

基于迁移学习的无人机高分影像 地震泥石流信息检测^{*}

郭加伟^{1,2}, 李永树¹, 王洪蜀³, 鲁 恒^{4,5}◆

(1. 西南交通大学地球科学与环境工程学院, 四川成都 611756; 2. 成都市规划信息技术中心, 四川成都 610094;
3. 四川水利职业技术学院测绘工程系, 四川成都 611231; 4. 四川大学水力学与山区河流开发保护国家重点实验室, 四川成都 610065; 5. 四川大学水利水电学院, 四川成都 610065)

摘要: 地震后经常会引发大量的泥石流灾害(称作地震泥石流), 容易造成极大的破坏, 无人机低空遥感技术以其便捷、时效性强等特点成为一种快速获取灾害信息的手段, 但其影像的光谱信息较为缺乏, 较难准确地检测地震泥石流灾害信息。针对以上问题, 提出了一种基于迁移学习机制地震泥石流检测方法, 该方法在已构建地震泥石流灾害样本库的基础上, 将卷积神经网络训练得到的特征迁移到地震泥石流灾害信息检测中, 完成地震泥石流灾害信息的自动检测, 并将面向对象的地震泥石流灾害信息检测结果与迁移学习支持下的检测结果进行了对比与分析。结果表明: 基于迁移学习的地震泥石流灾害信息检测结果在精度上稍优于面向对象的地震泥石流灾害信息检测结果, 且前者在保持地震泥石流的平滑性和完整性上要优于后者。

关键词: 地震; 泥石流; 无人机高分影像; 迁移学习; 信息检测

中图分类号: P315.9; P642.23

文献标识码: A

文章编号: 1000-0666(2018)02-0180-06

0 引言

2008年“5·12”汶川大地震给当地人民带来了巨大的损失, 且强震后较长一段时间内, 伴随着强降雨天气常出现的地震泥石流, 给灾区人民带来了极大的威胁和伤害。据统计, 汶川大地震由于地震滑坡、泥石流造成的人员死亡人数约占地震总死亡人数的1/4(殷跃平, 2008), 同时, 地震泥石流还会造成房屋建筑受损、交通阻塞和堰塞湖等诸多问题。因此, 如何利用现有的科学手段对地震泥石流信息进行快速检测, 准确获取灾情信息, 是目前地震灾害信息检测与应急救援工作中的研究重点之一(唐川, 2010; 彭述刚, 2014)。

无人机遥感技术以其灵活、快捷、受地形天气影响小、影像分辨率高等得天独厚的优势, 已成为地震灾害信息检测与应急响应工作中的常用手段(任娟, 2015; 周洋等, 2017)。但目前基于无人机高分辨率影像的地震泥石流信息检测多以

目视解译为主, 效率比较低下, 如何突破这一技术瓶颈已成为当前该领域的研究热点。

随着计算机技术的不断发展, 深度学习已成功在语音识别、自然语言处理以及计算机视觉领域取得突破(Mikolov et al, 2013)。迁移学习是深度学习的一种, 迁移学习不需要做训练数据与测试数据同分布假设, 这意味着迁移学习不需要对每个领域都标定大量的训练数据, 而是从现有的数据中迁移知识, 用来帮助新的学习任务, 目前基于特征的迁移学习具有更广泛的迁移能力(Weiss et al, 2016; Saha et al, 2016)。针对此现状, 本文以地震泥石流无人机高分影像灾害样本库为基础, 利用卷积神经网络进行地震泥石流特征训练, 结合迁移学习特征的优势, 将获取的特征训练方法迁移到地震泥石流灾害信息检测中, 实现地震泥石流灾害信息的自动检测。并将该方法检测的地震泥石流结果与面向对象的地震泥石流信息检测结果进行对比分析, 提出了一种基于迁移学习的无人机高分影像地震泥石流灾害信息检测方法。

* 收稿日期: 2016-12-14.

基金项目: 国家自然科学基金青年基金项目(41701499)及四川省科技厅重点研发项目(2018GZ0265)联合资助.

◆ 通讯作者: 鲁恒(1984-), 博士, 主要从事3S技术集成应用研究. E-mail: luheng@scu.edu.cn.

