

## Detection of sinkholes and landslides using deep-learning methods and UAV images

Narges Kariminejad<sup>1</sup>, Hamid Reza Pourghasemi<sup>2\*</sup>, Mohsen Hosseinalizadeh<sup>3</sup> and Vahid Shafaie<sup>4</sup>

<sup>1</sup> Department of Natural Resources and Environmental Engineering, College of Agriculture, Shiraz University, Shiraz, Iran

<sup>2</sup> Department of Soil Science, College of Agriculture, Shiraz University, Shiraz, Iran

<sup>3</sup> Department of Arid Zone Management, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

<sup>4</sup> Department of Structural and Geotechnical Engineering, Széchenyi István University, 9026 Győr, Hungary

Received: 22 December 2023

Accepted: 21 April 2024

### Extended abstract

#### Introduction

Landslides and sinkholes damage social, economic, and natural infrastructure. These processes have direct and indirect impacts on important infrastructure, including residential areas, and influence land use change and migration from rural to urban areas. Sinkholes and landslides occur when parts of a soil collapse mainly in more gentle or steeper slopes, which are often triggered by intensive rainfall. One of the main goals in sustainable land management is the identification and control of natural disasters, which on the one hand leads to the quantitative and qualitative improvement of production in the long term, and on the other hand, maintains the quality of the soil and prevents soil degradation. In order to manage better and more stable, it seems necessary to know how to change and identify different forms of erosion such as sinkholes and landslides. Sinkholes and landslides occur when parts of a soil collapse mainly in more gentle or steeper slopes, which are often triggered by intensive rainfall.

#### Materials and methods

Recent advances in acquiring images from unmanned aerial vehicles (UAV) (UAV) and deep learning (DL) methods inherited from computer vision have made it feasible to propose semi-automated soil landform detection methodologies for large areas at an unprecedented spatial resolution. In this study, we evaluate the potential of two cutting-edge DL deep learning segmentation models, the vanilla U-Net model, and the Attention Deep Supervision Multi-Scale U-Net model, applied to UAV-derived products, to map landslides and sinkholes in a semi-arid environment, the “Golestan Province” (north-east Iran).

#### Results and discussion

**Landslides:** The performance of the U-Net model shows that it has fewer false positives, but at the same time, it has missed many landslide cells. Meanwhile, the ADSMS U-Net model has performed better in detecting landslide cells, but it attributed many cases to incorrect predictions (which is explained by the low accuracy score). The best F1 score achieved for the ADSMS U-Net model is 0.68. **Sinkholes:** For all band combinations, the performances of ADSMS U-Net are better than those of the traditional U-Net model. The best overall scores by ADSMS U-Net were obtained when trained on the ALL data. Regarding the effectiveness of the various combinations evaluated in this study, we can observe the contradictory behaviors of the models. The traditional U-Net achieves the best performance using the RGB optical combination, while the ADSMS U-Net can leverage topographic derivative information and optical data, showing the best results with the ALL combination. Moreover, it is evident that the DSHC data alone provides the worst results for both models. In overall, the results show that the ability of ADSMS U-Net to predict landslides is closer to the ground reality compared to U-Net. This model identifies most of the landslides in the test sections. Also, for all combinations of sinkhole bands, ADSMS U-Net performs better than the U-Net model. The best overall scores were obtained by ADSMS U-Net when trained on ALL data.

\* Corresponding author: hamidreza.porghasemi@yahoo.com

### Conclusions

Since this kind of soil erosion is the main origin of some major soil erosion including gully initiation and extension, applying new technology namely, UAV and deep learning is highly important and recommended. Our framework can successfully map landslides in a challenging environment (with an F1-score of 69 %), and topographical derivatives from UAV-derived DSM decrease the capacity of mapping sinkholes and landslides of the models calibrated with optical data. Future research could explore the use of such an approach to map landslides and sinkholes over time to assess time-based changes in the formation and spread of natural hazards.

**Keywords:** ADSMS U-Net model, Fixed-wing drones, Photogrammetry, Topography, U-Net model

Cite this article: Kariminejad, N., Pourghasemi, H.R., Hosseinalizadeh, M., Shafaie, V., 2024. Detection of sinkholes and landslides using deep-learning methods and UAV images. *Watershed Engineering and Management* 16(3), 316-330.

© 2024, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)



## تشخیص فروچاله‌ها و زمین‌لغزش‌ها با استفاده از روش‌های یادگیری عمیق و تصاویر پهپادی

نرگس کریمی نژاد<sup>۱</sup>، حمیدرضا پورقاسمی<sup>۲\*</sup>، محسن حسینعلی زاده<sup>۳</sup> و وحید شفائی<sup>۴</sup>

<sup>۱</sup> استادیار، گروه مهندسی محیط زیست و منابع طبیعی، دانشکده کشاورزی، دانشگاه شیراز، شیراز، ایران

<sup>۲</sup> استاد، گروه مهندسی خاک، دانشکده کشاورزی، دانشگاه شیراز، شیراز، ایران

<sup>۳</sup> دانشیار، گروه مدیریت مناطق بیابانی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

<sup>۴</sup> دانشجو دکتری، گروه مهندسی سازه و ژئوتکنیک، دانشگاه Széchenyi István، ۹۰۲۶ گیور، مجارستان

تاریخ پذیرش: ۱۴۰۳/۰۲/۰۲

تاریخ دریافت: ۱۴۰۲/۱۰/۰۱

### چکیده مبسوط

#### مقدمه

زمین‌لغزش‌ها و فروچاله‌ها به زیرساخت‌های اجتماعی، اقتصادی و طبیعی آسیب می‌زنند. این فرایندها تأثیرات مستقیم و غیرمستقیم بر زیرساخت‌های مهم، از جمله مناطق مسکونی دارند و بر تغییر کاربری اراضی و مهاجرت از روستا به شهر تأثیرگذارند. یکی از اهداف اصلی در مدیریت پایدار اراضی، شناسایی و کنترل بلایای طبیعی است که از یک سو سبب ارتقاء کمی و کیفی تولید در طولانی مدت شده و از سوی دیگر، علاوه بر حفظ کیفیت خاک از تخریب خاک جلوگیری می‌کند. به منظور مدیریت بهتر و پایدارتر، آگاهی از نحوه تغییرپذیری و شناسایی شکل‌های مختلف فرسایشی مانند فروچاله‌ها و زمین‌لغزش‌ها ضروری به نظر می‌رسد.

### مواد و روش‌ها

با پیشرفت‌های اخیر در استفاده از تصاویر پهپاد (UAV) و روش‌های یادگیری عمیق (DL)، امکان ارائه روش‌های نیمه خودکار برای شناسایی واحدهای اراضی در مناطق مختلف با دقت مکانی بسیار خوب فراهم شده است. در این پژوهش، توانمندی دو مدل یادگیری عمیق پیشرفته، یعنی مدل U-Net و مدل U-Net با نظارت عمیق (ADSMS) که بر روی تصاویر به دست آمده از پهپاد اعمال شده است، برای نقشه‌برداری زمین‌لغزش‌ها و فروچاله‌ها در بخشی از نهبشته‌های لسی استان گلستان مورد بررسی قرار گرفته است.

