

用高分一号卫星数据识别多时相山区积雪

李成蹊^{1,2}, 肖鹏峰^{1,2}, 冯学智^{1,2}, 朱榴骏³, 宋明明^{1,2}

(1. 南京大学 地理信息科学系, 南京 210023; 2. 江苏省地理信息资源开发与利用协同创新中心, 南京 210023;
3. 莫纳什大学 土木工程系, 澳大利亚 Clayton Victoria 3168)

摘要:针对目前从高分辨率遥感图像中提取多时相山区积雪信息精度较低、效率不高的问题,基于高分一号卫星数据,提出了一种基于多视图的多时相山区积雪提取方法。该方法基于 GF-1 卫星 3 个时相的图像数据,将多时相遥感图像视为多个视图,通过空间约束构建积雪识别多视图。针对山区阴影的巨大影响的问题,提出了将积雪分为非阴影区积雪和阴影区积雪 2 个类别,分别进行训练样本的选取。仅通过一次样本选取,运用旋转森林算法,基于多视图构建面向多时相的识别模型,实现多时相遥感图像的积雪识别。实验结果表明,3 个时相识别结果的 F 值分别达到 0.941、0.951 和 0.945,精度较高,且具有较高的效率,具有实际应用价值。

关键词:高分一号;多视图;多时相;积雪识别;旋转森林

doi: 10.3969/j.issn.1000-3177.2017.02.012

中图分类号: TP 79 **文献标志码:** A **文章编号:** 1000-3177(2017)150-0071-08

Snow Cover Extraction from Multi-temporal GF-1 Satellite Imagery in Mountain Areas

LI Chengxi^{1,2}, XIAO Pengfeng^{1,2}, FENG Xuezhi^{1,2}, ZHU Liujun³, SONG Mingming^{1,2}

(1. *Department of Geographic Information Science, Nanjing University, Nanjing 210023, China;*
2. *Jiangsu Center for Collaborative Innovation in Geographical Information Resource Development and Application, Nanjing 210023, China;*
3. *Department of Civil Engineering, Monash University, Clayton Victoria 3168, Australia*)

Abstract: It is difficult to extract snow cover from multi-temporal high spatial resolution remotely sensed imagery, where the precision and efficiency is relatively low. This study provides a method which can extract multi-temporal snow cover from GF-1 based on multi-view model. Based on three GF-1 satellite images, single image was treated as a view, and multi views were built for multi-temporal snow recognition through extracting the unchanged part of multi-temporal images. In order to overcome the severe influence of terrain shadows, labeled samples of snow in sunlight and snow in shadow were selected separately. Only by selecting labeled samples once, three classifiers were built on different views based on rotation forest algorithm. Then, three classifiers were applied to the classification of three multi-temporal images. The accuracy verification showed that the F-score of three images are 0.941, 0.951, and 0.945, respectively. In addition, the efficiency is relatively high.

Key words: GF-1; multi-view; multi-temporal; snow cover extraction; rotation forest

收稿日期: 2016-06-16 修订日期: 2016-10-14

基金项目: 国家高分辨率对地观测系统重大专项(95-Y40B02-9001-13/15-04); 国家自然科学基金(41271353)。

作者简介: 李成蹊(1992—), 男, 硕士研究生, 主要研究方向为遥感数字图像处理与积雪遥感。

E-mail: lichengxirs@126.com

通信作者: 肖鹏峰(1979—), 男, 副教授, 主要研究方向为遥感数字图像处理与积雪遥感。

E-mail: xiaopf@nju.edu.cn

0 引言

积雪是冰冻圈的重要组成部分,是地表最活跃的自然要素之一,也是影响区域生态环境协调发展的重要因素^[1-2]。准确获取山区积雪的覆盖状况,对于促进干旱半干旱地区水资源合理利用、流域水资源高效管理具有十分重要的意义。卫星遥感技术具有宏观、快速、多时相的优点,在气候条件恶劣、气象资料不足的山区,是唯一能够反映大范围积雪覆盖状况的手段^[3],已经被广泛应用于积雪覆盖状况监测的研究中。近10年来,卫星遥感技术得到极大发展,高分辨率遥感图像被越来越多地应用到实际研究中。目前运用最广泛的雪盖产品为MODIS雪盖产品^[4],但是最高空间分辨率只有500 m。TM/ETM+数据可以提供30 m分辨率的雪盖产品^[5],但是时间分辨率最高只有16 d。我国高分辨率对地观测系统已于2013年4月16日成功发射高分一号(high-resolution satellite 1,GF-1)光学卫星^[6],携带的多光谱相机(panchromatic and multispectral sensor, PMS)可以提供空间分辨率8 m、最高时间分辨率4 d的遥感图像数据,为生产高时空分辨率积雪产品提供了可能。