1 数据选取与研究方法

1.1 研究区及数据概况

本文选择的研究区为汶川地震的重灾区汶川县和都江堰市，地理位置如图1所示。汶川县位于四川盆地西北部边缘，居阿坝藏族羌族自治州东南部，总面积4 083 km²；都江堰市西邻汶川县，位于成都平原西北边缘，面积共1 208 km²。该区域受汶川地震影响极大，地震诱发了大量的泥石流等次地质灾害，造成了严重的人员伤亡和财产损失。

图1中黑色点位是地震诱发的地质灾害，且拥有该区域无人机高分影像的位置，影像覆盖区域面积总计76.59 km²。利用收集到的无人机高分影像，采集地震泥石流灾害样本，并按照统一格式进行存储，形成地震泥石流灾害样本库，其中包括地震泥石流正样本（地震泥石流）280个，地震泥石流负样本（非地震泥石流）1 600个，所有样本均缩放到256×256像素。地震泥石流样本示例如图2所示。

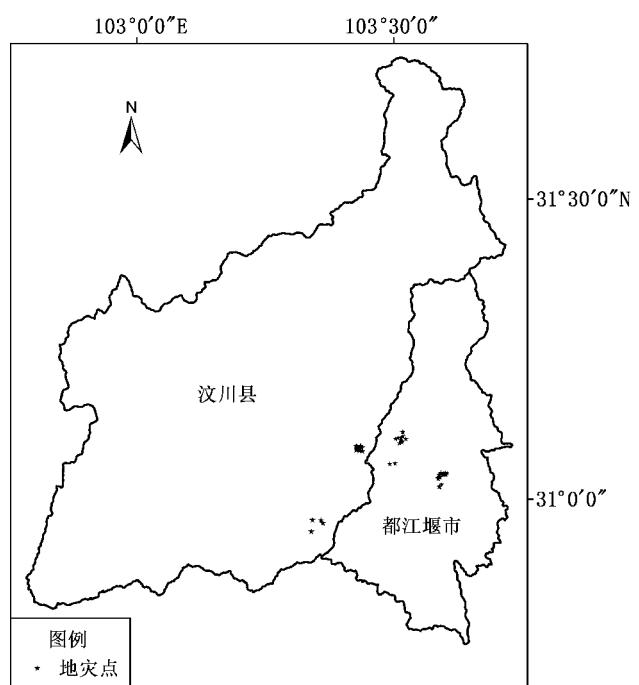


图1 研究区地理位置示意图

Fig. 1 The geographical location of the study area

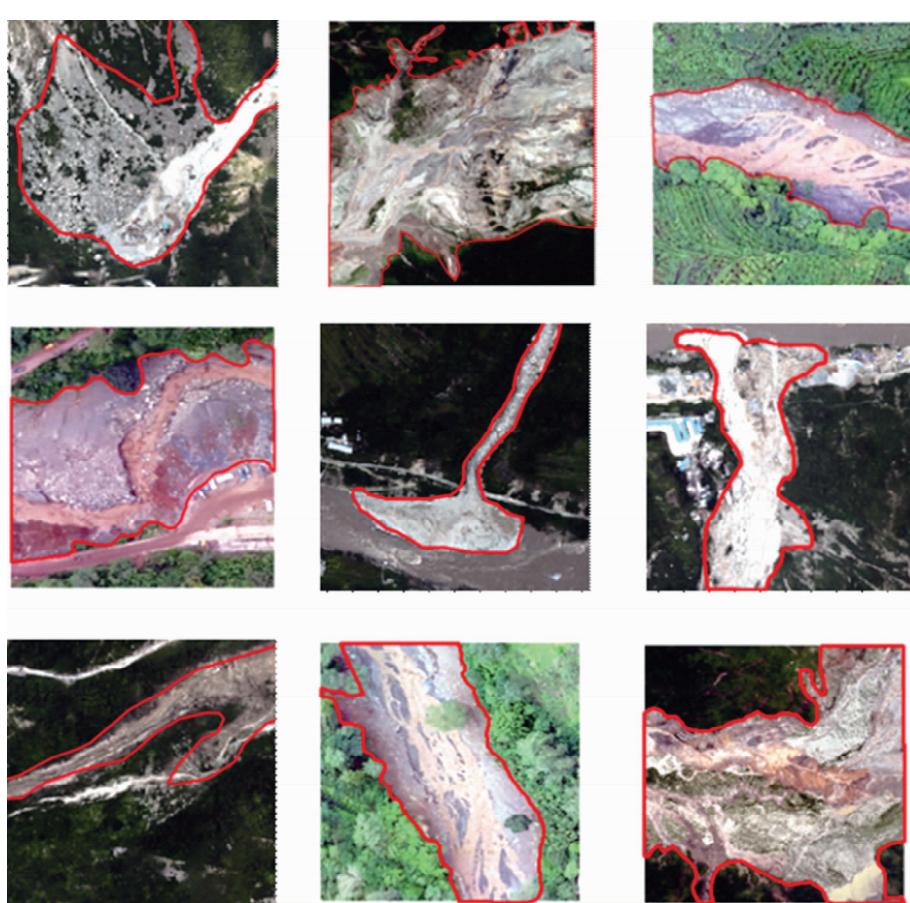


图2 无人机高分影像地震泥石流样本示例