### نتایج و بحث

عملکرد مدل U-Net در زمینه زمین‌لغزش‌ها نشان می‌دهد که مدل دارای مقادیر مثبت کاذب کمتری است، اما هم‌زمان، بسیاری از سلول‌های زمین‌لغزش را از دست داده است. در عین حال، مدل ADSMS U-Net در تشخیص سلول‌های زمین‌لغزش عملکرد بهتری داشته، اما موارد زیادی را به پیش‌بینی‌های نادرست نسبت داد (که با امتیاز پایین دقت توضیح داده شده است). بهترین امتیاز F1 به مقدار ۰/۶۸ برای مدل ADSMS U-Net به دست آمده است. برای همه ترکیب باندها در تشخیص فروچاله‌ها، عملکردهای ADSMS U-Net نسبت به مدل U-Net سنتی بهتر است. بهترین امتیازات کلی توسط ADSMS U-Net زمانی به دست آمد که بر روی داده‌های ALL، آموزش داده شد. در مورد اثربخشی مختلف

ترکیب‌های ارزیابی شده در این پژوهش، می‌توان رفتار متناقض مدل‌ها را مشاهده کرد. U-Net سنتی، بهترین عملکرد را با استفاده از ترکیب نوری RGB به دست می‌آورد، در حالی که ADSMS U-Net می‌تواند از اطلاعات مشتقات توپوگرافی و داده‌های نوری بهره برده و با ترکیب ALL بهترین نتایج را نشان دهد. علاوه بر این، واضح است که داده‌های DSHC به تنهایی برای هر دو مدل بدترین نتایج را ارائه می‌دهد. به طور کلی نتایج نشان داد که قابلیت ADSMS U-Net برای پیش‌بینی زمین‌لغزش‌ها در مقایسه با U-Net به واقعیت زمین نزدیک‌تر است. این مدل اغلب زمین‌لغزش‌های موجود در قسمت‌های آزمون را شناسایی می‌کند. همچنین، برای همه ترکیب باند‌های فروچاله‌ها، عملکرد ADSMS U-Net نسبت به مدل U-Net بهتر است. بهترین امتیازات کلی توسط ADSMS U-Net زمانی به دست آمده است که بر روی داده‌های ALL آموزش داده شده‌اند.

### نتیجه‌گیری

از آنجایی که فروچاله‌ها منشأ اصلی برخی از فرسایش‌های عمده دیگر از جمله شروع و گسترش آب‌کنند محسوب می‌شوند، استفاده از ابزارها و فناوری جدید نظیر پهپاد و یادگیری عمیق، بسیار مهم است. با استفاده از مدل‌های مورد استفاده در این پژوهش، زمین‌لغزش‌ها با امتیاز قابل قبول  $F1=69\%$  نقشه‌برداری شدند. همچنین، مشتقات توپوگرافیکی به دست آمده از مدل رقومی ارتفاع مبتنی بر پهپاد، توانایی نقشه‌برداری فروچاله‌ها و زمین‌لغزش‌ها با داده‌های موجود را دارا هستند. تحقیقات بعدی می‌توانند استفاده از چنین رویکردی را برای نقشه‌برداری از زمین‌لغزش‌ها و فروچاله‌ها در طول زمان مورد بررسی قرار داده تا تغییرات مبتنی بر زمان بر روی شکل‌گیری و گسترش مخاطرات طبیعی را ارزیابی کنند.

**واژه‌های کلیدی:** پهپاد بال ثابت، توپوگرافیکی، فتوگرامتری، مدل ADSMS U-Net، مدل U-Net

### مقدمه

باید توجه داشت که نتایج مورد نظر بسیار به دقت داده‌های ورودی وابسته هستند (Ghorbanzadeh et al., 2018). با فناوری پیشرفته سنجش از دور (ماهواره، هواپیما و پهپاد) کارایی نقشه‌برداری بلایای طبیعی در اقلیم‌های مختلف، مکان‌های صعب‌العبور و متأثر از فعالیت‌های نامناسب انسانی فراهم شده است. همچنین، سنجش از دور امکان نقشه‌برداری بزرگ مقیاس را فراهم می‌کند (Fernández et al., 2016).

از طرفی، پهپادها<sup>۱</sup> وسیله‌ای مناسب برای تهیه داده‌های میدانی به‌روز و دقیق هستند (Zhang et al., 2019؛ Ghorbanzadeh et al., 2019). امروزه استفاده از این ابزارها در شناسایی عوامل مؤثر بر ایجاد و گسترش بلایای طبیعی، در حال توسعه است (Watson et al., 2019؛ Windrim et al., 2019) و در مقایسه با تصاویر ماهواره‌ای (دوربرد) که عموماً دقت پایینی دارند، توانایی تهیه داده با وضوح مکانی بالاتر را فراهم می‌کند (Brovkina et al., 2018). اخیراً، UAV در تهیه نقشه‌های حساسیت به بلایای طبیعی در

تجزیه و تحلیل زمین‌لغزش‌ها عمدتاً به منظور شناسایی مناطق تحت تأثیر آنها انجام می‌شود (Mezaal et al., 2018؛ Wajaya et al., 2024؛ Asadi Nalivan et al., 2023). فروچاله‌ها در محدوده وسیعی در سراسر جهان در حال گسترش هستند (Poesen, 2018). آنها تأثیرات زیادی بر هیدرولوژی داشته و نقش عمده‌ای در تکامل سیمای سرزمین اعم از تخریب و فرسایش ایفا می‌کنند (Jones and Crane, 1984). این نوع رخساره‌ها به شبکه‌های زهکشی/آبراهه متصل شده (Bernatek et al., 2015) و منجر به گسترش کانال‌های زیرسطحی می‌شوند (Higgins et al., 1990).

برای شناسایی زمین‌لغزش‌ها و فروچاله‌ها لازم است که داده‌های دقیق و قابل دسترس از مخاطرات قبلی و نقشه مکانی آنها برای شناسایی مناطق مستعد به زمین‌لغزش و فروچاله مورد بررسی قرار گیرد (Chen et al., 2021؛ Agrawal et al., 2017). همچنین،

<sup>1</sup> Unmanned Aerial Vehicles (UAVs)

به‌طور قابل‌توجهی بر تراکم فرسایش آب‌کندی در منطقه تأثیر می‌گذارد. همچنین، نتایج حاکی از آن است که چارچوب یکپارچه می‌تواند در مناطقی که داده به‌اندازه کافی در دسترس نیست، مفید باشد.

نتایج بررسی Pourghasemi et al., (2017) در منطقه‌ای به وسعت ۲۵۹۵ هکتار در ارزیابی عملکرد مدل‌های ترکیبی با استفاده از تصاویر ماهواره‌ای لندست و در سه کاربری مرتع، کشاورزی و اراضی بدون پوشش گیاهی، بیانگر دقت بالای مدل ANN-SVM با مقدار سطح زیر منحنی ۰/۸۹ بوده است. از طرفی، نتایج بررسی عوامل مؤثر نشان داد که فاصله از رودخانه، تراکم زهکشی و کاربری زمین بیشترین تأثیر را در وقوع فرسایش آب‌کندی در منطقه مورد مطالعه داشته‌اند. Hoai et al., (2019)، رویکرد ردیابی فروچاله را ارائه دادند که از پیشرفت‌های اخیر در یادگیری انتقال CNN بر روی تصاویر مادون قرمز استفاده می‌کند. با این حال، هنوز مشخص نیست که آیا چنین روش‌هایی در مناطق نیمه‌خشک و با استفاده از تصاویر رنگی<sup>۶</sup> سنتی (و معمولاً در دسترس‌تر) قابل اجرا خواهد یا نخواهد بود. در مورد زمین لغزش‌ها، مطالعات اندکی وجود دارد که از تصاویر پهپاد با وضوح بسیار بالا همراه با الگوریتم‌های یادگیری عمیق برای نقشه‌برداری خودکار استفاده شده است. Ghorbanzadeh et al., (2019) در پژوهشی، با آموزش داده‌های مختلف CNN به دنبال تهیه نقشه زمین‌لغزش‌ها در یک منطقه جنگلی متراکم هیمالیا بوده است.

Karantanelis et al., (2021) چندین مدل یادگیری ماشین را با تجزیه و تحلیل تصاویر شیء‌گرا مقایسه کردند تا مرزهای زمین لغزش‌ها را در یونان تعیین نمایند. نتایج کار آنها نشان داد، زمانی که اطلاعات مدل رقومی سطح زمین<sup>۷</sup> یکپارچه شده بود، عملکرد بالاتری برای نقشه‌برداری زمین‌لغزش‌ها ایجاد شد. از این رو، پیکربندی لایه‌های طیفی و مدل رقومی سطح زمین با مدل جنگل تصادفی منجر به بالاترین طبقه‌بندی شد. پیشینه تحقیقات نشان می‌دهد که در مطالعات اندکی، نقشه‌برداری خودکار زمین لغزش‌ها و

دامنه‌های لسی شرق استان گلستان توسط Kariminejad et al., (2022) به‌کار برده شد که طبق گزارش ارائه شده توسط آنها، محدوده مطالعاتی بیشترین حساسیت را نسبت به فروچاله‌ها داشته و زمین‌لغزش‌ها و سرآب‌کندها در رتبه‌های بعدی قرار دارند. UAVها در برخی مطالعات برای جمع‌آوری داده‌های زمین‌لغزش و بررسی سایر رخساره‌های فرسایشی نیز به‌کار برده شده‌اند (Lin et al., 2010؛ Yang et al., 2015؛ Fernández et al., 2016)، اما فناوری تحلیل و طبقه‌بندی تصاویر پهپاد در پژوهش حاضر برای تشخیص فروچاله‌ها و زمین‌لغزش‌ها کمتر مورد مطالعه قرار گرفته است.