由于缺少归一化差值积雪指数(normalized difference snow index, NDSI)所需的短波红外波段,基于NDSI的积雪识别算法并不适用于高分辨率遥感图像的积雪识别。一类方法通过建立NDSI的替代指数进行积雪识别。Hinkler等^[7-8]分别用RGBNDSI(RGB normalized difference snow index)和NDSII(normalized difference snow/ice index)代替NDSI对多光谱数码相机影像中的积雪进行识别;蒋璐媛等^[9]以NDSII为原型,构建高分积雪指数(GF-1 snow index, GFSI)进行高分辨率遥感图像的积雪识别。由于山区阴影的影响,此类方法在山区积雪识别中通常难以取得较好的结果。地形校正可以有效解决山区阴影的影响^[10-12],但是高分辨率的数字高程模型(digital elevation model, DEM)数据通常难以获取。另一类方法运用图像分类方法实现高分辨率遥感图像的积雪识别。Kim等^[13]基于平坦地表的积雪与其他地物光谱上的差异,运用ISODATA算法提取IKONOS图像中的积雪信息;白磊等^[14]运用K-means算法提取高分辨率数码相机中的阳坡积雪信息;Zhu等^[15]基于ZY-3多光谱数据,通过特征选择获取积雪识别的最优特征,采用决策树方法对山区积雪进行提取。为解决山区阴影的影响,阴影区积雪和非阴影区积雪被视为2个不

同类别^[15],本研究即采用此策略。但是,多时相遥感图像的光谱特征存在较大差异,基于特定图像构建的积雪识别模型难以应用到其他图像,必须重新进行样本选取。

为解决多时相遥感图像积雪识别的问题,本研究引入多视图的概念。多视图源于对单一数据集的划分^[16],在遥感通常被视为单一图像的不同特征子集(如光谱特征和纹理特征)。不同于单一数据集的划分,多时相遥感图像是对同一空间位置的不同描述,因此多时相遥感图像可以视为多视图。不同于单一图像的属性集划分,多时相遥感图像的地物类别可能发生变化,因此需要将发生变化的像元进行剔除。在研究区大部分像元类别未发生变化的情况下,在多视图上训练出的多个分类器可以适用于多时相遥感图像的积雪识别。

近年来,分类器集成已经成为机器学习领域的研究热点之一^[17],已广泛运用于监督分类中。旋转森林(rotation forest, RoF)算法作为集成学习算法的一种,利用特征提取来扩大基分类器之间的差异性,由Rodriguez等^[18]提出。具体是利用主成分分析法,对原始的特征轴进行旋转,提高基分类器的差异性。与此同时,由于所有主成分都得以保留,基分类器的准确性并没有发生较大的变化。

鉴于此,本研究以多时相GF-1卫星影像为主要数据源,辅以DEM数据,基于遥感图像多视图,将积雪分为非阴影区积雪和阴影区积雪,运用旋转森林算法,仅通过一次样本选取,实现多时相高分辨率遥感图像山区积雪识别,具有较高的精度和效率。

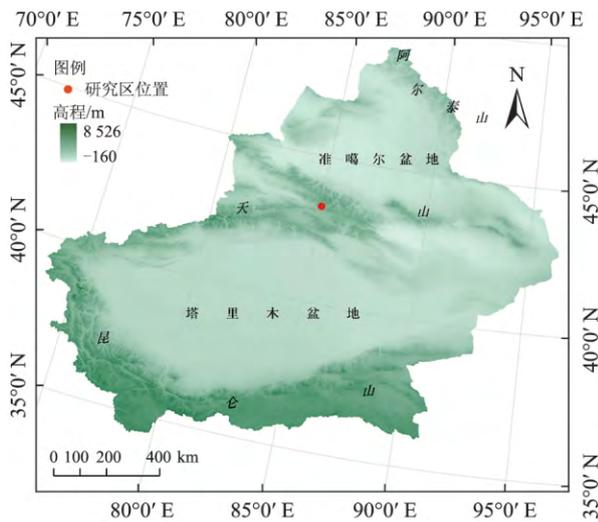
1 研究区与数据

1.1 研究区概况

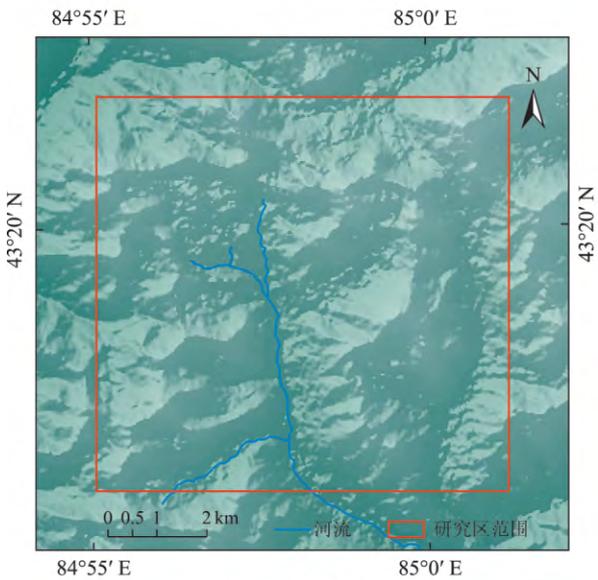
选择新疆天山中段依连哈比尔尕山典型区域作为研究区。依连哈比尔尕山属天山支脉,位于新疆尼勒克县东北部,西接博罗科努山,全长130 km,总面积 $0.78 \times 10^4 \text{ km}^2$,平均海拔高度达到3 600 m以上。研究区在新疆天山的位置与范围如图1所示,经纬度范围在 $43^{\circ}17' \text{ N} \sim 43^{\circ}21' \text{ N}$, $84^{\circ}55' \text{ E} \sim 85^{\circ}1' \text{ E}$,高程范围在3 027~4 423 m,面积约为 64 km^2 。研究区内地势高,地形较为复杂,山体阴影影响巨大,景观类型主要为高山草甸带和冰雪带。