Fig. 2 Sample examples of high-spatial resolution image of seismic debris flow from unmanned aerial vehicle

1.2 技术路线与方法

1.2.1 基于面向对象分类技术的地震泥石流灾害信息检测

在遥感领域，面向对象的分类技术是基于目标（对象）的一种分类方法，是针对高分辨率影像应用而兴起的一种影像分类技术，能够充分利用高分辨率遥感影像的光谱、纹理、形状、空间信息、相邻关系等实现影像的分割和对象的分类，使分类结果更加接近于目视判读的结果，可有效地提高分类精度。目前，面向对象的分类技术已被广泛应用于遥感影像分类中，面向对象分类技术有2个重要特征和技术关键：选取合适的分割尺

度对高分辨率影像进行分割，使检测的地物能在最合适的分割尺度中凸显出来；选取分割对象的多种典型特征建立地物的分类规则进行检测或分类（李宏宏，2013）。

影像多尺度分割是通过同质性及异质性准则获取多个对象，而不同的分割参数设置会得到不同的分割效果（鲁恒等，2011）。图3为不同分割尺度下的分割结果，由于本次多尺度分割形状参数和紧凑度参数对分割结果影响较小，故将2个参数固定，对比尺度参数对分割结果的影响。通过多个分割参数下的分割效果，可以灵活地选择影响分类任务所需的最优分割参数，从而提高分类精度。

