

引用格式: Zhang Yonghong, Cao Haixiao, Kan Xi. Snow Cover Recognition for Xinjiang based on Fusion of FY-4A/AGRI Spatial and Temporal Characteristics[J]. Remote Sensing Technology and Application, 2020, 35(6): 1337-1347. [张永宏, 曹海啸, 阚希. 基于FY-4A/AGRI时空特征融合的新疆地区积雪判识[J]. 遥感技术与应用, 2020, 35(6): 1337-1347.]
doi:10.11873/j.issn.1004-0323.2020.6.1337

基于FY-4A/AGRI时空特征融合的新疆地区 积雪判识

张永宏^{1,3}, 曹海啸¹, 阚希²

(1. 南京信息工程大学 自动化学院, 江苏 南京 210044;

2. 南京信息工程大学 滨江学院, 江苏 无锡 214105;

3. 南京信息工程大学江苏省大气环境与装备技术协同创新中心, 江苏 南京 210044)

摘要: 高时间分辨率的积雪判识对于新疆牧区农牧业发展和雪灾预警具有重要作用, 针对已有积雪产品易受复杂地形地貌、下垫面类型以及云遮蔽的影响, 导致积雪判识精度降低的问题, 提出一种利用深度学习方法对风云4号A星多通道辐射扫描计(AGRI)数据与地理信息数据进行多特征时序融合的积雪判识方法: 以多时相FY-4A/AGRI多光谱遥感数据, 以及高程、坡向、坡度和地表覆盖类型等地形地貌信息作为模型输入, 以Landsat 8 OLI提取的高空间分辨率积雪覆盖图作为“真值”标签, 构建并训练基于卷积神经网络的积雪判识模型, 从而有效区分新疆复杂地形与下垫面地区的云、雪以及无雪地表, 最终得到逐小时积雪覆盖范围产品。经数据集和2019年地面气象站实测雪盖验证, 该方法精度高于国际主流MODIS逐日积雪产品MOD10A1和MYD10A1, 显著降低云雪误判率。

关键词: 新疆; 深度学习; 积雪; FY-4A/AGRI; MOD10A1

中图分类号: P237 **文献标志码:** A **文章编号:** 1004-0323(2020)06-1337-11

1 引言

积雪是冰冻圈的重要组成部分^[1-2], 是研究地球辐射平衡、全球气候变化以及生态环境的重要依据, 积雪的高反射率、低导热率特性不仅会影响局部天气变化, 同时也影响到地表的辐射平衡^[2]。不仅如此, 积雪对于新疆地区的农牧业发展和水资源供给等方面具有不可估量的作用^[3,4]: 过于频繁的降雪会引起积雪大范围、长时间覆盖牧区草场, 导致畜牧无法觅食, 造成“白灾”^[5]; 另一方面, 春季积雪消融期间, 极易引发融雪性洪水, 给当地的农牧业生产和人民生活带来严重影响^[6]。然而新疆积雪监

测站点分布稀疏, 并且大多分布在城镇及附近地区^[6-8], 导致地面积雪观测资料在新疆地区的空间与地理代表性不足。因此高时空分辨率的遥感积雪产品对新疆地区具有重要作用。

基于卫星遥感技术的积雪监测具有时空分辨率高、监测范围广等优势, 已经成为积雪监测的主流方法^[9]。积雪遥感识别的难点在于云与雪的辨识, 主要是因为积雪与云的光谱反射率特征十分相似, 在可见光与大部分近红外波段都具有相当高的反射率。已有的积雪监测方法普遍采用归一化差分积雪指数(NDSI)^[10]作为积雪判识的主要依据。然而已有研究表明^[11-14], 受云的不同相态, 以及不同

收稿日期: 2020-07-31; 修订日期: 2020-11-10

基金项目: 国家自然科学基金面上项目“基于天气系统自动识别的新疆牧区雪灾遥感监测与预警研究”(41875027)。

作者简介: 张永宏(1974—), 男, 山东临沂人, 教授, 主要从事大气遥感检测、图像处理分析研究。E-mail: zyh@nuist.edu.cn

通讯作者: 阚希(1987—), 男, 江苏无锡人, 讲师, 博士, 主要从事遥感图像处理与深度学习。E-mail: kanxi@nuist.edu.cn

地表覆盖类型等影响,部分种类的云与雪在短红外波段光谱特征出现类似,形成同谱异质现象,因此仅凭NDSI以及红外波段数据无法有效区分云与雪盖^[15]。这在地形地貌、地表覆盖类型复杂多样的新疆地区尤其明显。

随着卫星遥感技术的快速发展,遥感大数据时代已经到来^[16],可用的高时空分辨率卫星资源日益丰富,特别是我国新一代地球静止轨道气象卫星风云四号A星(FY-4A)正式投入使用,其搭载的多通道辐射扫描计(AGRI)在可见光与近红外通道可达2 km及以上的空间分辨率,并每15 min扫描整个半球全圆盘,已经可以满足大范围、高时间分辨率积雪监测的要求^[17]。近年来,基于深度学习的大数据与人工智能技术引发了各行各业的技术革新,深度学习的最大优势在于它能够有效地对高维、海量数据进行特征提取与分类,因此深度学习方法可以作为处理遥感大数据的有效手段^[18],也适用于新疆地区的积雪判识问题。

深度学习方法按照训练方式的不同大致可以分为两类:①有监督的深度学习架构,如全连接神经网络(Full Connect Neural Networks, FNN)、深度卷积神经网络^[19](Convolutional Neural Networks, CNN)、循环神经网络^[20](Recurrent Neural Networks, RNN)以及长短时记忆神经网络^[21](Long Short Term Memory Networks, LSTM);②无监督或半监督的深度学习架构,如深度置信网络^[22](Deep Belief Network, DBN)以及层叠去噪自编码器^[23](Stacked Denoising Auto-Encoders, SDAE)。而卷积神经网络因其强大的自适应特征提取能力^[19],已经广泛应用于各个领域,其中一维卷积常用于序列信号,如自然语言处理、传感器时序信号分析等;二维卷积通常用于平面图的特征提取,如计算机视觉和图像处理;三维卷积常用于医学和视频处理。

利用FY-4A/AGRI资料高时间分辨率优势,结合多种地理信息,构建多源特征和时序信息融合的积雪判识模型,主要分为3个步骤:

(1)使用高空间分辨率(30 m)的Landsat 8 OLI遥感资料提取积雪信息,并与AGRI遥感图像地理位置配准,以此制备FY-4A/AGRI应被识别为积雪像素的“真值”标签。

(2)综合多时相FY-4A/AGRI光谱遥感数据,与地理高程、坡向、坡度和下垫面类型等多种地理

特征信息,构建多源时空融合的训练样本数据集。

(3)使用深度学习方法对积雪点周围像素块进行积雪特征的提取。并从时空维度自适应提取积雪特征进行新疆地区的积雪判识,并生成小时级积雪覆盖范围产品。

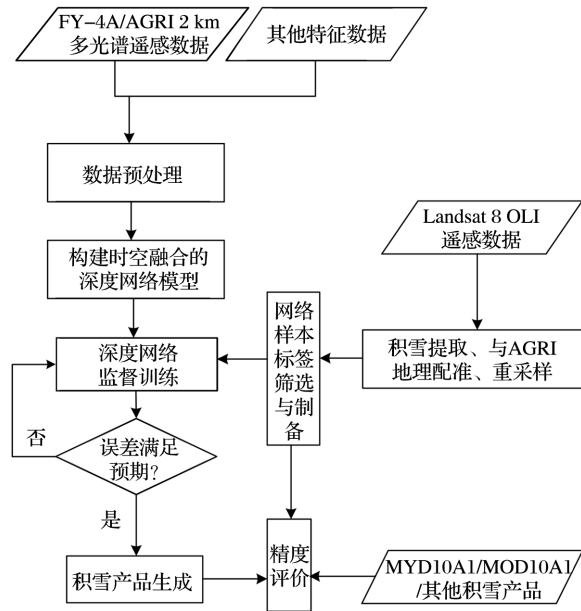


图1 技术流程图

Fig.1 Flow chart of method

2 研究区域与数据处理

2.1 研究区域概况

新疆位于亚欧大陆中部,中国西北边陲,地貌轮廓总的特点是山脉与盆地相间排列,俗称“三山夹两盆^[24]”。新疆是我国三大稳定积雪区之一,冬季寒冷漫长,积雪期一般从当年11月份到次年3月份,夏季炎热短促,春秋季节天气变化剧烈。受地形、地貌和大气环流的影响,积雪期以天山为界北多南少,天山山区和新疆北部阿勒泰、塔城和伊犁河谷的大部份地区是新疆积雪丰富的区域,也是积雪期相对较长的区域。本文样本标签数据来源如图2,涉及2018年9月至2020年3月间不同地点和相同地点不同时间Landsat 8 OLI拍摄的86景影像。

2.2 AGRI遥感数据预处理

FY-4A/AGRI遥感数据预处理包括可见光近红外波段定标、几何校正、矢量裁剪等几个重要处理环节。其中可见光近红外波段的定标主要包括辐射定标和太阳高度角订正;几何校正采用的是地理位置查找表(Geographic Lookup Table, GLT)进行变换并投影为0.02°等经纬度影像,以此完成AGRI 2 km 7通道遥感图像所有像元与地理空间位

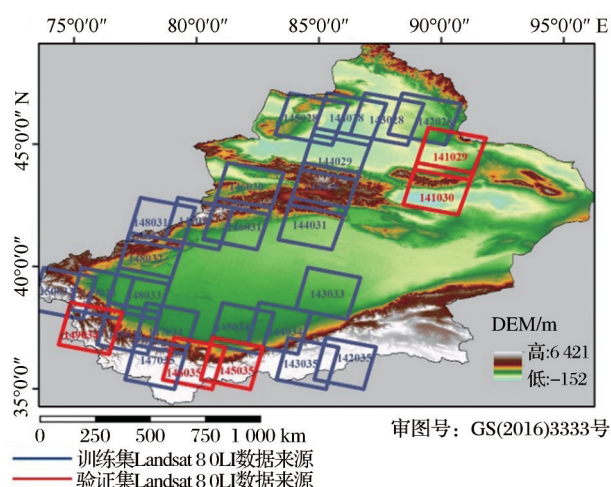


图2 新疆地理高程和标签数据来源

Fig.2 Xinjiang Digital Elevation Model and label data sources

置的匹配;矢量裁剪则是利用新疆地区矢量文件构建感兴趣区域,并从原始大范围图像掩膜中得到最终研究区域(图3)。




图3 AGRI遥感数据预处理流程

Fig.3 AGRI Multispectral remote sensing data pre-processing

2.3 数据集的建立

2.3.1 FY-4A/AGRI 多光谱遥感数据

FY-4A 是我国第二代地球静止轨道(GEO)定量遥感卫星的首颗星,作为新一代静止轨道气象卫星,其功能和性能都实现了跨越式的发展,多通道辐射扫描计(AGRI)是其主要载荷之一,通过精密的双扫描镜可以实现精确和灵活的二维指向^[23],实现分钟级的区域快速扫描。辐射成像通道由FY-2G星的5个增加到14个,覆盖了可见光、短红外波、中波红外和长波红外等波段。本文使用AGRI 2 km分辨率的7通道光谱信息作为深度学习神经网络的输入之一,具体信息如表1所示。

2.3.2 其他特征数据

(1)地理信息数据,包括数字高程、坡向和坡度、地表覆盖类型。数字高程采用GTOPO30(Global 30 Arc-Second Elevation)作为高程数据,坡向和坡度数据由高程数据计算得到,地表覆盖类型数据来

表1 AGRI 2 km 通道信息

Table 1 AGRI 2 km Channel Information

通道序号	中心波长/ μm	位深	通道分辨率
1	0.47	12	10 992×10 992
2	0.65	12	21 984×21 984
3	0.83	12	10 992×10 992
4	1.37	12	5 496×5 496
5	1.61	12	5 496×5 496
6	2.22	12	5 496×5 496
7	3.72	12	5 496×5 496