1.2 数据准备与预处理

GF-1卫星是我国高分辨率对地观测系统的首发星,于2013年4月26日成功发射入轨。卫星上搭载了2台2 m全色分辨率、8 m多光谱分辨率的PMS(panchromatic and multispectral sensor)相机



(a) 研究区在新疆天山的位置



(b) 研究区的范围

图 1 研究区位置与范围示意图

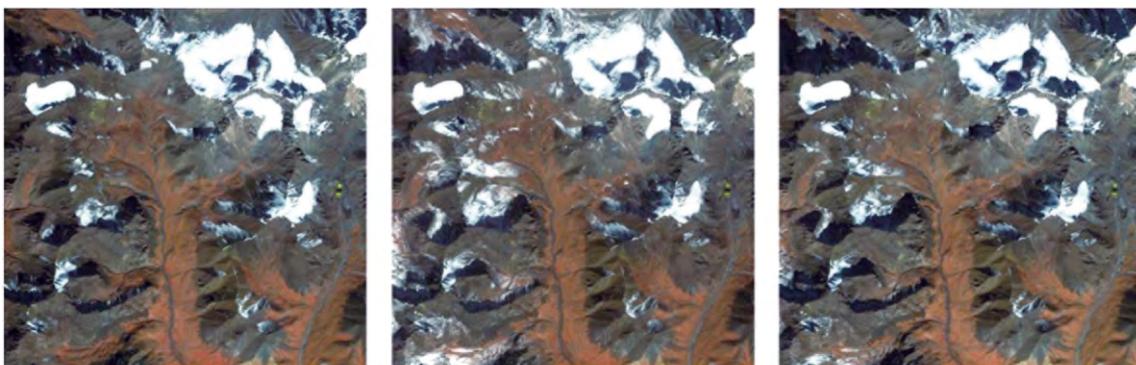
以及 4 台 16 m 分辨率的 WFV(wide field of view) 相机。卫星轨道高度为 645 km(标称值),轨道倾角为 98.05° ,降交点地方时为 $10:30 \text{ am}^{[6]}$ 。卫星数据可通过中国资源卫星中心下载(<http://www.cresda.com>),数据级别为 level 1A 级(预处理级辐射校正影像产品),PMS 多光谱数据采用 10 bit 方式量化传感器接收的辐亮度。本研究所采用的数据为多时相 GF-1 PMS 相机多光谱数据,空间分辨率为 8 m,共 4 个波段:B1($0.45\sim 0.52 \mu\text{m}$)、B2($0.52\sim 0.59 \mu\text{m}$)、B3($0.63\sim 0.69 \mu\text{m}$)和 B4($0.77\sim 0.89 \mu\text{m}$)。数据信息如表 1 所示,裁剪后的研究区范围假彩色合成图像如图 2 所示。

采用 ASTER GDEM (advanced spaceborne thermal emission and reflection radiometer global digital elevation model) 数据作为所使用数字高程数据。美国国家航空航天局(National Aeronautics and Space Administration,NASA)于 2011 年 11 月发布 ASTER GDEM 第二版数据,垂直精度和水平精度有一定的提高。数据空间分辨率约为 30 m,可通过美国地质调查局(United States Geological Survey, USGS) 网站下载 (<http://earthexplorer.usgs.gov/>)。

数据预处理的主要内容为几何校正,以防止因

表 1 GF-1 PMS 数据列表

编号	获取时间	太阳方位角	太阳高度角
T1	2013-10-07	168.63	40.58
T2	2013-10-15	169.35	37.64
T3	2013-10-19	169.55	36.19



(a) T1假彩色合成图像

(b) T2假彩色合成图像

(c) T3假彩色合成图像

图 2 GF-1 PMS 影像

图像错位而产生误差。本研究以 T1 为基准图像,对 T2、T3 2 幅图像进行几何校正,精度在 0.5 个像素以内。

2 研究方法

本研究基于 GF-1 PMS 数据,将空间约束后的多

时相遥感图像视为积雪识别的多视图。通过地形分析得到研究区阴影区范围,将积雪分为非阴影区积雪和阴影区积雪 2 个类别进行识别。仅通过在积雪多视图上进行一次样本选取,运用旋转森林算法,训练出针对各个视图的积雪识别模型,完成山区多时相遥感图像的积雪识别。主要技术路线如图 3 所示。