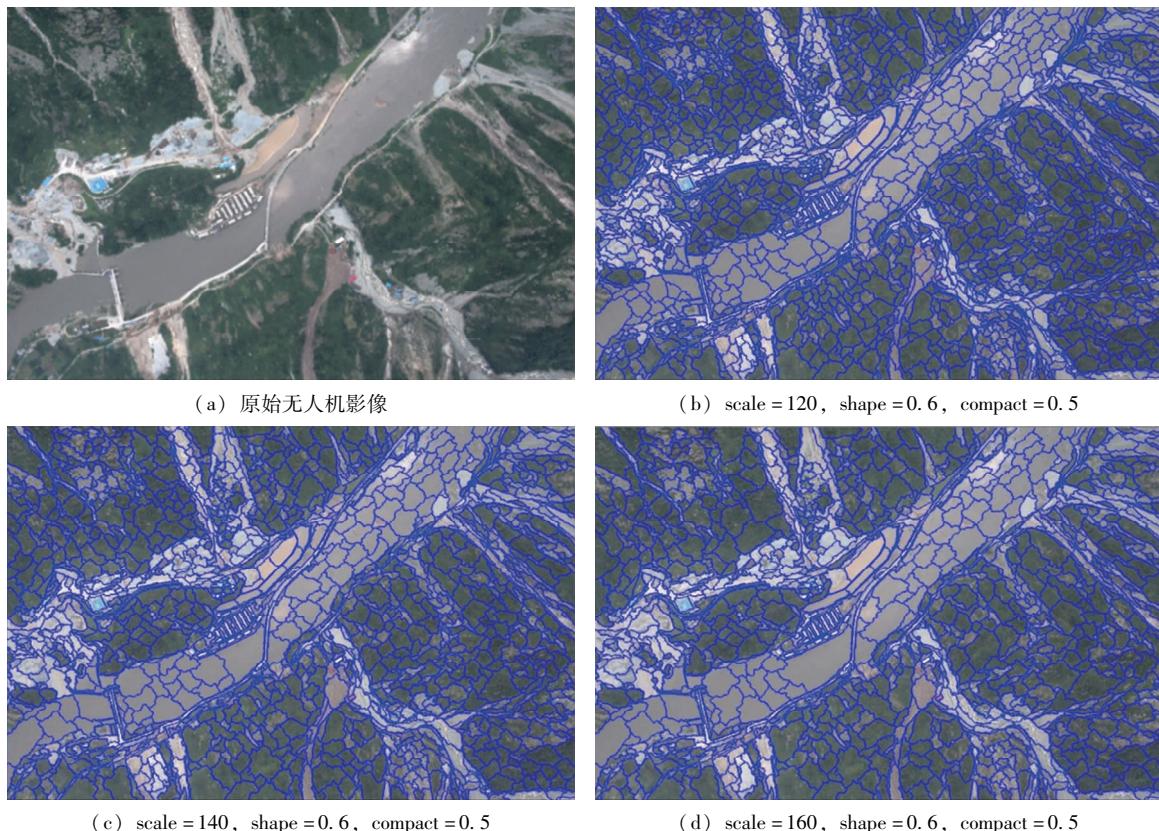


图3 不同分割尺度下的效果图

Fig. 3 Effect diagrams under different segmentation scales

通过计算异质度来判断的分割对象的好坏程度，计算公式如下：

$$f = w \cdot h_{\text{color}} + (1 - w) \cdot h_{\text{shape}} \quad (1)$$

式中： f 表示总的分割对象的异质度； w 为用户给定义的形状参数占的权重，取值范围为 0 ~ 1；光谱异质度为 h_{color} ，形状异质度为 h_{shape} ，且由 2 个

参数组成，即紧凑度异质度 h_{compact} 和光滑度异质度 h_{smooth} 。

形状异质度的计算公式如下：

$$h_{\text{shape}} = w_{\text{compact}} \cdot h_{\text{compact}} + (1 - w_{\text{compact}}) \cdot h_{\text{smooth}} \quad (2)$$

式中： w_{compact} 为紧凑度异质度的权重，取值范围为 0 ~ 1。

光谱异质度的计算公式如下：

$$h_{\text{color}} = \sum_c w_c \left[n_{\text{merge}} \cdot \sigma_c^{\text{merge}} - (n_{\text{obj1}} \cdot \sigma_c^{\text{obj1}} + n_{\text{obj2}} \cdot \sigma_c^{\text{obj2}}) \right] \quad (3)$$

式中： w_c 表示参与分割合并的波段权重； n_{merge} 、 σ_c^{merge} 分别表示合并后的区域面积和光谱方差； n_{obj1} 、 σ_c^{obj1} 、 n_{obj2} 、 σ_c^{obj2} 分别为 2 个相邻区域的面积和光谱方差。

光滑度和紧致度的计算公式如下：

$$h_{\text{smooth}} = n_{\text{merge}} \cdot \frac{l_{\text{merge}}}{b_{\text{merge}}} - (n_{\text{obj1}} \cdot \frac{l_{\text{obj1}}}{b_{\text{obj1}}} + n_{\text{obj2}} \cdot \frac{l_{\text{obj2}}}{b_{\text{obj2}}}) \quad (4)$$

$$h_{\text{compact}} = n_{\text{merge}} \cdot \frac{l_{\text{merge}}}{\sqrt{n_{\text{merge}}}} - (n_{\text{obj1}} \cdot \frac{l_{\text{obj1}}}{\sqrt{n_{\text{obj1}}}} + n_{\text{obj2}} \cdot \frac{l_{\text{obj2}}}{\sqrt{n_{\text{obj2}}}}) \quad (5)$$