源于国家基础地理信息中心发布的全球30 m分辨率地表覆盖类型遥感制图(GlobalLand30),四者通过ENVI5.3重采样为2 km空间分辨率。

(2)归一化差分积雪指数(NDSI),用于区别云雪在AGRI通道1(0.47 μm)和通道5(1.61 μm)反射率差异。

$$\text{NDSI} = \frac{R_{0.47} - R_{1.61}}{R_{0.47} + R_{1.61}} \quad (1)$$

(3)归一化植被指数(NDVI),用于反映植被覆盖情况,负值表示地面覆盖为云、水、雪等,涉及通道5(1.61 μm)和通道3(0.83 μm)。

$$\text{NDVI} = \frac{R_{1.61} - R_{0.83}}{R_{1.61} + R_{0.83}} \quad (2)$$

2.3.3 真值标签的制备

影响使用有监督的深度学习方法进行积雪判识最关键的因素之一就是真值标签的制备,不准确的标签真值会直接造成模型准确率的降低,而遥感大数据时代不同的卫星探测器性能侧重点各不相同,时间和空间分辨率很难同时具备,有监督的机器学习方法中对真值标签的要求非常高,所以具有准确且大量的样本真值标签也是本文重点研究领域,本文标签真值分为3类,分别为积雪、云、裸地。其中积雪标签使用空间分辨率较高的Landsat 8 OLI陆地成像仪拍摄的影像进行积雪的提取,云标签选择非积雪季人工目视方法标注,其余为非云雪的裸地,样本标签三者比例均衡。积雪标签提取方法如下:

(1)使用Google Earth Engine(GEE)地理信息数据处理可视化平台,该平台包含大量主流卫星图像和地理空间数据集,选择Landsat 8 OLI影像云覆盖低于10%的提取积雪标签,提取算法如下。

$$\begin{cases} \text{NDSI} > 0.4 \\ \text{NDVI} < -0.035 \\ R_{0.55\mu\text{m}} > 0.10 \\ R_{0.65\mu\text{m}} > 0.07 \\ R_{0.86\mu\text{m}} > 0.11 \end{cases} \quad (3)$$

(2)将Landsat 8 OLI 30 m积雪真值投影成

WGS84 地理坐标系,并与 AGRI 2 km 预处理之后的遥感数据按照经纬度进行地理配准,需要指出的是 AGRI 的时间分辨率为 15 min,与 OLI 积雪真值地理位置相同区域的 AGRI 遥感影像时间误差最多为 7.5 min,在此时间内积雪变换非常小,可以忽略

由于成像时间不同造成的积雪消融误差。

(3)将 Landsat 8 OLI 30 m 空间分辨率积雪真值图重采样为 2 km 空间分辨率,采样方式为在每个 $2\text{ km} \times 2\text{ km}$ 像元内 OLI 积雪像元超过一半即为标签真值积雪像元(图 4)。




图 4 2018 年 10 月 2 日轨道行列号为 035146 的 Landsat 8 OLI 影像积雪提取方式

Fig.4 Snow extraction method of Landsat 8 OLI image with track number 035146 on October 2, 2018

3 研究方法

3.1 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)一般包括输入层、卷积层、池化层和全连接层。卷积层通过卷积核对输入信号进行特征的提取,具有局部观察、权值共享和高层聚合等特征^[17]。本文将融合的 13 个通道选取固定像素块,以中间像素点的值作为真值标签。一阶段使用二维卷积对积雪的空间信息进行特征提取,二阶段将多时相空间积雪特征图作为时序信号输入,使用一维卷积来提取时间维度积雪信息,以降低复杂地形地貌,下垫面类型不同,以及云遮蔽对积雪判识的影响。

3.1.1 二维卷积

二维卷积网络的输入通常为多通道平面结构,其大小为高 \times 宽 \times 通道数,即输入为多通道二维特征映射。卷积核是卷积神经网络模型的主要参数之一,每个卷积层的多个卷积核从左到右、从上到下依次卷积整个图像,输出多个表征图像的特征图,随着卷积层的增加可以捕捉图像更为复杂、抽象的内部语义信息,经过多个卷积层的运算,最后可以得到图像在各个不同尺度的抽象表示,但是层数的增加也会造成过拟合等问题。激活函数目的是为了给网络增加非线性映射,常用的激活函数有 Softmax、tanh、ReLU 等。

3.1.2 一维卷积

一维卷积神经网络本质上和二维卷积神经网络




图 5 二维卷积网络结构图

Fig.5 2D convolution network structure

络相同,只不过输入并不是二维图像,而是只有单一维度,常用在时间序列特征提取上,卷积层将一维输入与一维卷积核进行卷积运算,再通过激活函数提取局部特征,为了提取输入数据的多种不同特征,往往需要在同一个卷积层中设置不同卷积核,卷积的一般形式如下列公式:

$$x_{ij}^y = f \left[\sum_{m=0}^N \text{Conv}(W_{ij}, V_{(i-1)m}^{(y+l)}) + b_{ij} \right] \quad (4)$$

其中: x_{ij}^y 表示第*i*层第*j*个特征图上第*y*个位置的值, $f(\cdot)$ 为激活函数,本文使用 Relu 激活函数。 W_{ij} 和 b_{ij} 分别为此特征图的卷积核和偏置项, N 为*i*-1 层特征图的数量, $V_{(i-1)m}^{(y+l)}$ 表示*i*-1 层第*m*个特征图中第*y*到*y*+*l*间的数据,*l*代表卷积核长度。

3.1.3 池化层

池化(Pooling)可以减少特征图的维数和防止过拟合,具体做法是对特征图的某一区域用一个值替代,本文使用最大池化,这样可以使下一层神经元在面对一些较小幅度改变时保持不变性,逐步减少数据表示的空间大小,提高模型的鲁棒性。

3.1.4 全连接层

全连接层的每个神经元节点都与其前一层输出特征图中的所有神经元节点相互连接,全连接层可以整合卷积层或者池化层中具有类别区分性的局部信息,本文将最后一层的特征图映射为一维向量。

3.1.5 分类器

采用Softmax分类器对提取的特征向量进行分类,假设训练样本中输入数据为 x ,对应标签为 y ,则将样本数据判定为类别 j 的概率为 $p(y=j|x)$,所以,对于本文三分类问题,输出的将是一个三维向量(向量元素和为1),如下列公式所示:

$$h_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)}=1|x^{(i)};\theta) \\ p(y^{(i)}=2|x^{(i)};\theta) \\ p(y^{(i)}=3|x^{(i)};\theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^3 e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ e^{\theta_3^T x^{(i)}} \end{bmatrix} \quad (5)$$

其中: $\theta_1, \theta_2, \theta_3 \in R^{n+1}$ 为参数模型。

3.1.6 损失函数

交叉熵损失函数通常与Softmax分类器一起使用,在神经网络最后一层输出三类的预测概率,再与真值标签进行损失值的计算,计算公式如下:

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \log \hat{y}_i + (1-y_i) \log (1-\hat{y}_i)] \quad (6)$$

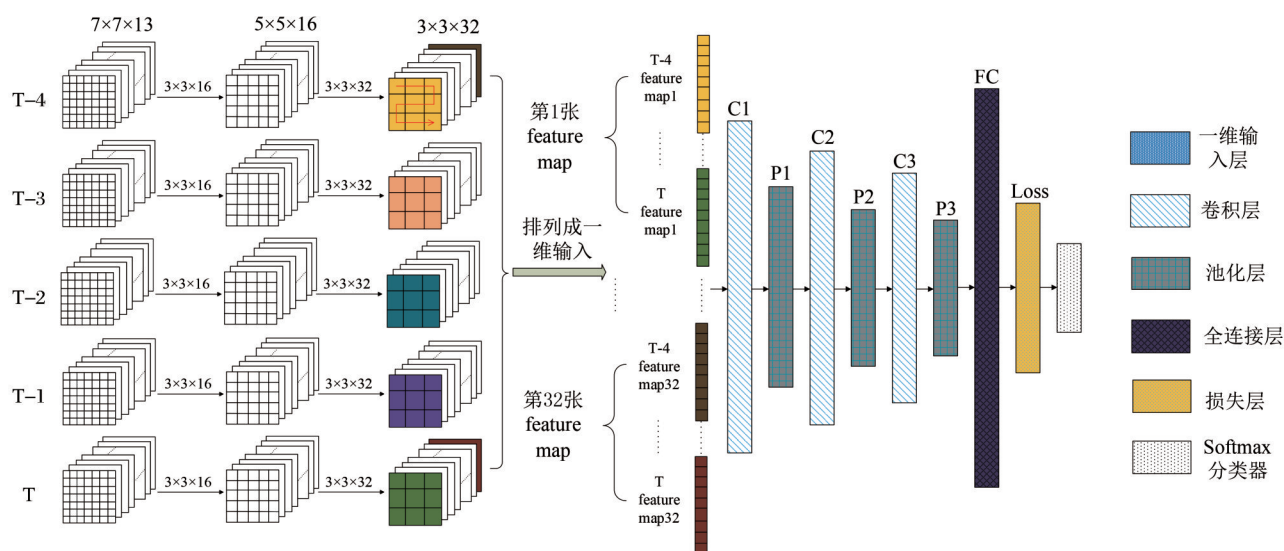


图6 深度网络积雪判识模型

Fig.6 Deep network snow identification mode

4 验证与分析

4.1 实验设计

实验数据集共计213 600个样本,训练集和测试集按照8:2划分,涉及Landsat 8制作的真值标签数据集80景,验证集6景,需要说明的是Aqua卫星为太阳同步极轨卫星,所以其搭载的MODIS过境

其中: L 表示损失值, N 为一次迭代的样本数(Batch_size), y 表示样本真值标签, \hat{y} 表示预测概率, \log 表示以 e 为底数的自然对数。

3.2 时空融合的深度学习积雪判识模型

网络模型主要分为两个阶段,一阶段提取空间积雪信息,输入层包括AGRI 2 km 7通道波段数据、NDSI、NDVI、DEM、坡向、坡度和地表覆盖类型,总计13个通道的数据。利用二维卷积网络对平面图强大的语义特征提取能力,从积雪的光谱特性、纹理信息、复杂地形地貌等影响因素建立空间信息相关性,通过两次卷积将空间积雪特征图输出。

二阶段主要解决云遮蔽对积雪判识的影响,因为云雪在相同地理位置上时间变化是不同的,利用AGRI高时间分辨率的优势,以一阶段 $T \sim T-4$ 时刻提取的积雪空间特征图做为输入,使用一维卷积提取积雪的时序特征,以此降低云雪误判的概率。

模型融合了积雪在时间和空间上的语义信息,可以提高判识的准确度。为减轻网络过拟合,引入“Dropout”为0.1的扰动系数,使用RMSProp优化算法解决摆动幅度大的问题,神经网络模型见图6,各网络层结构参数见表2。

时间固定为北京时间13点30分,所以选择的AGRI影像也为13点30分。为降低AGRI和MODIS与OLI真值标签由于成像时间造成的积雪消融误差,选择的OLI与两者成像时间差基本控制在10 min内,由于篇幅限制选择80景中8景,过境时间如表3所示。

为验证本文网络模型的有效性,分别对网络的

表 2 网络结构参数

Tabel 2 The parameters of network structure			
操作步骤	网络层名称	参数	输出特征大小
空间特征提取	输入层 \		7×7×13
	第一次卷积卷积核=3×3×16,步长=1		5×5×16
	第二次卷积卷积核=3×3×32,步长=1		3×3×32
5时相输入			1 440×1
时序特征提取	卷积层 C1 卷积核=3×1×16,步长=1		1 438×16
	激活函数 Rule		\
	池化层 P1 窗口=3×1,步长=3		479×16
	卷积层 C2 卷积核=3×16×32,步长=1		477×32
	激活函数 Rule		\
	池化层 P2 窗口=3×1,步长=3		159×32
	卷积层 C3 卷积核=3×32×64,步长=1		157×64
	激活函数 Rule		\
	全连接层 权值=10 048×10		10
	Softmax		3

隐藏层数、池化层步长、选取的像素块大小以及不同输入数据进行对比验证,如表 4 所示。其中地理

表 3 OLI过境时间

Tabel 3 OLI transit time			
行列号	过境时间	行列号	过境时间
031148	13 点 27 分	033148	13 点 28 分
032148	13 点 28 分	034148	13 点 29 分
033150	13 点 41 分	034147	13 点 22 分
033149	13 分 34 分	035147	13 点 23 分

信息数据包括 NDSI、NDVI、DEM、坡向坡度以及地表覆盖类型 6 个特征通道。实验 A~E 为网络不同层数的对比,F 和 G 为池化步长的对比,H 和 I 为不同输入像素块的对比,J~P 为加入不同地理特征的对比实验。

4.2 数据集实验结果

按照表 4 的网络结构和模型输入数据进行精度的对比验证,包括国际主流基于 MODIS 卫星采用 NDSI 方法提取的第六版逐日积雪产品 MOD10A1 和 MYD10A1。经过多次训练迭代后实验结果如表 5 所示。