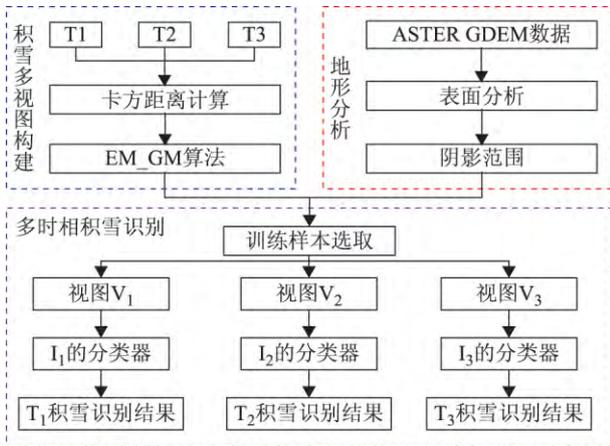


图 3 多时相山区积雪识别技术路线图

2.1 积雪识别多视图构建

多视图是指对同一对象的不同描述,最早由 Blum 和 Mitchell 于 1998 年提出。多视图的概念来源于对数据属性集的划分,在遥感领域,多视图即为多种波段的组合方式,任何具有多个属性的数据集都能够构建特征空间,并根据一定规则划分为若干个特征子空间,不同的特征子空间即为不同的视图。

多视图是对同一目标的不同描述,而多时相遥感图像实际上是对同一空间位置或目标的不同描述,因此,多时相遥感图像本身就是多个视图。对于在较短时间间隔内获取的同一空间范围的多幅遥感

图像 I_1, I_2, \dots, I_n , 令 $X_1 = \{x_i^1 \in I_1\}_{i=1}^N$, $X_2 = \{x_i^2 \in I_2\}_{i=1}^N, \dots, X_n = \{x_i^n \in I_n\}_{i=1}^N$ 分别表示多幅遥感图像, $x_i^1, x_i^2, \dots, x_i^n$ 分别表示为对应图像同一位置的第 i 个样本。在积雪识别过程中,由于时间上存在差异,导致在同一个空间位置上的像元类型有可能发生变化,即多时相遥感图像对同一空间位置的描述是对不同的目标的描述,无法满足多视图的构建条件。因此,需要剔除像元类型发生变化的空间位置,即通过变化检测技术对多时相遥感图像的空间范围进行约束,进而构建多时相遥感图像积雪多视图。本研究运用非监督变化检测的方法,得到多时相遥感图像中像元类型未发生变化的区域,用于积雪多视图的构建。

首先计 2 幅图像间的卡方距离 (chi-square distance, CSD)^[19],任意 2 个像元间的 CSD 由以下公式计算得出:

$$CSD = \sum_{k=1}^N \left(\frac{x_{i,k}^1 - x_{i,k}^2}{\sigma_{diff}^k} \right)^2 \quad (1)$$

式中: N 为波段数目; σ_{diff}^k 为 2 幅图像第 k 个波段差值的方差。然后由 EM-GM 算法获取阈值,通过阈值将图像分为变化区域和未变化区域。EM-GM 算法主要是通过最大期望法算法对高斯混合模型进行参数估计,然后基于贝叶斯最小错误理论得到区分变化区域与未变化区域的阈值^[8]。对于在较短时间间隔内获取的同一区域的多幅遥感图像,地物类别未变化区域像元光谱的差异远小于地物类别变化区域像元光谱的差异,对于区分积雪与非积雪这样的两类地物的分类问题尤其如此。因此,本文利用非监督变化检测方法,能够有效提取多时相遥感图像中未变化的区域,进而构建有效的多视图。

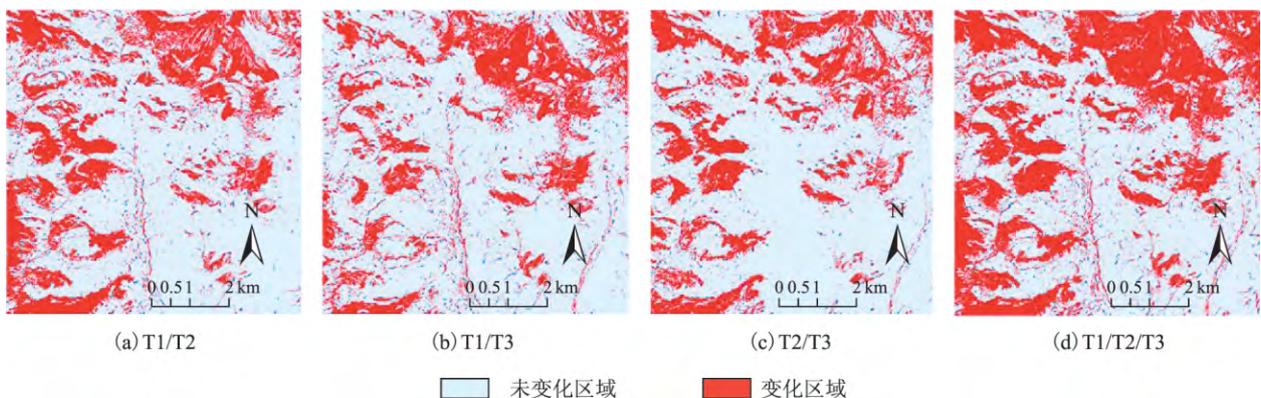


图 4 不同时相的变化检测结果

图 4 是基于研究区图像 4 个波段不同时相组合的非监督变化检测结果,未变化区域以灰白色表示,变化区域以红色表示。其中,图 4(a)、图 4(b)、

图 4(c) 分别为 T1/T2、T1/T3、T2/T3 时相组合的变化检测结果,其区分变化区域与为变化区域的阈值分别为 0.843 8、0.779 7 和 1.479 5,未变化像元