式中： l_{merge} 、 b_{merge} 分别表示合并后的区域周长和外界矩形的周长， l_{obj1} 、 b_{obj1} ， l_{obj2} 、 b_{obj2} 分别为 2 个相邻区域的周长和外界矩形的周长。根据形状参数和光谱参数来不断调整进行分割，最后得到理想的分割对象，调整尺度参数可间接调整影像对象大小，大的参数值得到大的对象，反之亦然。

在影像多尺度分割后，选取地震泥石流灾害信息检测所需的最优分割参数，通过对高分影像分割对象特征信息进行分析，选取可用于地震泥石流灾害信息检测的特征，然后根据特征信息建立检测地震泥石流灾害信息的自定义特征，最终完成地震泥石流信息的检测。这里将实验影像分为地震泥石流区域和非地震泥石流区域。为检测地震泥石流区域，建立自定义特征 H ：

$$H = 2 \times B - G - R \quad (6)$$

式中： R 、 G 、 B 分别表示无人机影像红、绿、蓝三通道的平均值。当 H 属于区间 $[30, 50]$ ，且所有波段的亮度均值（Brightness）在区间 $[150, 196]$ 范围内，则判别为地震泥石流灾害信息未分类的信息则判读为非地震泥石流信息。

1.2.2 基于迁移学习的地震泥石流灾害信息检测

卷积神经网络（CNN）是一个多层次结构学习算法，可通过分析空间相对关系来提高训练效率（Zeiler, Fergus, 2014）。CNN 包含卷积层和下采样层两个部分，其中卷积层通过输入影像和特定

的卷积模板进行卷积运算生成，通过卷积层的特征图进行下采样可得到下采样层。卷积层和下采样层不断反复交替，再加上诸多全连接层组成一个完整的卷积神经网络。

通过构建卷积神经网络线状地物剔除模型，剔除道路、河流等线状地类，既可保持检测的地震泥石流信息的完整性，又可以减少线状地物对检测结果的干扰。构建的卷积神经网络线状地物剔除模型包括 1 个输入层、3 个卷积层、1 个 FC256 全连接层以及 1 个 FC2 输出层，如图 4 所示。图中 FC2 输出层的输出结果为线状地类与非线状地类，其中输出的非线状地类结果将作为迁移学习支持下地震泥石流灾害信息检测的参数进行输入。

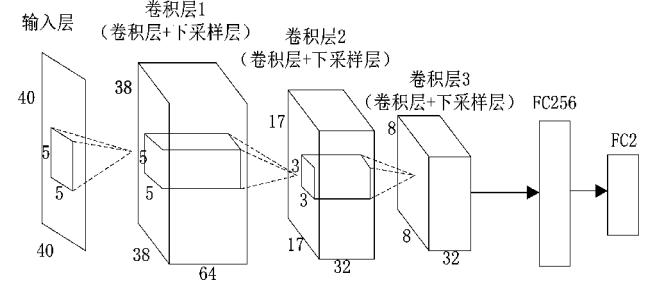


图 4 卷积神经网络线状地类剔除模型

Fig. 4 Linear class elimination model
of convolution neural network

从图 2 地震泥石流的示例样本中可以看出，地震泥石流的空间形状各异、纹理变化大，且由于采集的多期数据，样本的光谱差异较大。利用已构建的地震泥石流灾害样本库，通过上一步卷积神经网络线状地物剔除模型，利用支持向量机（SVM）分类器将线状地物剔除在该模型中的特征检测方法迁移到地震泥石流信息检测中，构建如图 5 所示的基于迁移学习的地震泥石流灾害信息检测流程。

迁移学习支持下的地震泥石流灾害信息检测，主要包括特征学习、特征迁移以及地震泥石流信息检测模型训练。针对特征学习阶段，通过训练样本库，采用如图 4 所示的卷积神经网络线状地物剔除模型。特征迁移阶段，将卷积神经网络训练得到的参数进行转移，保持模型各层参数不变，选择一个输出层，输出地震泥石流灾害特征。模型训练阶段，将特征迁移阶段输出的泥石流特征向量输入支持向量机（SVM）分类器，进行模型训练。

