 2020. Progress in monitoring the grazing information of livestock. *Journal of Nanjing Agricultural University*, 43(3): 403-413 (王奎, 武佩, 宣传忠, 于文波, 苏赫. 2020. 放牧家畜牧食信息监测的研究进展. *南京农业大学学报*, 43(3): 403-413) [DOI: 10.7685/jnau.201906052]
- Wang M T and Li D Q. 2017. Analysis of animal husbandry economy development in Northern Tibet Plateau based on the statistical data and investigation of 111 shepherds. *Journal of Shanxi Agricultural University (Social Science Edition)*, 16(12): 18-24 (王美兔, 李迪强. 2017. 基于统计数据及 111 户牧户调查的藏北高原畜牧经济发展探析. *山西农业大学学报(社会科学版)*, 16(12): 18-24) [DOI: 10.3969/j.issn.1671-816X.2017.12.003]
- Wang Q, Ma L L, Wang N, Wang Y H, Li J M, Teng G E, Ouyang G Z, Zhang Y P, Ao L, Niu Y F, Zheng Q C and Li Z Y. 2021. Automatic grassland livestock quantity accounting method for optical images acquired by tethered balloon. *Radio Engineering*, 51(12): 1485-1492 (汪琪, 马灵玲, 王宁, 王宇航, 黎荆梅, 腾格尔, 欧阳光洲, 张远平, 敖磊, 牛沂芳, 郑青川, 李子扬. 2021. 系留球载光学影像的草原牲畜数量自动核算方法. *无线电工程*, 51(12): 1485-1492) [DOI: 10.3969/j.issn.1003-3106.2021.12.015]
- Wang Q, Sun B P and Zhao T N. 2007. Investigation and research of forage yield and livestock capacity in Yanchi county. *Research of Soil and Water Conservation*, 14(4): 109-112 (王庆, 孙保平, 赵廷宁. 2007. 盐池县天然草场产草量与载畜量调查研究. *水土保持研究*, 14(4): 109-112)
- Yao H G, Wang C, Yu J, Bai X J and Li W. 2020. Recognition of small-target ships in complex satellite images. *Journal of Remote Sensing*, 24(2): 116-125 (姚红革, 王诚, 喻钧, 白小军, 李蔚. 2020. 复杂卫星图像中的小目标船舶识别. *遥感学报*, 24(2): 116-125) [DOI: 10.11834/jrs.20208238]
- Zhang X S, Zhang M J, Wang L, Luo H L and Li J. 2019. Research status and development analysis of wearable information monitoring technology in animal husbandry. *Transactions of the Chinese Society for Agricultural Machinery*, 50(11): 1-14 (张小栓, 张梦杰, 王磊, 罗海玲, 李军. 2019. 畜牧养殖穿戴式信息监测技术研究现状与发展分析. *农业机械学报*, 50(11): 1-14) [DOI: 10.6041/j.issn.1000-1298.2019.11.001]
- Zhao J B and Du B S. 2023. Development of small target detection technology based on deep learning. *Electronics Optics and Control*, 30(2): 63-70, 74 (赵景波, 杜保帅. 2023. 基于深度学习的小目标检测技术发展. *电光与控制*, 30(2): 63-70, 74) [DOI: 10.3969/j.issn.1671-637X.2023.02.012]

## Remote sensing monitoring method of livestock in grassland based on multi-scale features and multi-models fusion

XIAO Rulin<sup>1</sup>, GAO Jixi<sup>1</sup>, LIU Aijun<sup>2</sup>, HOU Peng<sup>1</sup>, ZHANG Wenguo<sup>1</sup>, YANG Yong<sup>2</sup>, LI Yunbao<sup>3</sup>, FU Zhuo<sup>1</sup>, JIN Chuanping<sup>1</sup>, YANG Xu<sup>1</sup>, ZHENG Shuhua<sup>2</sup>, YIN Shoujing<sup>1</sup>

1. Satellite Application Center for Ecology and Environment of MEE, Beijing 100094, China;

2. Inner Mongolia Autonomous Region Grassland Remote Sensing and Emergency Technical Reserve Key Laboratory, Hohhot 010020, China;

3. Information Center of Ecology and Environment of Mianyang, Mianyang 621050, China

**Abstract:** China is a large country of grassland and animal husbandry. Overloading and overgrazing is one of the main causes of grassland degradation in China. To protect the grassland, it is necessary to precisely monitoring livestock carrying capacity, which is the key to evaluation and control grass-livestock balance. However, traditional method of livestock carrying capacity such as hierarchical statistics, sampling field survey and online camera monitoring is whether time-consuming, labor-intensive, costly or poor quality. So it is very urgent to find a kind of efficient and precise monitoring method of livestock carrying capacity in grassland.

To achieve this goal, this research proposes an efficient and precise monitoring method of the livestock in grassland by using of sub-



meter resolution satellite image. The method not only fuses multi-scale features of livestock in sub-meter resolution satellite image such as “blob feature”、“flock feature”、“moving feature”, but also integrates deep learning technology and object oriented recognition technology. Firstly, considering that the livestock in satellite image is a kind of small (tiny) target, it uses kinds of image enhancement method such as bi-lateral filtering and Laplace of Gaussian (LoG) operator to enhance the weak livestock signal successfully. Secondly, in consideration of “flock feature” of livestock flock, it use a kind of “livestock flock detection model” based on deep learning technology to get the rough distribution area of livestock flocks. Thirdly, in consideration of “blob feature” and “moving feature” of livestock, it use a kind of “livestock blob detection method” based on LoG Gradient Difference and object oriented recognition technology to get the possible livestock blobs. Finally, by integrating the detecting result of both livestock flocks and livestock blobs, it uses the livestock blobs result to enhance and verify the livestock flocks result, and the enhanced and verified livestock flocks and the livestock blobs within them is finally get by using some simple manually revising work.

Through an experiment in Xilingol grassland, it is found that the approach has good effect on livestock flock detection: with positive detection rate about 0.802 and false detection rate about 0.244, especially as to big livestock flock, the positive detection rate is up to 0.937, the false detection rate is low to 0.072.

It is very helpful for the monitoring and supervision of livestock flock in grassland, and can also provide reference for remote sensing monitoring of other “small (tiny) targets”. It is of great significance both in terms of technological innovation and business application. It makes a litter effort in promoting the livestock satellite remote sensing monitoring into an intuitive and fine monitoring era- “Number-Counting Era”.

**Key words:** livestock, remote sensing, livestock carrying, grassland, small (tiny) target

**Supported by** National Key Research and Development Program of China (No. 2021YFB3901102)