رویکردهایی که برای تجزیه و تحلیل یا طبقه‌بندی تصاویر استفاده می‌شوند، عمدتاً مبتنی بر سلول‌ها و شیء‌گرا بوده که برای تشخیص بلایای طبیعی با استفاده از الگوریتم‌های یادگیری ماشین و یادگیری عمیق توسعه یافته‌اند (Dou et al.; Hölbling et al., 2012؛ Mezaal et al., 2018؛ 2015). اخیراً، مدل‌های یادگیری عمیق برای تفکیک و طبقه‌بندی تصاویر سنجش‌ازدور استفاده شده‌اند (Du et al., 2019؛ Qayyum et al., 2019؛ Ghadi et al., 2022). بر اساس مطالعات صورت‌گرفته، در حال حاضر فناوری‌های خودکار بر اساس روش‌های یادگیری عمیق برای تهیه نقشه‌های فروچاله‌ها متداول نیست. Lee et al., (2016) شبکه‌های کانولوشنی نوری<sup>۱</sup> را بر روی تصاویر مادون قرمز<sup>۲</sup> برای تهیه نقشه‌های فروچاله‌ها در مناطق شهری استفاده کردند. لازم به توضیح است که شبکه عصبی کانولوشنی، یکی از بهترین روش‌ها برای حل مسائل حوزه بصری ماشین، مانند طبقه‌بندی تصاویر<sup>۳</sup>، شناسایی تصاویر<sup>۴</sup> و تشخیص چهره<sup>۵</sup> است.

Rahmati et al., (2017) به منظور تعیین ویژگی‌های فرسایش آب‌کندی، به تلفیق روش طبقه‌بندی شیء‌گرا GEOBIA و تصاویر ماهواره SPOT 5 پرداختند. نتایج بیانگر دقت مناسب مدل‌های مذکور (۹۲/۴ درصد) بوده است. بر اساس نتایج حاصل از تحلیل حساسیت، بافت خاک، تراکم زهکشی و سنگ‌شناسی

<sup>5</sup> Face Recognition

<sup>6</sup> RGB

<sup>7</sup> DSM

<sup>1</sup> Convolutional Neural Network (CNN)

<sup>2</sup> FIR

<sup>3</sup> Image Classification

<sup>4</sup> Image Detection

از گونه‌های گیاهی موجود در قسمت مرتعی می‌توان به گونه‌های علفی خودرو و یک‌ساله، نیزار، گراس‌ها و درختچه‌های انار، سیاه‌تلو و انجیر وحشی و درخت عرعر اشاره نمود. اراضی کشاورزی حدوداً ۵۸/۸ درصد از محدوده مطالعاتی است که به‌صورت کشت دیم بوده و محصولاتی از قبیل گندم، جو و کلزا توسط کشاورزان کشت می‌شود.

**تهیه داده‌های ورودی:** عکس‌برداری فتوگرامتری مبتنی بر پهپاد، باعث شناسایی دقیق محل زمین‌لغزش و فروچاله می‌شود. در این پژوهش، از پهپاد بال ثابت<sup>۱</sup> با دوربین Sensefly Aeria X با فاصله کانونی ۱۸/۵۰ میلی‌متر استفاده شد (شکل ۱). اندازه سلول نقشه افقی نهایی، پنج سانتی‌متر به‌دست آمد.

برنامه کنترل پرواز senseFly eMotion، توسط اپراتور با تجربه طراحی شد. RTK<sup>۲</sup> نیز تنظیم و مسیرهای پهپاد با در نظر گرفتن همپوشانی ۷۰ درصدی عرضی و ۸۵ درصدی طولی مشخص شد. همچنین، میانگین ارتفاع این پرواز ۲۲۰ متر بالاتر از سطح زمین بوده است و برای پردازش تصاویر هوایی از برنامه فتوگرامتری Pix4Dmapper استفاده شد.

برای هر تصویر ترکیبی (جدول ۱)، یک محدوده بزرگ از کل منطقه تحقیقاتی برای ساخت بانک اطلاعاتی مورد نیاز استخراج شد که سه، چهار یا هفت باند بوده است و بسته به ترتیب باند، ابعادی به اندازه ۵۱۲ × ۵۱۲ پیکسل داشتند. در مورد داده‌های زمین لغزش، تعداد سلول‌ها در منطقه مورد مطالعه، ۲۰۶۴۲۸۸ سلول در داخل زمین‌لغزش‌ها و ۴۸۷۸۶۸۶۲۲ سلول در طبقه پس‌زمینه، به نسبت ۲۳۶ وجود دارد. موزاییک و ماسک به قطعات ۵۱۲ × ۵۱۲ پیکسل بدون همپوشانی تقسیم که در این مورد به ایجاد ۶۵۰۸ قطعه منجر شد.

در مورد داده فروچاله، ۲۰۹۶۲۴۱ سلول متعلق به طبقه فروچاله‌ها و ۱۸۶۴۴۱۵۹۸۳ سلول در طبقه پس‌زمینه به نسبت ۸۹۹ به‌دست آمد. در هر دو مورد، فقط تصاویری ثبت شدند که حداقل یک سلول از هدف تحقیقاتی را در بر گرفته بودند (۱۳۲ تصویر برای زمین‌لغزش‌ها و ۲۰۳ تصویر مربوط به فروچاله‌ها). این

فروچاله‌ها توسط پهپاد با فناوری‌های یادگیری عمیق انجام شده است. استفاده از چارچوب یادگیری عمیق در کنار پهپاد، روشی جدید برای شناسایی زمین‌لغزش‌ها و فروچاله‌ها است.

همچنین، به‌دلیل مشکلات ناشی از اختلاف طیفی کم، امکان استفاده از روش‌های مشابه در مناطق نیمه خشک وجود ندارند. در این پژوهش، کارآمدی رویکردهای خودکار مبتنی بر یادگیری عمیق و مزایا و معایب استفاده از آنها برای شناسایی فروچاله‌ها و زمین لغزش‌ها با استفاده از اطلاعات طیفی برگرفته از تصاویر پهپاد و مجموعه داده‌های توپوگرافی مورد بررسی قرار گرفته است. همچنین، نقشه‌های خروجی تهیه شده با استفاده از رویکردهای خودکار با داده‌های استخراجی از فروچاله‌ها و زمین‌لغزش‌ها به‌صورت دستی مقایسه شدند. در انتها، فروچاله‌ها و زمین‌لغزش‌ها شناسایی شده با استفاده از فناوری‌های اعتبارسنجی بصری رایانه‌ای مورد بررسی قرار گرفتند.

## مواد و روش‌ها

**منطقه مورد مطالعه:** منطقه مطالعاتی در استان گلستان واقع شده است که بین عرض‌های جغرافیایی " ۱۷' ۳۹" تا " ۳۶' ۳۶" ۳۷° شمالی و طول‌های جغرافیایی " ۴۹' ۳۶" ۵۵° تا " ۴۳' ۰۶" ۵۵° شرقی واقع شده است. این منطقه با مساحت ۵۱۵ هکتار، دارای اقلیم نیمه‌خشک است. منطقه مطالعاتی، دارای میانگین بارندگی سالیانه ۴۵۰ میلی‌متر و کمینه و بیشینه ارتفاع از سطح دریا به ترتیب ۲۱۱ و ۵۴۹ متر است. بافت اصلی خاک در این منطقه رسی ماسه‌ای است و کل منطقه پوشیده از لس است. علاوه بر آن، یکی از مناطقی است که برای دامداران و کشاورزان بسیار حائز اهمیت است. نهشته‌های لسی در این محدوده مطالعاتی، حاصلخیز و شکننده بوده و از این رو، در برابر مخاطرات طبیعی از جمله فروچاله و زمین‌لغزش مستعد به فرسایش است. محدوده مطالعاتی دارای دو کاربری کشاورزی و مرتع است. مراتع حوضه مطالعاتی سطحی معادل ۴۱/۲ درصد از کل سطح را تشکیل می‌دهد.