表 4 网络结构参数

Tabel 4 The parameters of network structure										
实验	截取的像素块大小	空间特征提取网络/(卷积核数)				时序特征提取网络/(卷积核数)				模型输入数据
		一层	二层	三层	一层	二层	三层	四层	池化步长	
A	7×7	16	/	/	16	/	/	/	3	AGRI 7 通道+地理信息数据
B	7×7	16	32	/	16	32	/	/	3	AGRI 7 通道+地理信息数据
C	7×7	16	32	/	16	32	64	/	3	AGRI 7 通道+地理信息数据
D	7×7	16	32	/	16	32	64	128	3	AGRI 7 通道+地理信息数据
E	7×7	16	32	64	16	32	64	128	3	AGRI 7 通道+地理信息数据
F	7×7	16	32	/	16	32	64	/	2	AGRI 7 通道+地理信息数据
G	7×7	16	32	/	16	32	64	/	4	AGRI 7 通道+地理信息数据
H	5×5	16	32	/	16	32	64	/	3	AGRI 7 通道+地理信息数据
I	9×9	16	32	/	16	32	64	/	3	AGRI 7 通道+地理信息数据
J	7×7	16	32	/	16	32	64	/	3	AGRI 7 通道
K	7×7	16	32	/	16	32	64	/	3	AGRI 7 通道+NDSI
L	7×7	16	32	/	16	32	64	/	3	AGRI 7 通道+NDVI
M	7×7	16	32	/	16	32	64	/	3	AGRI 7 通道+DEM
N	7×7	16	32	/	16	32	64	/	3	AGRI 7 通道+坡向
O	7×7	16	32	/	16	32	64	/	3	AGRI 7 通道+坡度
P	7×7	16	32	/	16	32	64	/	3	AGRI 7 通道+地表覆盖类型

从实验 A~E 可以发现网络模型为 5 层时准确率最高,此时空间特征提取网络为 2 层,时序特征提取网络为 3 层,每层卷积核分别为 16、32、16、32、64,池化步长为 3。从实验 C 和 H~P 对比发现当输入 7×7 像素块并且加入地理信息时的 C 网络最优。此时的最优网络积雪提取准确度较 MOD10A1 和 MYD10A1 都有提升。

本文提出的方法能够取得较高积雪判识精度

的根本原因之一在于:该方法通过建立两个融合的特征提取网络,能够自适应地提取多时刻积雪点周围像素块空间和时间变化的特征信息,从而降低复杂地形地貌、下垫面类型不同和云遮蔽对积雪判识的影响。

4.3 Landsat 8 OLI 验证本文方法积雪提取效果

使用 30 m 分辨率 Landsat 8 对地观测卫星搭载的 OLI 陆地成像仪进行本文方法分类效果验证,研

表 5 多方法实验结果

Tabel 5 Experimental results of the Multi-method

实验	测试集准确度				训练集准确度			
	雪	云	裸地	综合	雪	云	裸地	综合
MOD10A1	0.931 0	0.940 3	0.949 6	0.940 3	/	/	/	/
MYD10A1	0.929 8	0.941 3	0.948 3	0.939 8	/	/	/	/
A	0.746 8	0.669 7	0.769 8	0.728 8	0.766 9	0.689 5	0.789 8	0.748 9
B	0.905 6	0.897 4	0.918 6	0.901 2	0.924 5	0.914 5	0.938 6	0.924 3
C	<u>0.941 9</u>	<u>0.936 9</u>	<u>0.959 6</u>	<u>0.946 8</u>	0.954 5	0.956 6	0.974 6	0.961 9
D	0.908 9	0.927 8	0.924 5	0.920 8	0.918 7	0.924 5	0.934 8	0.926 4
E	0.919 7	0.921 5	0.929 8	0.929 4	0.910 9	0.917 8	0.931 0	0.929 1
F	0.895 4	0.896 7	0.901 9	0.898 6	0.901 8	0.908 7	0.908 9	0.908 6
G	0.895 4	0.896 7	0.901 9	0.898 6	0.901 8	0.908 7	0.908 9	0.908 6
H	0.935 8	0.938 8	0.949 8	0.935 6	0.947 8	0.948 9	0.939 8	0.945 6
I	0.935 6	0.931 2	0.941 2	0.936 4	0.945 8	0.945 5	0.938 9	0.943 8
J	0.925 4	0.928 7	0.946 7	0.933 6	0.935 4	0.937 8	0.963 6	0.945 6
K	0.927 7	0.928 9	0.946 9	0.934 5	0.942 1	0.948 2	0.968 4	0.952 9
L	0.933 2	0.928 7	0.939 8	0.933 9	0.957 9	0.934 6	0.956 3	0.949 6
M	0.933 2	0.936 9	0.953 5	0.941 2	0.936 4	0.948 6	0.968 9	0.951 3
N	0.930 9	0.931 2	0.942 3	0.934 8	0.950 7	0.946 3	0.963 8	0.953 6
O	0.933 9	0.937 2	0.942 3	0.937 8	0.946 9	0.938 5	0.961 3	0.948 9
P	0.934 3	0.934 6	0.946 3	0.938 4	0.948 0	0.946 3	0.966 5	0.953 6

究数据来源于谷歌地理信息数据处理平台,在此随机下载了 6 景晴空 Landsat 8 OLI 影像,数据信息如表 6。分别验证本文方法的积雪分类精度和总精度,积雪分类精度表示识别出积雪像元的概率,即正确分类出积雪像元数与实际所有积雪像元数的比值。经统计得出 6 景的积雪分类精度为 0.938 1,总精度为 0.943 7,和网络测试集精度相当,达到了预期效果。其中 M1-M4 为高山地区积雪带,M5、M6 为人口居住地区日常积雪。分类效果对比如图 7 所示,可以看出本文方法不仅精度高而且对山脉积雪和居住区薄雪也有着很好的识别效果。

表 6 验证集 Landsat8-OLI 相关信息

Tabel 6 Landsat8-OLI Related information

数据编号	过境时间	轨道行号	轨道列号	积雪分类精度	总精度
M1	2018/09/25	035	145	0.938 9	0.958 7
M2	2018/10/02	035	146	0.934 6	0.938 9
M3	2018/11/24	034	149	0.956 3	0.954 6
M4	2019/11/19	030	141	0.926 4	0.934 6
M5	2019/12/05	029	141	0.926 8	0.936 4
M6	2020/02/07	029	141	0.945 8	0.948 2