比重分别为 68.6%、71.7%和 71.8%。提取在 3 个时相中像元类型均未发生变化的区域得到图 4(d),为 T1/T2/T3 的变化检测结果,未变化像元的比重达到 58.83%,即大部分区域满足了类别未发生变化的条件。假设通过样本选取训练出的积雪识别模型能够完成各个时相中未变化区域中的积雪识别,那么对于各个时相中类别发生变化区域的积雪识别,此方法同样适用。

经过非监督变化检测,提取在 3 个时相中像元类型均未发生变化的区域,即对 T1、T2 和 T3 进行空间约束。最终得到积雪识别多视图 V_1 、 V_2 和 V_3 ,其中每个视图的特征空间均由 4 个光谱波段组成。

2.2 训练样本选取

本研究基于分类技术进行积雪识别,而训练样本的选取是分类器构建的关键步骤,分类器的分类精度在很大程度上取决于训练样本的选取。如果选取的训练样本没法很好代表总集合的分布,由此训练得到的分类器同样会受到影响,进而影响积雪识别的精度。研究区地形条件较为复杂,受到山体阴影的影响,阴影区积雪与非阴影区积雪存在较大的差异。在未进行地形校正的情况下,阴影区积雪和非阴影区积雪应视为独立的类别进行识别^[15]。因此,将研究区内的地物类型分为 3 个类别:非阴影区积雪、阴影区积雪和非积雪,并依据这 3 个类别进行样本选取。

首先,根据玛纳斯河流域的平均雪线高度,在海拔高于平均雪线的区域选取积雪样本,在其他区域选取非积雪样本。并通过表面分析^[20]得到研究区的阴影范围,判断样本是否落入阴影区影响的范围内,区分阴影区与非阴影区样本。本研究依据以上的方法,并结合遥感图像目视判读,选取用来构建积雪识别模型的训练样本。非阴影区积雪、阴影区积雪和非积雪 3 个类别各选取样本 50 个,共 150 个样本,每个样本为一个像元。需要说明的是,选取的训

练样本是基于空间约束后的遥感图像,因此选取的训练样本在不同图像上类别并未发生变化。

2.3 积雪识别模型构建

由于空间约束后的 T1、T2 和 T3 3 幅遥感图像可以视为积雪识别的多视图,所选取的样本具有分别对应 3 个时相的 3 个视图,称为 V_1 、 V_2 和 V_3 。基于所选取的训练样本,采用旋转森林算法,分别构建面向 V_1 、 V_2 和 V_3 3 个视图的分类器 f_1 、 f_2 和 f_3 。3 个分类器分别对应时相 T1、T2 和 T3,利用 3 个不同的分类器完成 3 个时相遥感图像的积雪识别。积雪识别模型实际上是多个基于旋转森林算法的分类器。

旋转森林算法的最大优势在于:基分类器间同时具有较高的差异性及其准确性,其分类性能往往优于其他传统的集成学习算法。研究表明,相较于传统的集成策略,在分类器个数降到 10 个以下的情况下,旋转森林算法仍能具有较高的分类性能^[21]。然而传统的集成策略,要获取较好的分类性能,基分类器的个数需要更多。因此,在保证分类效果的同时,旋转森林算法的效率也得到了保证。

旋转森林算法的具体实现过程如下,设 X 表示具有 n 个特征的训练样本集, Y 表示相应的类别标记, F 表示特征集。假定 X 中包含 N 个训练样本,那么 X 可以表示为一个 $N \times n$ 的矩阵。设 D_1, D_2, \dots, D_L 表示 L 个基分类器。旋转森林算法每一个基分类器 $D_i (1 \leq i \leq L)$ 的训练集由以下步骤进行构建^[18]:

1) 将 F 划分为 K 个完全不相交的子集,因此,每个子集包含 $M=n/K$ 个特征。

2) 用 $F_{i,j}$ 表示用于训练分类器 D_i 的第 j 个子集。对于每个特征集,在随机去掉某一类的样本后,对剩下样本进行 75% 的重采样。随后,对 $F_{i,j}$ 进行主成分分析,得到 M_j 个主成分: $a_{i,j}^{(1)}, a_{i,j}^{(2)}, \dots, a_{i,j}^{(M_j)}$ 。

3) 基于得到的 K 个主成分系数,构建稀疏矩阵 R_i :

$$R_i = \begin{bmatrix} a_{i,1}^{(1)}, \dots, a_{i,1}^{(M_1)} & [0] & \dots & [0] \\ [0] & a_{i,2}^{(1)}, a_{i,2}^{(2)}, \dots, a_{i,2}^{(M_2)} & \dots & [0] \\ \vdots & \vdots & \ddots & \vdots \\ [0] & [0] & \dots & a_{i,K}^{(1)}, a_{i,K}^{(2)}, \dots, a_{i,K}^{(M_K)} \end{bmatrix} \quad (2)$$

根据原始特征集的顺序,将这个矩阵重新排列,得到旋转矩阵 R_i^c 。最后 D_i 的训练集为 XR_i^c 。基于这种方法,所有基分类器可以并行训练。由于决策树对旋转矩阵具有一定的敏感性,可以提高各个基分类器之间的差异性,本研究采用 J48 决策树^[22]