<sup>2</sup> Real time kinematics

<sup>1</sup> Sensefly eBee x

فرایند اعتبارسنجی استفاده شد (Agrawal et al., 2017).

رویکرد نمونه‌گیری برای کاهش اختلاف بین طبقه‌ها و همچنین ارائه مقدار ثابتی از سلول‌های هدف انتخاب شد. از ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای



شکل ۱- پهپاد بال ثابت به کار رفته برای نقشه‌برداری هوایی و نمونه‌هایی از اشکال فرسایشی در محدوده مطالعاتی  
Fig. 1. Fixed-wing drones using for aerial mapping and some samples of erosional landforms in the study area

مطالعات قبلی (Ghorbanzadeh et al., 2019) مشخص شد که تصویربرداری از زمین<sup>۱</sup> با استفاده از شیب، مناسب‌ترین ترکیب باند است.

در مورد شناسایی فروچاله‌ها، سه ترکیب باند مختلف، یعنی RGB (نوری)، DHSC (مشتقات توپوگرافی) و ترکیبی از مشتقات نوری و توپوگرافی (ALL) مورد ارزیابی قرار گرفت (جدول ۱).

مجموعه داده‌های اعتبارسنجی دیگر با استفاده از ۲۰ درصد مجموعه داده‌های آموزش ایجاد شد. در هر دو مورد، قطعات بدون همپوشانی نمونه‌برداری شدند تا از سوءگیری در فرایند کالیبراسیون جلوگیری شود. در نهایت، بیشترین و کمترین مقادیر سلول برای هر قطعه بین ۰ و ۱ استاندارد شد (Nava et al., 2022). همچنین، در این پژوهش چهار ترکیب باند مختلف مورد بررسی قرار گرفت. برای کار نقشه‌برداری زمین لغزش، از ترکیب RGBS استفاده شد، زیرا بر اساس



جدول ۱- ارزیابی زمین‌لغزش و فروچاله با سه ترکیب باند مختلف، RGB، DHSC و ترکیب نوری و مشتقات توپوگرافی (ALL)

Table 1. Landslide and sinkhole evaluation with three different band combinations, namely, RGB, DHSC, and the combination of optical and topographical derivatives (ALL)

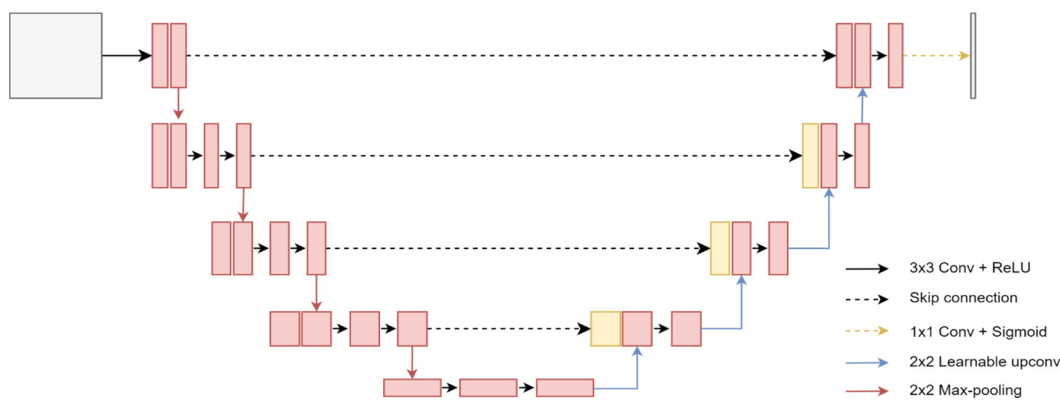
Target	Dataset	Band1	Band2	Band3	Band4	Band5	Band6	Band7
Landslides	RGBS	Red	Green	Blue	Slope	x	x	x
	RGB	Red	Green	Blue	x	x	x	x
Sinkholes	DSHC	DSM	Slope	Hillshade	P Curve	x	x	x
	ALL	Red	Green	Blue	DSM	Slope	Hillshade	Profile Curve

کانولوشنی تشکیل شده است. هر بلوک کانولوشنی دو لایه کانولوشن با اندازه هسته  $3 \times 3$  و یک لایه بیشینه‌گیری  $2 \times 2$  دارد. هر لایه از شبکه کانولوشنی توسط تابع فعال‌سازی واحد خطی اصلاح‌شده<sup>۱</sup> فعال می‌شود (Agarap, 2018).

به‌منظور انجام نمونه‌برداری کاهش‌ی غیرخطی، یک لایه بیشینه‌گیری  $2 \times 2$  در انتهای بلوک کانولوشنی در مسیر کدگذار قرار داده شده است. در مقابل، لایه‌های نمونه‌برداری افزایشی  $2 \times 2$  داخل مسیر رمزگشا اضافه شده به‌دنبال آن از یک لایه کانولوشنی افزایشی  $3 \times 3$  می‌آید (شکل ۲). از این ترکیب به‌عنوان کانولوشن (پیچش) آموزش‌پذیر یاد می‌شود (Kundu et al., 2020).

مدل‌های یادگیری عمیق، U-Net: بسیاری از متخصصان از شیوه‌های تفکیک مناسبی از جمله U-Net برای تشخیص بلایای طبیعی از جمله زمین‌لغزش استفاده کرده‌اند که نتایج خوبی را به دنبال داشته است (Chandra et al., 2023). در گذشته از روش U-Net برای تفکیک تصاویر زیست-پزشکی استفاده می‌شد (Ronneberger et al., 2015)، اما امروزه با موفقیت در چندین پژوهش مربوط به منابع طبیعی مانند تشخیص زمین‌لغزش‌ها نیز استفاده شده است (Bhuyan et al., 2022; Meena et al., 2022; Nava et al., 2022).

در این روش، یک مسیر قراردادی (رمزگذار) نمایش‌های سطح پایین و یک مسیر رمزگشا نمایش‌های سطح بالا را ثبت می‌نماید. مسیر رمزگذاری مانند ساختار سنتی CNN است و از بلوک‌های پیاپی



شکل ۲- مدل U-Net سنتی (Nava et al., 2022)

Fig. 2. The architecture of the conventional U-Net model (Nava et al., 2022)

تقسیم‌بندی ضایعات پوستی ارائه شده، استفاده می‌شود (شکل ۳). با این مدل می‌توان اطلاعات طبقه‌بندی شده را جمع‌آوری کرد که از ورودی‌های چند مقیاسی و در مقیاس‌های مختلف به‌دست آمده است. این موضوع هم برای ویژگی‌های پس‌زمینه و هم برای اهداف موردنظر

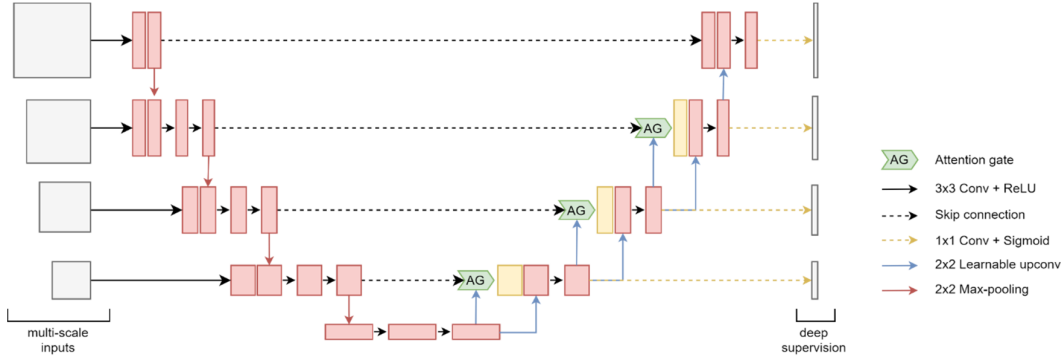
مدل ADSMS U-Net: ساختار U-Net سنتی نقاط ضعف قابل توجهی دارد، به‌ویژه زمانی که با داده‌های نامتعادل و هدف‌های کوچکی مانند مطالعه کنونی کار می‌شود. برای غلبه بر این محدودیت، از مدل ADSMS U-Net که توسط Abraham and Khan, (2019) برای

<sup>1</sup> ReLU



هستند، نظارت عمیق یک نظم‌دهی قوی انجام می‌دهد.