4.4 新疆积雪制图效果对比

使用本文方法进行新疆地区积雪分类制图,并与 MOD10A1 积雪产品和 AGRI 遥感数据使用传统

阈值法 NDSI 进行积雪提取效果对比,由于在不同地区 NDSI 阈值选取不同,所以在样本数据集上通过设置不同阈值来评估积雪精确度,通过实验表明新疆地区阈值设置为 0.43 时可以达到样本最高准确率。

随机选择 MODIS 过境新疆地区的某日积雪产品 MOD10A1,如图 8(c)所示,过境时刻为北京时间 2018 年 12 月 6 号 13 点 30 分左右。因此对照选择 AGRI 拍摄的最接近时刻遥感数据,如图 8(a)为 13 点 30 分拍摄的彩色合成图像,并对此刻进行积雪分类制图。对图 8(a)中可以通过经验观测人工判识为雪的大致区域用黄色线条画出,然而部分云雪肉眼很难分辨,为了更好的比较局部细节信息,对图 8(a)蓝色虚线框放大,并利用 AGRI 高时间分辨率的特性,选取前后两个时刻拍摄的影像辅助判断,图 9(b)为 11 点拍摄的彩色合成图、图 9(c)为 15 点拍摄的彩色合成图。

通过对比可以发现,图 9(d)本文方法积雪提取轮廓线与黄色真值轮廓线大体相当,边缘轮廓清晰,积雪块判识准确;图 9(e)MOD10A1 产品却将大量积雪误识别成了云,原因在于本文方法充分利用了国产 FY-4A/AGRI 高时间分辨率的优势,不仅提取了空间地理方面的积雪特征信息,更进一步融合了时间维度云雪的变化特性,采用时空融合的积




图 7 OLI彩色图像与本文方法积雪提取对比

Fig.7 Comparison of OLI color image and snow extraction method in this paper

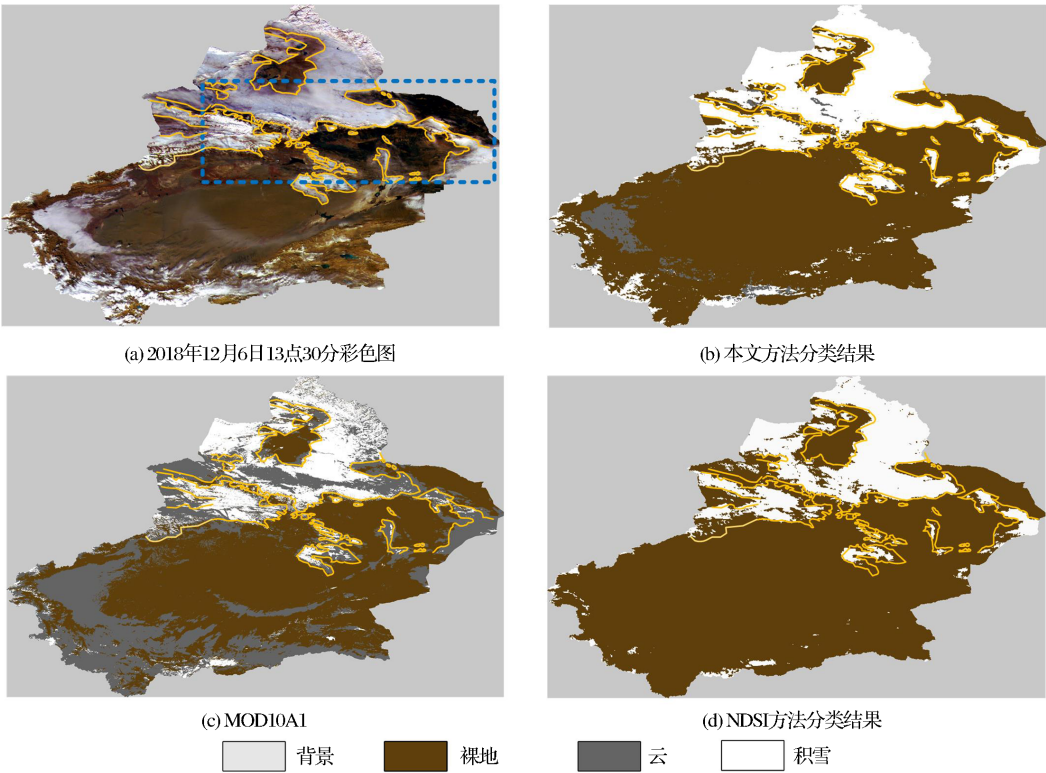


图 8 新疆 2018 年 12 月 6 日 13 点 45 分多种方法积雪提取效果对比

审图号:GS(2016)3333号

Fig.8 Comparison of snow extraction results by various methods at 13:45 on December 6, 2018 in Xinjiang

雪判识网络有效地去除了云对积雪判识的影响,并且减轻了基于像素阈值法进行分类提取的MOD10A1产品所造成的椒盐点现象,空间连续性

更强。
图 9(f)NDSI方法与真值雪线相比有大量积雪漏识别,为方便读者观察,部分用红色线标出,可以

明显看出,NDSI方法对细小积雪点和连续积雪块不敏感,原因在于NDSI只采用了可见光和近红外光单一差异积雪特征信息,而本文采用自适应的多光谱和空间地理特征深度学习方法,对积雪深层次