作为基分类器。

具体分类过程如下:对于一个样本 x ,设 $d_{i,j}(xR_i^c)$ 为 D_i 预测 x 属于类别 c 的可能性, label 表示所有可能的类别,则 x 属于 c 类的置信度为:

$$u_c(x) = \frac{1}{L} \sum_{i=1}^L d_{i,c}(xR_i^q), c \in \text{label} \quad (3)$$

$$x = \operatorname{argmax}(u_c(x)), c \in \text{label} \quad (4)$$

最后, x 被划分为置信度值最大的类别中。

3 结果与评价

3.1 积雪识别结果

根据选取的训练样本,采用旋转森林算法,基于 V_1 、 V_2 和 V_3 3个视图训练得到的3个分类器,分别

对 T1、T2、T3 3个时相的 GF-1 PMS 图像进行分类。由于研究区山体阴影影响巨大,存在大量阴影区积雪,基于分类方法进行积雪识别时将积雪人为区分为非阴影区积雪和阴影区积雪。因此,研究区地物类型分为非阴影区积雪、阴影区积雪和非积雪3个类别,分类结果如图5所示。其中非阴影区积雪用蓝色表示,阴影区积雪用橙色表示,非积雪用灰色表示。可见,由于山体阴影的影响,研究区内存在大量阴影区积雪。

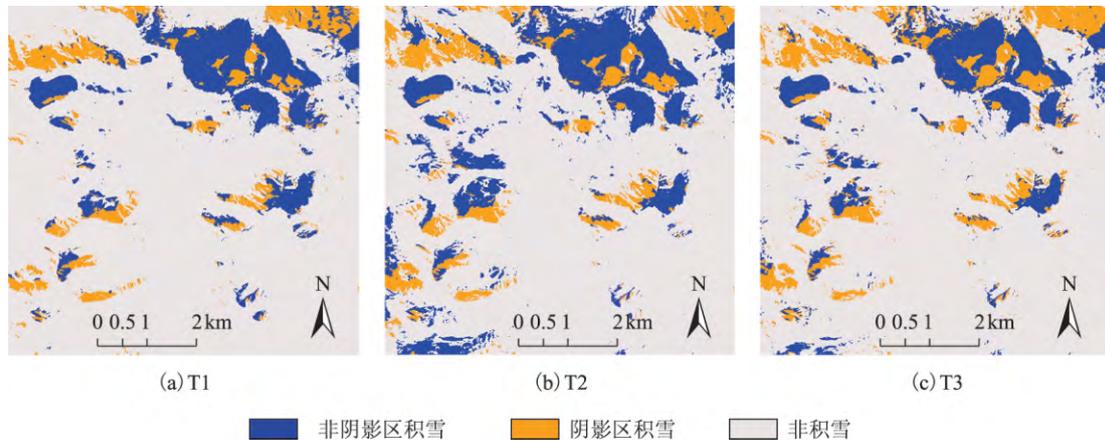


图5 研究区多时相分类结果

但是在积雪识别过程中,二者均为积雪,并无区别,因此在结果中将二者合并。研究区最终的多时相积雪识别结果如图6所示,其中积雪用蓝色表示,非积雪用灰色表示。从图6中可以看出,

T1到T2期间,研究区内积雪面积明显增加,可见经历了一次降雪过程;T2到T3期间,研究区内积雪面积有所减少,在低海拔地区的部分积雪逐渐融化。

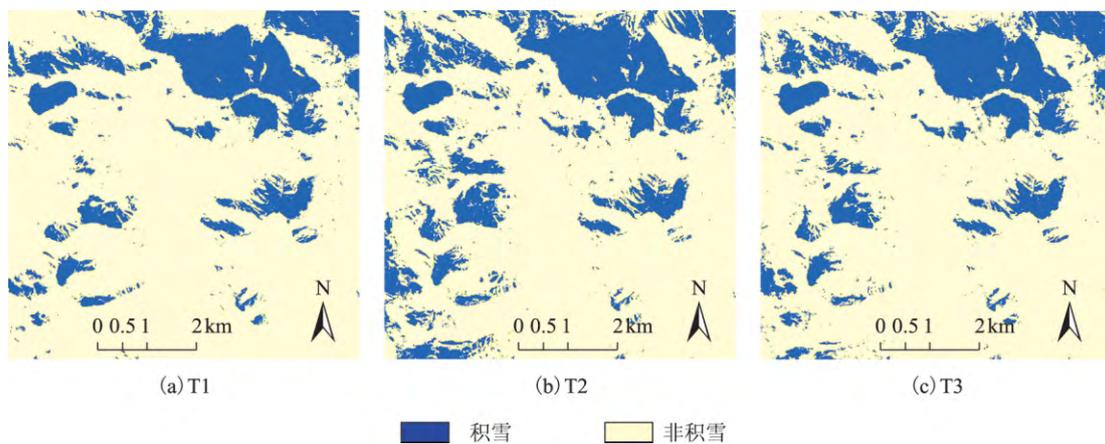


图6 研究区多时相积雪识别结果

3.2 识别结果评价

本研究基于分类方法进行积雪识别,在积雪识别过程中将研究区地物分为非阴影区积雪、阴影区积雪和非积雪3个类别。由于本文的目标是提取多时相遥感图像中的积雪,非阴影区积雪和阴影区积雪都属于积雪。因此,在识别精度评价过程中,非阴影区积雪和阴影区积雪2个类别合