صدق می‌کند. علاوه بر این، به‌دلیل کانولوشن‌های تسلسلی، به‌دست‌آوردن پیش‌بینی‌های نادرست برای اشیاء کوچک با تغییر شکل بالا ساده است. در نهایت، زمانی که داده‌های آموزشی محدود و شبکه‌ها کم‌عمق



شکل ۳- مدل ADSMS U-Net (Nava et al., 2022)

Fig. 3. The architecture of the ADSMS U-Net model (Nava et al., 2022)

مثبت واقعی (TP)، منفی واقعی (TN)، مثبت کاذب (FP) و منفی کاذب (FN) به‌دست آمد (رابطه‌های ۱ تا ۴). برای محاسبه Precision و Recall نیاز است TP، FP و FN برای تشخیص شیء<sup>۴</sup> تعریف شود.

این کار با در نظر گرفتن دقت localization انجام می‌شود (Nava et al., 2022). Recall نسبت زمین لغزش‌ها یا فروچاله‌ها در داده‌های برچسب‌گذاری شده است که با دقت توسط مدل شناسایی می‌شوند و امتیاز F1-score تعادل بین معیارهای دقت و فراخوان است. تقاطع روی اتحاد<sup>۵</sup> به سمت همپوشانی پیش‌بینی‌ها و حقیقت زمینی نزدیک می‌شود. معیار IoU دقت localization را با مقایسه میزان روی هم افتادگی مرجع و پیشگویی شده مشخص می‌کند (Nava et al., 2022).

$$Precision: p = \frac{TP}{(TP+FP)} \quad (1)$$

$$Recall: r = \frac{TP}{(TP+FN)} \quad (2)$$

$$F1-score: f = 2 \frac{(p \cdot r)}{(p + r)} \quad (3)$$

$$IoU: i = \frac{TP}{(TP+FP+FN)} \quad (4)$$

### نتایج و بحث

نتایج به‌کارگیری مدل‌های U-Net و ADSMS U-Net برای شناسایی زمین‌لغزش‌ها و فروچاله‌ها در

آموزش مدل‌ها: هنگام آموزش U-Net، آنتروپی متقاطع دودویی به‌عنوان یک تابع اعمال می‌شود. به‌عنوان یک استثنا، خروجی نهایی مدل ADSMS U-Net توسط Tversky Loss معمولی هدایت می‌شود. در عین حال، در همان حال، کنترل هر نمایشی از ویژگی‌های با ابعاد بالا توسط تلفیق ضرر تورسکی متمرکز<sup>۱</sup> انجام می‌شود تا از وقوع خسارت پیشگیری شود. طبق پژوهش‌های Lee et al., (2015)، لایه‌های میانی در این فناوری نظارت عمیق، باید از نظر معنایی در مقیاس‌های مختلف متمایز باشند. با این روش می‌توان مطمئن شد که ماژول توجه، قابلیت تغییر در واکنش به محرک‌های بصری زمینه‌ای را دارد.

این فناوری از Abraham and Khan, (2019) الهام گرفته شده است که مدل ADSMS U-Net با آن ارائه شد. برای هر دو مدل، از یک روش کاهش گرادینت تصادفی<sup>۲</sup> استفاده شد که در مسائلی که داده‌هایی با گرادینت‌های پراکنده است، مؤثر است (Kingma and Ba, 2014).

ارزیابی دقت مدل‌ها: در این پژوهش، معیارهای دقت استاندارد Precision، Recall، F1-score و Intersection Over-Union<sup>۳</sup> برای نتایج با استفاده از

<sup>4</sup> Object detection

<sup>5</sup> Intersection over Union (IoU)

<sup>1</sup> Focal Tversky Loss

<sup>2</sup> Adam

<sup>3</sup> IOU

مدل ADSMS U-Net به دست آمده است (جدول ۲). شکل ۴، قابلیت پیش‌بینی دو مدل را نشان می‌دهد. به‌ویژه قابلیت ADSMS U-Net که پیش‌بینی‌های آن در مقایسه با U-Net به واقعیت زمین نزدیک‌تر است. این مدل اغلب زمین‌لغزش‌های موجود در قسمت‌های آزمون را شناسایی می‌کند. در برخی موارد، پیش‌بینی عوارض زمین‌لغزش حتی دقیق‌تر از نقشه‌برداری دستی به‌عنوان واقعیت زمین بوده است (شکل ۴). مدل U-Net، پیش‌بینی‌های مثبت گمراه‌کننده‌ای از زمین‌لغزش ایجاد می‌کند. استفاده از ADSMS U-Net این طبقه‌بندی اشتباه را از بین می‌برد و امکان تعیین دقیق‌تر چندضلعی‌های زمین‌لغزش هدف را فراهم می‌نماید.

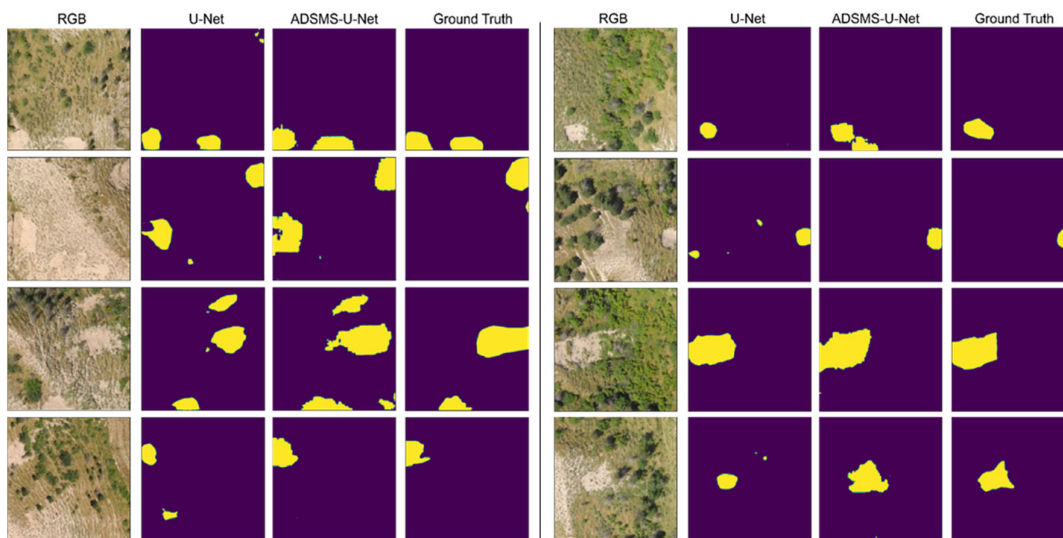
تصاویر پهنای نشان داده شده است. نتایج طبقه‌بندی برای زمین‌لغزش‌ها در جدول ۲ و برای فروچاله‌ها در جدول ۳، آورده شده است. همچنین، برای دستیابی به بهترین نتایج، ابرعامل‌ها برای هر دو مدل تنظیم شده‌اند.