特征信息识别更准确。

通过以上对比观察可以发现本文方法对积雪判识效果最好,充分发挥出了国产风云气象卫星高性能的优势。

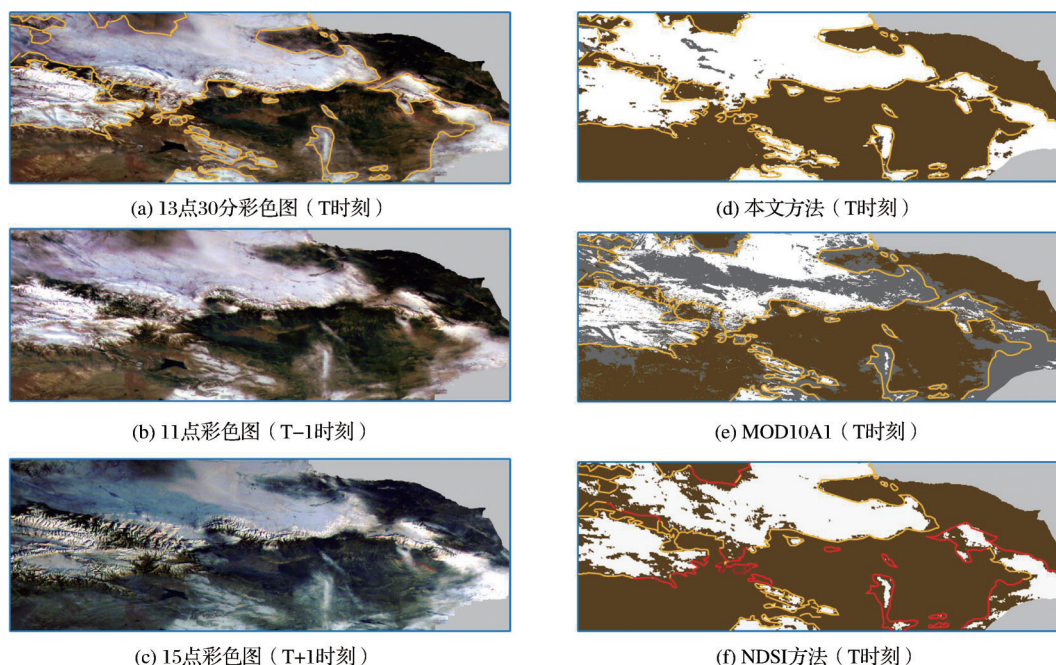


图9 多种方法积雪提取局部效果对比

Fig.9 Comparison of local effects of different methods for snow extraction

4.5 地面气象站验证

统计2019年新疆地区105个国家气象站台每日实测雪深数据,分别得到各自的分类精度。评价指标采用公式7通用的积雪评价标准。 A_s 为积雪分类正确率, M_s 为积雪产品被检样本中正确识别积雪的样本数量, M 为地面真值样本中有雪样本的总数。

$$A_s = \frac{M_s}{M} \quad (7)$$

在验证过程中,由于无法得知积雪产品识别为云的区域,其云层之下是否有雪,因此在普遍采用的地面站验证方法中,通常不用云覆盖下气象站数据验证精度;而在非积雪期(3~11月)降雪过程非常少,零星的降雪不具有代表性,因此只验证积雪期的分类精度,图10给出了不同产品2019年新疆地区积雪期周平均积雪分类精度对比。

由图10可以明显发现45~50周积雪分类精度都有着较大的降低,原因在于刚进入积雪期,气温变化大,积雪消融快,而气象台站每日记录时间固定,MODIS每日过境时间也是固定的,两者具有固有的时间差,因此积雪判识精度低且不具有客观对




图10 新疆2019年积雪期周积雪精度对比

Fig.10 Accuracy comparison of weekly snow cover over Xinjiang of snow period in 2019

比性,所以将精度统计分为1~9和51,52周以及45~50周两个部分,如表7积雪精度统计,在1~9和51,52周MODIS产品以及本文积雪分类精度与数据集验证结果相当,可以证明本文方法使用地面气象站验证的积雪分类精度也略高于MODIS积雪产品。

5 结论

本文通过构建与训练一个时空融合的卷积神经网络实现了对新疆地区基于国产FY-4A/AGRI

表 7 新疆 2019 年积雪期积雪精度对比

Tabel 7 Accuracy comparison of snow cover over Xinjiang of snow period in 2019

周号	积雪分类精度/(%)		
	MYD10A1	MOD10A1	本文方法
1~9, 51, 52	93.76	93.19	94.15
45~50	70.96	69.56	71.36

遥感数据和地理信息的特征融合与提取,并用于积雪分布判识,经数据集和地面气象站台验证,最终绘制出新疆地区高时间分辨率的积雪分布图,降低云雪误识别的概率,以上结果足以表明该方法可以将国产风云 4 号卫星在积雪判识上发挥出国际领先的优势。但是本文方法也是有很多可以改进与研究之处:①通过精度对比发现本文方法空间分辨率不如主流积雪产品,下一步将根据风云四号的光谱特点,提高空间分辨率到 1 km;②目前本文方法只能够针对新疆地区地形地貌特点进行积雪判识,因此地区适应性不足,下一步将扩展到其他区域,使用深度学习自适应的提取时间和空间地理信息进行积雪判识。

参考文献 (References):