并为积雪。基于在3幅图像中独立选取大量测试样本(每个类别样本数大于3000个),计算3个时相基于本文方法积雪识别结果的 Precision 值、Recall 值以及 F 值。并与另一种著名的集成学习算法随机森林(random forest)^[23],以及旋转森林算法的基分类器 J48 决策树进行对比。识别精度评价结果如图7所示。

其中, Precision 值、Recall 值及 F 指数的计算方法如下:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (6)$$

$$F = \frac{2TP}{2TP+FP+FN} \quad (7)$$

式中: TP(true positive) 是积雪像元被准确识别的

数量; FP(false positive) 是非积雪像元被识别为积雪的数量; FN(false negative) 是漏识别的积雪像元数量。 Precision 值表示被识别为积雪的像元中实际为积雪像元的比例, Recall 值表示积雪像元被正确识别的比例。 F 指数 Precision 值和 Recall 值的调和均值, 评估的不是整个的分类结果, 而是只是考虑某个类别误识别和漏识别的现象, 被认为是评价积雪识别结果的最佳手段之一^[24]。

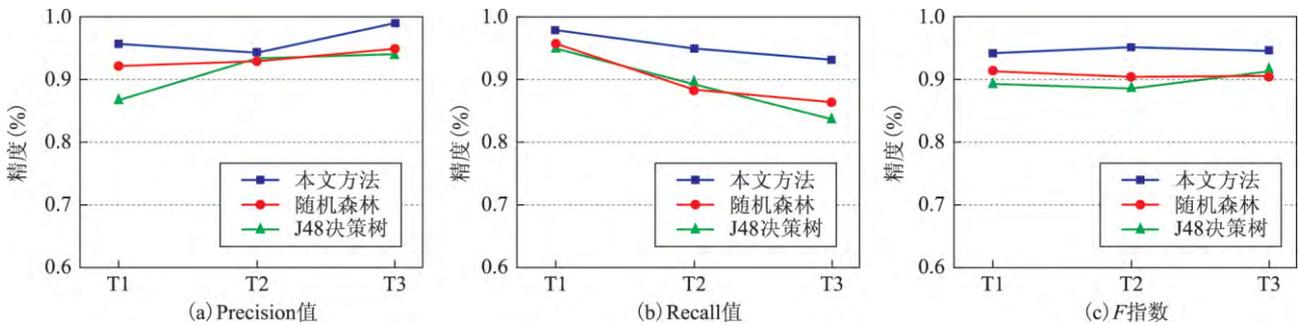


图7 不同时相积雪识别结果精度比较

在3个时相的积雪识别结果中, 本文方法的积雪识别结果 F 值分别达到了 0.941、0.951 和 0.945, 均高于随机森林和 J48 决策树, 同时也具有较高的 Precision 值及 Recall 值。此外, 为探究本文方法的效率, 计算本文算法在各个时相遥感图像训练出用于积雪识别的分类器的时间, 并与另一种常用的集成学习算法——随机森林算法进行比较, 具体结果如表 2 所示。基于本文方法, T1、T2 和 T3 3 个时相的分类器训练时间分别为 0.02 s、0.02 s 和 0.01 s, 基于随机森林方法 3 个时相上分类器训练时间分别为 0.04 s、0.03 s 和 0.03 s。因此, 本文方法较随机森林方法, 在效率上具有一定的优势。

表2 不同时相分类器训练时间统计

方法	T1	T2	T3
本文方法	0.02	0.02	0.01
随机森林	0.04	0.03	0.03

从整体角度来看, T1、T2 和 T3 中基于本文方法的多时相积雪识别结果均具有较高的精度和效率。因此, 本文方法在多时相遥感图像积雪识别的过程中, 具有较高的稳定性, 较其他方法有一定的优势。由于多视图的构建基于非监督变化检测及自动阈值获取方法, 无需人工干预, 算法自动化水平较高。此外, 本文方法在不同时相上分类器的训练速度较快, 相对于目前的多时相积雪识别方法在效率上有一定优势。

4 结束语

随着遥感数据时空分辨率的不断提高, 从不断获取的多时相数据中提取出雪盖信息具有重要意义。国产 GF-1 卫星可以提供高时空分辨率的遥感图像, 为提供高时空分辨率雪盖信息提供了可能。本文基于 GF-1 PMS 数据, 构建积雪识别多视图, 仅通过一次样本选取, 实现了多时相积雪识别。将积雪分为非阴影区积雪和阴影区积雪, 克服山区阴影的巨大影响。以此探索基于多视图的多时相高分辨率遥感图像积雪识别的可能性。本研究主要结论如下:

1) 基于国产 GF-1 卫星数据能够有效完成山区积雪识别。在高海拔地形复杂的山区, 由于山体阴影现象严重, 基于分类方法的积雪识别需要将积雪划分为阴影区积雪和非阴影区积雪 2 个类别进行分别识别。