زمین‌لغزش‌ها: هنگام اجرای دو مدل، هر دو مدل در قابلیت‌های پیش‌بینی خود گرایش‌های کاملاً متضادی داشتند. عملکرد مدل U-Net نشان می‌دهد، مدل دارای مقادیر مثبت کاذب کمتری است، اما بسیاری از سلول‌های زمین‌لغزش را از دست داده است. درعین‌حال، مدل ADSMS U-Net در تشخیص سلول‌های زمین‌لغزش عملکرد بهتری داشته، اما موارد زیادی را به پیش‌بینی‌های نادرست نسبت داد (که با امتیاز پایین دقت توضیح داده شده است). بهترین امتیاز F1 به مقدار ۰/۶۸ برای

جدول ۲- نقشه‌برداری زمین لغزش: معیارهای ارزیابی برای مدل‌های U-Net و ADSMS U-Net بر روی قسمت‌های آزمون نشده بر اساس داده‌های RGBS

**Table 2.** Landslide mapping: evaluation metrics for the U-Net and ADSMS U-Net models on the unseen test set on the RGBS dataset

Model	Dataset	Batch Size	Learning Rate	Filters	Precision	Recall	F1-Score	IOU Score
U-Net	RGBS	8	0.0005	8	0.7225	0.6000	0.6444	0.4778
ADSMS U-Net	RGBS	4	0.0001	8	0.6488	0.7631	0.6896	0.5281



شکل ۴- پیش‌بینی‌های زمین‌لغزش توسط دو مدل یادگیری عمیق مورد استفاده در این پژوهش بر روی قسمت‌های آزمون نشده بر اساس داده‌های RGBS

Fig. 4. Landslide predictions by the two DL models used in this research on the unseen test set patches on the RGBS dataset

U-Net، زمانی به دست آمد که بر روی داده‌های ALL ، آموزش داده شد. در مورد اثربخشی مختلف ترکیب‌های ارزیابی شده در این پژوهش، می‌توان رفتار

فروچاله‌ها: برای همه ترکیب باندها، عملکردهای ADSMS U-Net نسبت به مدل U-Net سنتی بهتر است. بهترین امتیازات کلی توسط ADSMS

پیش‌بینی‌های نادرست مرزهای فروچاله را مشاهده کرد. به‌طور کلی، آموزش با داده‌های RGB از داده‌هایی که صرفاً از داده‌های توپوگرافی مبتنی بر پهپاد تهیه شده باشند، بهتر عمل می‌کند.

با این حال، همان‌طور که در تصاویر رنگی واقعی دیده می‌شود، اغلب درختان در فروچاله‌ها وجود دارند و بنابراین، هنگام استفاده از DSM<sup>1</sup>ها در تشخیص فروچاله‌ها باعث ایجاد خطا می‌شود. بنابراین، اندازه‌گیری عمق فروچاله‌ها توسط پوشش گیاهی مختل می‌شود و DSM حاصل اغلب ساختار واقعی فروچاله را نشان نمی‌دهد.

متناقض مدل‌ها را مشاهده کرد. U-Net سنتی، بهترین عملکرد را با استفاده از ترکیب نوری RGB به‌دست می‌آورد، درحالی‌که ADSMS U-Net می‌تواند از اطلاعات مشتقات توپوگرافی و داده‌های نوری بهره‌برده و با ترکیب ALL، بهترین نتایج را نشان دهد. علاوه بر این، واضح است که داده‌های DSHC به‌تنهایی برای هر دو مدل بدترین نتایج را ارائه می‌دهد (جدول ۳).

با ارزیابی بصری نتایج در شکل ۵، می‌توان متوجه تمایل مدل‌ها به پیش‌بینی ناقص نتایج هنگام استفاده از مشتقات توپوگرافی به‌عنوان تنها ابزار پیش‌بینی شد. از طرف دیگر، هنگام استفاده از داده‌های RGB و ALL، می‌توان مشاهده کرد که تقریباً تمام اشیاء به‌درستی پیش‌بینی شده‌اند. با این حال، می‌توان بعضی از

**جدول ۳-** نقشه‌برداری فروچاله‌ها: معیارهای ارزیابی برای مدل‌های U-Net و ADSMS U-Net بر روی مجموعه آزمون شده بر اساس داده‌های ALL و DSHC, RGB

**Table 3.** Sinkhole mapping: evaluation metrics for the U-Net and ADSMS U-Net models on the unseen test set for the RGB, DSHC, and ALL datasets

Model	Dataset	Batch Size	Learning Rate	Filters	Precision	Recall	F1-Score	IOU Score
U-Net	RGB	8	0.0005	4	0.4646	0.4613	0.4624	0.3018
	DSHC	8	0.0001	8	0.1422	0.5137	0.2143	0.1204
	ALL	4	0.0005	4	0.5398	0.3707	0.4394	0.2829
ADSMS U-Net	RGB	4	0.0001	16	0.4173	0.6403	0.5045	0.3380
	DSHC	4	0.0001	32	0.3937	0.3410	0.3643	0.2246
	ALL	4	0.0001	32	0.5059	0.5382	0.5215	0.3527

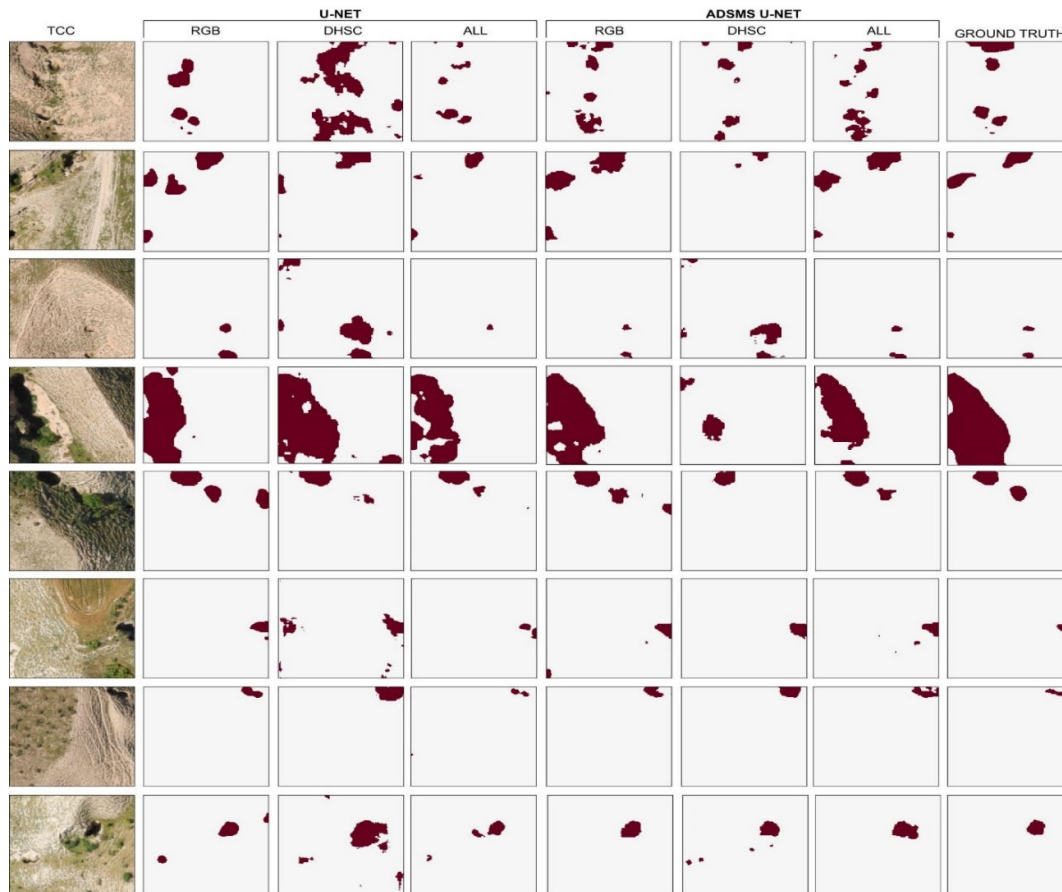
کاذبی از زمین‌لغزش‌ها را ارائه می‌دهد. این تمایل به طبقه‌بندی نادرست، هنگام استفاده از ADSMS U-Net صورت نمی‌گیرد و این مورد باعث ارتقای قابلیت پیش‌بینی خوب مدل دوم می‌شود. این رفتار به‌دلیل ورودی چند مقیاسی است که قبلاً توضیح داده شده است.

در مورد فروچاله‌ها، واضح است که برخی فروچاله‌ها با داده‌های RGB به‌راحتی قابل تشخیص هستند. این تفاوت می‌تواند به‌دلیل وجود درختان در بیشتر فروچاله‌ها باشد که هم توسط داده‌های نوری و هم DSM به اثبات رسیده است. با این حال، هنگام استفاده از مجموعه داده ALL، با ترکیب اطلاعات نوری و توپوگرافی به ADSMS U-Net، می‌توان به بالاترین عملکرد نقشه‌برداری دست یافت.