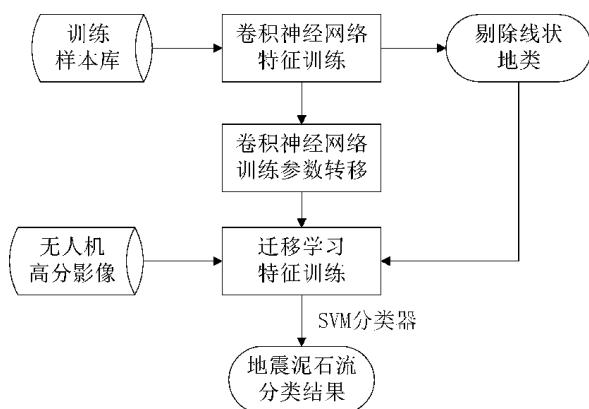


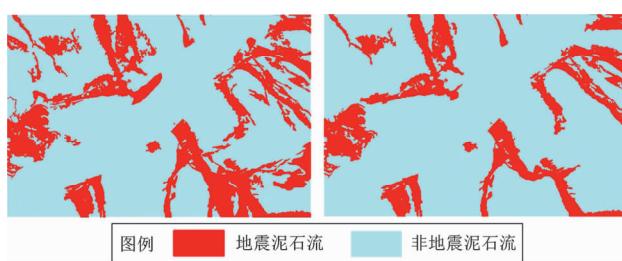
图 5 迁移学习检测地震泥石流灾害信息流程

Fig. 5 Transfer learning and detection of seismic debris flow disaster information flow

2 实验及结果分析

2.1 地震泥石流信息检测结果

实验选取图 3a 的无人机高分影像作为实验数据, 根据本文提出的面向对象分类技术, 通过反复分割实验, 获得研究的无人机高分影像的最优分割尺度为 140, 形状参数为 0.6, 紧致度参数为 0.5。最终通过面向对象的分类方法检测该区域地震泥石流灾害信息, 结果如图 6a 所示。1.2.2 节基于迁移学习的地震泥石流灾害信息检测流程中, 需通过对比分析正负样本输入各层的激活情况来分析特征迁移的训练结果。实验发现, 地震泥石流的正样本和负样本在 FC6 层的激活情况较好, 可适用于区分地震泥石流与非地震泥石流。该方法对地震泥石流信息检测结果如图 6b 所示。



(a) 面向对象分类方法 (b) 基于迁移学习的信息检测方法

图 6 2 种方法检测的地震泥石流结果

Fig. 6 The results of seismic debris flow detected by two methods

2.2 精度分析

针对上述地震泥石流二分类问题, 采用混淆

矩阵, 通过计算真正类率 (TPR)、负正类率 (FPR) 以及分类准确度 (ACC), 来评价本次地震泥石流信息检测的精度。精度评价体系见表 1。

表 1 地震泥石流信息实际检测精度评价体系

Tab. 1 Accuracy evaluation system for seismic debris flow information detection

		面向对象分类法		基于迁移学习的信息检测方法	
		地震泥石流	非地震泥石流	地震泥石流	非地震泥石流
地震泥石流	45	9	43	11	
非地震泥石流	12	76	8	80	

从表 1 可以得出, 面向对象分类法对该区域地震泥石流的检测 TPR 为 83.33%, FPR 为 13.64%, 分类准确度 ACC 约为 85.21%; 而本文提出的基于迁移学习的该区域地震泥石流检测 FPR 为 9.10%, TPR 为 79.63%, 分类准确度 ACC 则达到了 86.62%。从以上参数可以看出, 面向对象的分类方法在真正类率上要优于基于迁移学习的信息检测方法, 但在负正类率上前者不如后者, 这说明面向对象的分类方法将更多的非目标类检测为目标类, 从而导致在分类准确度上, 基于迁移学习的地震泥石流信息检测方法要高于面向对象的分类方法。