2) 基于单一遥感图像通过样本选取训练出的分类器, 通常无法用于多时相遥感图像。但经过空间约束的多时相遥感图像可以看作积雪识别多视图, 只需要一次样本选取就可以构建针对多时相遥感图像的多个积雪识别模型, 完成多时相遥感图像的积雪识别。

3) 旋转森林算法在保证分类效果的同时, 效率也得到了保证, 在基于多视图的多时相高分辨率遥感图像积雪识别的过程中具有较高的精度和效率。

本研究各个视图的特征空间只包含原始的

4个光谱波段,如何利用纹理、指数等其他辅助信息,通过特征选择提高类别间的可分性,进而提升积雪在各个时相中的识别精度,后续需进行进一步研究。

参考文献

- [1] 施雅风,程国栋. 冰冻圈与全球变化[J]. 中国科学院院刊,1991(4):287-291.
- [2] DÉRY S J,BROWN R D. Recent Northern Hemisphere snow cover extent trends and implications for the snow-albedo feedback[J]. *Geophysical Research Letters*,2007,34(22):60-64.
- [3] 曹梅盛. 冰冻圈遥感[M]. 北京:科学出版社,2006.
- [4] 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.
- [5] CRAWFORD C J,MANSON S M,BAUER M E,et al. Multitemporal snow cover mapping in mountainous terrain for Landsat climate data record development[J]. *Remote Sensing of Environment*,2013,135:224-233.
- [6] 白照广. 高分一号卫星的技术特点[J]. *中国航天*,2013(8):5-9.
- [7] HINKLER J,RBK J B,HANSEN B U. Detection of spatial,temporal,and spectral surface changes in the Ny-Ålesund area 79 N,Svalbard,using a low cost multispectral camera in combination with spectroradiometer measurements[J]. *Physics and Chemistry of the Earth,Parts A/B/C*,2003,28(28):1229-1239.
- [8] HINKLER J,PEDERSEN S B,Rasch M,et al. Automatic snow cover monitoring at high temporal and spatial resolution,using images taken by a standard digital camera[J]. *International Journal of Remote Sensing*,2002,23(21):4669-4682.
- [9] 蒋璐媛,肖鹏峰,冯学智,等. 山区复杂地形条件下 GF-1 卫星遥感雪面反射率计算[J]. *南京大学学报(自然科学版)*,2015,51(5):944-954.
- [10] SIRGUEY P,MATHIEU R,Arnaud Y. Subpixel monitoring of the seasonal snow cover with MODIS at 250 m spatial resolution in the Southern Alps of New Zealand: methodology and accuracy assessment [J]. *Remote Sensing of Environment*,2009,113(1):160-181.
- [11] NEGI H S,KULKARNI A V,SEMWAL B S. Estimation of snow cover distribution in Beas basin,Indian Himalaya using satellite data and ground measurements[J]. *Journal of Earth System Science*,2009,118(5):525-538.
- [12] CRAWFORD C J,MANSON S M,BAUER M E,et al. Multitemporal snow cover mapping in mountainous terrain for Landsat climate data record development[J]. *Remote Sensing of Environment*,2013,135:224-233.
- [13] KIM S,HONG C. Antarctic land-cover classification using IKONOS and Hyperion data at Terra Nova Bay [J]. *International Journal of Remote Sensing*,2012,33(22):7151-7164.
- [14] 白磊,郭玲鹏,马杰,等. 基于数码相机拍摄影像的山区积雪消融动态观测研究:以天山积雪站为例[J]. *资源科学*,2012,34(4):620-628.
- [15] ZHU L,XIAO P,FENG X,et al. Support vector machine-based decision tree for snow cover extraction in mountain areas using high spatial resolution remote sensing image[J]. *Journal of Applied Remote Sensing*,2014,8(1):84698.
- [16] BLUM A,MITCHELL T. Combining labeled and unlabeled data with co-training [C]//Eleventh Conference on Computation learning Theory. USA:ACM,2000:92-100.
- [17] KUNCHEVA L I,RODRIGUEZ J J. An experimental study on rotation forest ensembles[M]. New York:Multiple Classifier Systems,Springer,2007,459-468.
- [18] RODRIGUEZ J J,KUNCHEVA L I,ALONSO C J. Rotation forest: a new classifier ensemble method [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,2006,28(10):1619-1630.
- [19] D'ADDABBO A,SATALINO G,PASQUARIELLO G,et al. Three different unsupervised methods for change detection: an application[C]//Geoscience and Remote Sensing Symposium,2004. IGARSS'04 Proceedings, 2004 IEEE International. USA:IEEE,2004,3:1980-1983.
- [20] BURROUGH P A,MCDONNELL R A. Principles of geographical information systems [M]. New York: Oxford University Press,2011.
- [21] 毛莎莎,熊霖,焦季成,等. 利用旋转森林变换的异构多分类器集成算法[J]. *西安电子科技大学学报*,2014,41(5):48-53.
- [22] QUINLAN J R. C4. 5:programs for machine learning[M]. Amsterdam:Elsevier,2014.
- [23] BREIMAN L. Random forests[J]. *Machine Learning*,2001,45(1):5-32.
- [24] RITTEGER K,PAINTER T H,DOZIER J. Assessment of methods for mapping snow cover from MODIS[J]. *Advances in Water Resources*,2013,51:367-380.