- [1] Qing Dahe, Zhou Botao, Xiao Cunde. Changes of the Cryosphere and Its Impact on Climate in China[J]. Journal of Meteorology, 2014, 72(5): 869-879. [秦大河, 周波涛, 效存德. 冰冻圈变化及其对中国气候的影响[J]. 气象学报, 2014, 72(5): 869-879.]
- [2] Xia K, Luo Y, Li W P. Simulation of Freezing and Melting of Soil on the Northeast Tibetan Plateau[J]. Chinese Science Bulletin, 2011, 56(20): 2145-2155.
- [3] Yu Hongfeng, Zhang Xianfeng. Analysis of Snow Cover Change in Xinjiang based on Optical and Microwave Remote Sensing[J]. Earth Information Science, 2015, 17(2): 244-252. [于泓峰, 张显峰. 光学与微波遥感的新疆积雪覆盖变化分析[J]. 地球信息科学, 2015, 17(2): 244-252.]
- [4] Yan Xueying, Zhang Qinqin, Zhang Sicong, et al. Monitoring of Glacier and Perennial Snow Cover in Xinjiang from 2005 to 2015[J]. Geospatial Information, 2019, 17(8): 36-39, 10. [鄯雪英, 张琴琴, 张思聪, 等. 2005~2015 年新疆冰川与常年积雪变化监测研究[J]. 地理空间信息, 2019, 17(8): 36-39, 10.]
- [5] Ma Yu, Wang Yun, Wang Xu. Classification of White Disasters and Circulation Characteristics of Disaster-induced Snowstorm in Altai Area[J]. Resources and Environment in Arid Areas, 2014, 28(8): 120-124. [马禹, 王昀, 王旭. 阿勒泰地区白灾的等级划分及致灾暴雪的环流特征[J]. 干旱区资源与环境, 2014, 28(8): 120-124.]
- [6] Wang Xiaoru, Tang Zhiguang, Wang Jian, et al. Remote Sensing Monitoring of Snow Line Height at the End of Snowmelt in High Asia based on MODIS Snow Products[J]. Journal of Geography, 2020, 75(3): 470-484. [王晓茹, 唐志光, 王建, 等. 基于 MODIS 积雪产品的高亚洲融雪末期雪线高度遥感监测[J]. 地理学报, 2020, 75(3): 470-484.]
- [7] Pei H, Fang S F, Liu Z H, et al. Snow Information Abstraction based on Remote Sensing Data: Taking the North of Xinjiang for Example[J]. Taylor and Francis Group, 2012, 12(1): 56-60.
- [8] Dai L Y, Che T, Wang J, et al. Snow Depth and Snow Water Equivalent Estimation from AMSR-E Data based on a Priori Snow Characteristics in Xinjiang, China[J]. Remote Sensing of Environment, 2012, 127(1): 14-29.
- [9] Liu Y, Cheng X, Hao J S, et al. Snow Cover Estimation from MODIS and Sentinel-1 SAR Data Using Machine Learning Algorithms in the Western Part of the Tianshan Mountains[J]. Journal of Mountain Science, 2020, 17(4): 884-897.
- [10] Sun Yuyan, Zhang Lei, Lu Shanlong, et al. Daily Snow Monitoring Method based on Dynamic NDSI Threshold[J]. Journal of Earth Information Science, 2020, 22(2): 298-307. [孙玉燕, 张磊, 卢善龙, 等. 基于动态 NDSI 阈值的每日积雪监测方法[J]. 地球信息科学学报, 2020, 22(2): 298-307.]
- [11] Liu Y, Chen X, Hao J S, et al. Snow Cover Estimation from MODIS and Sentinel-1 SAR Data Using Machine Learning Algorithms in the Western Part of the Tianshan Mountains[J]. Journal of Mountain Science, 2020, 17(4): 884-897.
- [12] Hall D K, Riggs G A. In: National Snow and Ice Data Center (NSIDC) (Ed.), MODIS/Terra Snow Cover Daily L3 Global 500 m Grid, Version 6. NASA, Boulder, Colorado USA [J]. Quaternary Science Reviews, 2016, 32(1): 6-15.
- [13] Hall D K, Riggs G A, Salomonson V V, et al. MODIS Snow Cover Products[J]. Remote Sensing of Environment, 2002, 83(1): 181-194.
- [14] Salomonson V, Appel I. Estimation Fractional Snow Cover from MODIS Using the Normalized Difference Snow Index[J]. Remote Sensing of Environment, 2004, 89(3): 351-360.
- [15] Wang Xuan, Hao Xiaohua, Wang Jian, et al. Accuracy Evaluation of Long Time Series AVHRR Snow Cover Area Products in China[J]. Remote Sensing Technology and Application, 2018, 33(6): 994-1003. [王轩, 郝晓华, 王建, 等. 中国地区 AVHRR 长时间序列积雪范围产品精度评估[J]. 遥感技术与应用, 2018, 33(6): 994-1003.]
- [16] Yan J N, Ma Y, Wang L Z, et al. A Cloud-based Remote Sensing Data Production System[J]. Future Generation Computer Systems, 2018, 86(3): 1154-1166.
- [17] Feng Xun, Li Libing, Cheng Boyang, et al. On Orbit Calibration and Performance Evaluation of FY-4A Atmospheric Vertical Detector[J]. Journal of Infrared and Millimeter Wave, 2019, 38(5): 648-654. [冯绚, 李利兵, 陈博洋, 等. 风云四号 A 星干涉式大气垂直探测仪在轨定标及性能评价[J]. 红外与毫米波学报, 2019, 38(5): 648-654.]

- [18] 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.]
- [19] Krizhevsky A, Sutskever I, Hinton G E. ImageNet Classification with Deep Convolutional Neural Networks[C]// Advances in Neural Information Processing Systems. Red Hook, NY: Curran Associate, 2012: 1097-1105.
- [20] Mikolov T, Karafiat M, Burget L, *et al.* Recurrent Neural Network based Language Model [C]// Proceedings of INTERSPEECH. Lyon France: ISCA, 2010: 1045-1048.
- [21] Hochreiter S, Schmidhuber J. Long Short-term Memory. [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [22] Hinton G, Osindero S, Teh Y W, *et al.* Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [23] Vincent P, Larochelle H, Bengio Y, *et al.* Extracting and Composing Robust Features with Denoising Autoencoders [C]// Proceedings of the 25th International Conference on Machine Learning. New York: ACM Press, 2008: 1096-1103.
- [24] Zhang Jiahua, Wu Yang, Yao Fengmei, *et al.* Characteristics of Snow Cover in Xinjiang in Recent Years based on Satellite Remote Sensing and Ground Measured Snow Data[J]. Plateau Meteorology, 2008, 27(3): 551-557. [张佳华, 吴杨, 姚凤梅, 等. 利用卫星遥感和地面实测积雪资料分析近年新疆积雪特征[J]. 高原气象, 2008, 27(3): 551-557.]

Snow Cover Recognition for Xinjiang based on Fusion of FY-4A/AGRI Spatial and Temporal Characteristics

Zhang Yonghong^{1,3}, Cao Haixiao¹, Kan Xi²

(1. College of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China;

2. Bingjiang College, Nanjing University of Information Science & Technology, Wuxi 214105, China;

3. Jiangsu Collaborative Innovation Center of Atmospheric Environment and Equipment Technology (CICAET), Nanjing University of Information Science & Technology, Nanjing 210044, China)

Abstract: Snow cover recognition with high temporal resolution plays an important role in the development of agriculture and animal husbandry and snow disaster warning in Xinjiang pastoral areas. To solve the problem that existing snow cover products are susceptible to complex topography, landform, underlying surface type and cloud cover, which leads to the reduced accuracy of snow cover recognition, a deep learning method is proposed to use the data of Fengyun-4A Star Multichannel Radiation Scanner (AGRI) and the number of geographic information. Based on the method of multi-feature time series fusion, a new snow cover recognition model based on convolution neural network is constructed and trained, which takes the multitemporal FY-4A/AGRI multispectral remote sensing data, terrain topographic information such as elevation, aspect, slope, and surface cover type as the input of the model, and the high-resolution snow cover map extracted by Landsat 8-OLI as the "true value" label. Clouds, snow and snow-free surfaces in Xinjiang's complex terrain and underlying areas ultimately lead to hourly snow cover products. It is verified by the data set and the snow cover of meteorological station in 2019 the accuracy of this method is higher than that of MOD10A1 and MYD10A1, the main international MODIS snow products, which significantly reduces the misclassification rate of cloud and snow.

Key words: Xinjiang; Deep learning; Snow cover; Fengyun-4A/AGRI; MOD10A1