امروزه، فناوری خودکار تنها گزینه قابل‌قبول برای نقشه‌برداری در مناطق گسترده با دقت مکانی و زمانی مناسب (در یک بازه زمانی کوتاه) برای اهداف علمی و عملیاتی در زمینه بررسی بلایای طبیعی همچون زمین‌لغزش و فروچاله است. با این حال، فرایندهای مؤثر، قابل تکرار و دقیق برای تشخیص خودکار زمین‌لغزش در تصاویر پهپادی با وضوح بالا در حال حاضر وجود ندارد. ترکیب RGB، به‌عنوان یک راه‌حل قابل‌قبول برای نقشه‌برداری خودکار زمین‌لغزش با مدل‌های یادگیری عمیق به اثبات رسیده است.

در این مورد، پیش‌بینی‌های قابل اعتماد توسط U-Net و ADSMS U-Net حاصل شد. با این حال، می‌توان گفت که با استفاده از U-Net طبقه‌بندی مثبت کاذب زمین‌لغزش‌ها در جایی که رخ نداده‌اند را می‌توان ارائه داد و شبکه U-Net در چنین حالتی، طبقه‌بندی مثبت

<sup>1</sup>Digital Surface Model



شکل ۵- تشخیص فروچاله توسط دو مدل یادگیری عمیق بر روی قسمت‌های آزموده نشده بر اساس داده‌های RGB، DHSC و ALL  
 Fig. 5. Sinkhole predictions by the two DL models used in this research on the unseen test set patches on RGB, DHSC, and ALL datasets

هنوز تحقیقات اندکی با روش‌های خودکار مبتنی بر یادگیری عمیق برای نقشه‌برداری فروچاله‌ها انجام شده است (Hoai et al., 2019). همچنین، در مطالعات محدودی از تصاویر پهپادی با وضوح بالا در ترکیب با الگوریتم‌های یادگیری عمیق برای نقشه‌برداری لغزش زمین استفاده شده است. Ghorbanzadeh et al., (2019)، چندین مدل CNN را آموزش داده‌اند تا زمین‌لغزش را در منطقه‌ای با پوشش گیاهی زیاد در هیمالیا نقشه‌برداری نمایند (امتیاز  $F1=0.85$ ). در این پژوهش، محیط نیمه‌خشک موضوع را حتی چالش برانگیزتر کرد.

در این راستا، Karantanellis et al., (2021)، چندین مدل یادگیری ماشین را همراه با تجزیه و تحلیل تصویر شیء‌گرا ارزیابی کردند تا مرزهای دو زمین‌لغزش چرخشی در یونان را تشخیص دهند (امتیاز  $F1=0.85$ ).

اگر عملکرد U-Net روی هر دو داده موردنظر ADSHC و ALL را مورد تجزیه و تحلیل قرار دهیم، واضح است که با چنین مدلی نمی‌توان با موفقیت از اطلاعات حاصل از لایه‌های توپوگرافی بهره برد. از طرف دیگر، توانایی ADSMS U-Net در به دست آوردن دقت‌های بالاتر می‌تواند به این دلیل باشد که در این مدل از مکانیزمی استفاده می‌شود که امکان حفظ اطلاعات سطح پایین را در حین کانولوشن فراهم می‌کند و هم زمان، ورودی‌های چند مقیاسی به مدل این امکان را می‌دهد که اطلاعات کلاسی که در مقیاس‌های مختلف به راحتی در دسترس است، جمع‌آوری شود. به نظر می‌رسد که می‌توان از این چارچوب به‌ویژه در شرایطی که وضوح داده‌ها مانند چنین مواردی بسیار بالا است، استفاده کرد.

زمین‌لغزش‌ها است. یافته‌ها نشان می‌دهد که مشتقات توپوگرافی از DSM برگرفته از پهپاد راه‌حل قابل قبول و مستدلی برای نقشه‌برداری از فروچاله‌ها نیست. تحقیقات بعدی می‌توانند استفاده از چنین رویکردی را برای نقشه‌برداری از زمین‌لغزش‌ها و فروچاله‌ها در طول زمان مورد بررسی قرار داده تا تغییرات مبتنی بر زمان بر روی شکل‌گیری و گسترش مخاطرات طبیعی را ارزیابی کنند.

### تشکر و قدردانی

نویسندگان از Lorenzo Nava و تیم علمی وی به‌خاطر اظهارات سازنده‌شان در مورد روش‌هایی که به طور قابل‌توجهی کیفیت مقاله را ارتقا داده است، قدردانی می‌کنند.

### تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مسئله مورد تأیید همه نویسندگان است.

در این مورد، تنها دو زمین‌لغزش در مجموعه آزمون وجود داشت. همچنین، این نتایج ممکن است در مناطق با مقیاس بزرگ‌تر مورد پذیرش قرار نگیرد.

### نتیجه‌گیری

در این پژوهش، روش‌های تشخیص سریع فروچاله و زمین‌لغزش در یک منطقه نیمه‌خشک مورد بررسی قرار گرفت و عملکرد پیش‌بینی مدل پیشنهادی در مقایسه با U-Net سنتی ارزیابی، تجزیه و تحلیل شد. علاوه بر آن، استفاده از DSM برگرفته از پهپاد برای شناسایی فروچاله‌ها از دیدگاه دو مدل پیشرفته بررسی شد. همچنین، به طور هدفمند یک مکان مناسب برای نقشه‌برداری انتخاب شد تا رویکردی تطبیقی و قابل‌اعتماد در شرایط تشخیص سخت ایجاد شود. این مطالعه یکی از اولین نقشه‌برداری‌های فروچاله‌ها و زمین‌لغزش‌ها در یک منطقه نیمه‌خشک محسوب می‌شود. علاوه بر این، اولین پژوهشی است که در آن از مدل ADSMS U-Net در ارتباط با داده‌های پهپاد به‌کار گرفته شده است. نتایج نشان می‌دهد که ترکیب یادگیری عمیق و داده‌های برگرفته از پهپاد به عنوان یک رویکرد و ابزار قابل‌اعتماد برای نقشه‌برداری

### منابع مورد استفاده

- Abraham, N., Khan, N.M., 2019. A novel focal tversky loss function with improved attention U-Net for lesion segmentation. In 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), IEEE., 683-687.
- Agarap, A.F., 2018. Deep learning using rectified linear units (relu). arXiv preprint arXiv:1803.08375.
- Agrawal, K., Baweja, Y., Dwivedi, D., Saha, R., Prasad, P., Agrawal, S., Kapoor, S., Chaturvedi, P., Mali, N., Kala, V.U. Dutt, V., 2017. A comparison of class imbalance techniques for real-world landslide predictions. In 2017 international conference on machine learning and data science (MLDS), IEEE., 1-8.
- Asadi Nalivan, O., Rahmani, M., Vakili Tajreh, F., Bayat, A., 2024. Prioritization of factors and zoning susceptibility of landslide in Karaj Dam Watershed. Watershed Engineering and Management 16(1), 1-14.
- Bernatek-Jakiel, A., 2015. The influence of piping on mid-mountain relief: A case study from the polish bieszczady Mts. (Eastern Carpathians). CJEEs, 10(1), 107-120.
- Bernatek-Jakiel, A., Poesen, J., 2018. Subsurface erosion by soil piping: significance and research needs. Earth Sci. Rev. 185, 1107-1128.
- Brovkina, O. Cienciala, E. Surovy, P., Janata, P., 2018. Unmanned Aerial Vehicles (UAV) for assessment of qualitative classification of norway spruce in temperate forest stands. Geo. Spat. Inf. Sci. 21, 12-20.
- Chandra, N., Sawant, S., Vaidya, H., 2023. An Efficient U-Net model for improved landslide detection from satellite images. J. Photogramm. Remote Sens. Geoinf. 1-16.
- Chen, Y., Chen, W., Janizadeh, S., Bhunia, G.S., Bera, A., Pham, Q.B., Linh, N.T.T., Balogun, A.L., Wang, X., 2021. Deep learning and boosting framework for piping erosion susceptibility modeling: spatial evaluation of agricultural areas in the semi-arid region. Geocarto Int. 1-27.
- Dou, J. Chang, K.-T. Chen, S. Yunus, A. Liu, J.-K. Xia, H. Zhu, Z., 2015. Automatic case-based reasoning approach for landslide detection: Integration of object-oriented image analysis and a genetic algorithm. Remote Sens. 7, 4318.