3 结语

如何在地震灾后第一时间通过获取的无人机高分影像自动检测泥石流等灾害信息, 已成为目前地震应急响应工作中的难点。本文结合卷积神经网络和迁移学习方法, 提出了一套行之有效的地震泥石流灾害信息自动检测方法, 该方法的检测精度优于面向对象的分类方法, 且有效减少将非目标对象混淆为目标对象的情况。但该方法也存在样本需求量大、训练过程复杂、计算资源要求高等缺点。同时, 考虑到该方法应用在空间数据信息检测上的巨大潜力, 今后将向多源数据的融合, 将其运用到其它高分影像中, 为地震灾后信息检测, 包括建筑物倒塌、道路桥梁破坏等信息检测提供可靠的技术方法。

参考文献:

李宏宏. 2013. 面向对象的高分辨率遥感影像分类及泥石流信息提取研究 [D]. 南京:南京理工大学.

- 鲁恒,李永树,唐敏. 2011. 面向对象的山地区域多源遥感影像分割尺度选择及评价[J]. 山地学报,29(6):688-694.
- 彭述刚. 2014. 汶川县震后泥石流遥感信息提取与监测评估研究[D]. 湘潭:湖南科技大学.
- 任娟. 2015. 基于无人机遥感与GIS技术的泥石流灾害监测[D]. 成都:成都理工大学.
- 唐川. 2010. 汶川地震区暴雨滑坡泥石流活动趋势预测[J]. 山地学报,28(3):341-349.
- 殷跃平. 2008. 汶川八级地震地质灾害研究[J]. 工程地质学报,16(4):433-444.
- 周洋,明小娜,杨艳珠,等. 灾评新技术在云龙5.0级地震烈度调查中的应用[J]. 地震研究,40(1):161-166.
- Mikolov T, Chen K, Corrado G, et al. 2013. Efficient Estimation of Word Representations in Vector Space[J/OL]. (2013-09-07) [2016-12-14]. <https://arxiv.org/pdf/1301.3781v3.pdf>.
- Saha B, Gupta S, Phung D, et al. 2016. Multiple task transfer learning with small sample sizes[J]. Knowledge & Information Systems, 46(2):315-342.
- Weiss K, Khoshgoftaar T M, Wang D D. 2016. A survey of transfer learning[J]. Journal of Big Data, 3(1):9.
- Zeiler M D, Fergus R. 2014. Visualizing and Understanding Convolutional Networks[C]//European Conference on Computer Vision. Springer, Cham:818-833.

Seismic Debris Flow Information Detection for High Resolution Images of UAV Based on Transfer Learning

GUO Jiawei^{1,2}, LI Yongshu¹, WANG Hongshu³, LU Heng^{4,5}

- (1. Faculty of Geosciences and Environmental Engineering, Southwest Jiaotong University, Chengdu 611756, Sichuan, China)
 (2. Information Technology Center of Chengdu Planning and Management Bureau, Chengdu 610094, Sichuan, China)
 (3. Department of Surveying and Mapping Engineering, Sichuan Water Conservancy Vocational College, Chengdu 611231, Sichuan, China)
 (4. State Key Laboratory of Hydraulics and Mountain River Engineering, Sichuan University, Chengdu 610065, Sichuan, China)
 (5. College of Hydraulic and Hydroelectric Engineering, Sichuan University, Chengdu 610065, Sichuan, China)

Abstract

A lot of debris flow disasters (known as the earthquake debris – flow) occurred in post – earthquake, which cause great damage. UAV low – altitude remote sensing technology has the characteristics of convenience, timeliness and so on, and becomes a means of rapid access to disaster information. However, the spectral information of the UAV images is not enough, and it is difficult to detect the information of the earthquake debris flow disaster accurately. Taking into account of the above problems, a method based on transfer learning mechanism for earthquake debris flow detection was proposed. Based on the established earthquake debris flow disaster sample database, features trained by convolution neural network were transferred to earthquake debris flow information detection and the information was detected automatically. The earthquake debris flow information detected based on object – oriented and transfer learning were compared and analyzed. The experimental results showed that the information detection result of earthquake debris flow disaster based on transfer learning was slightly better than that of object – oriented and the former was better than the latter in maintaining smoothness and integrity of earthquake debris flow.

Keywords: earthquake; debris flow; UAV high – spatial resolution images; transfer learning; information detection