- Du, Z., Yang, J., Ou, C., Zhang, T., 2019. Smallholder crop area mapped with a semantic segmentation deep learning method. *Remote Sens.* 11, 888.
- Fernández, T., Pérez, J.L., Cardenal, J., Gómez, J.M., Colomo, C., Delgado, J., 2016. Analysis of landslide evolution affecting olive groves using uav and photogrammetric techniques. *Remote Sens.* 8, 837.
- Ghadi, Y.Y., Rafique, A.A., Al Shloul, T., Alsuhibany, S.A., Jalal, A., Park, J., 2022. Robust object categorization and Scene classification over remote sensing images via features fusion and fully convolutional network. *Remote Sens.* 14(7), 1550.
- Ghorbanzadeh, O., Meena, S.R., Blaschke, T., Aryal, J., 2019. UAV-based landslide detection using deep-learning convolutional neural networks. *Remote Sens.* 11(17), 2046.
- Ghorbanzadeh, O., Rostamzadeh, H., Blaschke, T., Gholaminia, K., Aryal, J., 2018. A new gis-based data mining technique using an adaptive neuro-fuzzy inference system (anfis) and k-fold cross-validation approach for land subsidence susceptibility mapping. *Nat. Hazards* 94, 497–517.
- Higgins, C.G., Coates, D.R., 1990. *Groundwater geomorphology: The role of subsurface water in Earth-surface processes and landforms* (Vol. 252). Geological Society of America.
- Hoai, N.V., Dung, N.M., Ro, S., 2019, July. Sinkhole detection by deep learning and data association. In 2019 Eleventh International Conference on Ubiquitous and Future Networks (ICUFN) (pp. 211-213). IEEE.
- Hölbling, D., Füreder, P., Antolini, F., Cigna, F., Casagli, N., Lang, S., 2012. A semi-automated object-based approach for landslide detection validated by persistent scatterer interferometry measures and landslide inventories. *Remote Sens.* 4, 1310-1336.
- Hosseinalizadeh, M., Kariminejad, N., Alinejad, M., 2018. An application of different summary statistics for modelling piping collapses and gully headcuts to evaluate their geomorphological interactions in Golestan Province, Iran. *Catena* 171, 613-621.
- Jones, J.A.A., Crane, F.G., 1984. Pipeflow and pipe erosion in the Maesnant experimental catchment. *International Geographical Union Commission on Field Experiments in Geomorphology. Meeting* 55-72.
- Karantanelis, E., Marinos, V., Vassilakis, E., Hölbling, D., 2021. Evaluation of machine learning algorithms for object-based mapping of landslide zones using UAV data. *Geosciences* 11(8), 305.
- Kariminejad, N., Hosseinalizadeh, M., Pourghasemi, H.R., Tiefenbacher, J.P., 2021. Change detection in piping, gully head forms, and mechanisms. *Catena* 206, 105550.
- Kariminejad, N., Pourghasemi, H.R., Hosseinalizadeh, M., 2022. Analytical techniques for mapping multi-hazard with geo - environmental modeling approaches and UAV images. *Sci. Rep.* 1-17.
- Kingma, D.P., Ba, J., 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kundu, S., Mostafa, H., Sridhar, S.N., Sundaresan, S., 2020. Attention-based Image Upsampling. *arXiv preprint arXiv:2012.09904*.
- Lee, C.Y., Xie, S., Gallagher, P., Zhang, Z., Tu, Z., 2015. Deeply-supervised nets. In *Artificial intelligence and statistics* (pp. 562-570). PMLR.
- Lin, J., Tao, H., Wang, Y., Huang, Z., 2010. Practical application of unmanned aerial vehicles for mountain hazards survey. In *Proceedings of the International Conference on Geoinformatics, Beijing, China*.
- Meena, S.R., Mishra, B.K., Tavakkoli Piralilou, S., 2019. A hybrid spatial multi-criteria evaluation method for mapping landslide susceptible areas in kullu valley, himalayas. *Geosciences* 9, 156.
- Meena, S.R., Soares, L.P., Grohmann, C.H., van Westen, C., Bhuyan, K., Singh, R.P., Catani, F., 2022. Landslide detection in the Himalayas using machine learning algorithms and U-Net. *Landslides* 19(5), 1209-1229.
- Mey, J., Guntu, R.K., Plakias, A., Silva de Almeida, I., Schwanghart, W., 2023. More than one landslide per road kilometer—surveying and modelling mass movements along the Rishikesh-Joshimath (NH-7) highway, Uttarakhand, India. *Nat. Hazards Earth Syst. Sci. Discuss.* 1-25.
- Mezaal, M., Pradhan, B., Rizeei, H., 2018, Improving landslide detection from airborne laser scanning data using optimized dempster–shafer. *Remote Sens.* 10, 1029.
- Miura, H., 2019. Fusion analysis of optical satellite images and digital elevation model for quantifying volume in debris flow disaster. *Remote Sens.* 11(9), 1096.
- Nava, L., Bhuyan, K., Meena, S.R., Monserrat, O., Catani, F., 2022. Rapid mapping of landslides on SAR data by attention U-Net. *Remote Sens.* 14(6), 1449.
- Poesen, J., 2018. Soil erosion in the Anthropocene: Research needs. *Earth Surface Processes and Landforms*, 43(1).
- Pourghasemi, H.R., Yousefi, S., Kornejady, A., Cerdà, A., 2017. Performance assessment of individual and ensemble data-mining techniques for gully erosion modeling. *Sci. Total Environ.* 609, 764-775.
- Qayyum, A., Malik, A., M Saad, N., Mazher, M., 2019. Designing deep CNN models based on sparse coding for aerial imagery: a deep-features reduction approach. *European Journal of Remote Sens.* 52(1), 221-239.

- Rahmati, O., Tahmasebipour, N., Haghizadeh, A., Pourghasemi, H.R., Feizizadeh, B., 2017. Evaluation of different machine learning models for predicting and mapping the susceptibility of gully erosion. *Geomorphology* 298, 118-137.
- Ronneberger, O., Fischer, P., Brox, T., 2015. U-Net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (234-241). Springer, Cham.
- Sarro, R., Riquelme, A., García-Davalillo, J.C., Mateos, R.M., Tomás, R., Pastor, J.L., Cano, M., Herrera, G., 2018. Rockfall simulation based on uav photogrammetry data obtained during an emergency declaration: Application at a cultural heritage site. *Remote Sens.* 10, 1923.
- Thakur, M., Kumar, N., Dhiman, R.K., Malik, J.N., 2023. Geological and geotechnical investigations of the Sataun landslide along the Active Sirmauri Tal Fault, Sataun, Northwestern Himalaya, India. *Landslides* 1-19.
- Wang, L., Li, X.A., Zheng, Z.Y., Zheng, H., Ren, Y.B., Chen, W.J., Lei, H.N., 2022. Analysis of the landslide mechanism a under tunnel erosion environment in the south-eastern Loess Plateau in China. *Catena* 212, 106039.
- Watson, C.S., Kargel, J.S., 2019. Tiruwa, B. Uav-derived himalayan topography: Hazard assessments and comparison with global dem products. *Drones* 3, 18.
- Wijaya, I.P., Straka, W., Mergili, M., Ottner, F., Wriessnig, K., Arndt, R., Andreatta, P., Arifianti, Y., Zangerl, C., 2023. Geological characterization and failure analysis of a catastrophic landslide in volcanoclastic soils: the Banjarnegara–Jemblung Landslide (Indonesia). *Q. J. Eng. Geol. Hydrogeol.* 56(1).
- Windrim, L., Bryson, M., McLean, M., Randle, J., 2019. Stone, C. Automated mapping of woody debris over harvested forest plantations using uavs, high-resolution imagery, and machine learning. *Remote Sens.* 11, 733.
- Yang, Z.-h., Lan, H.-x., Gao, X., Li, L.-p., Meng, Y.-s., 2015. Urgent landslide susceptibility assessment in the 2013 lushan earthquake-impacted area, sichuan province, china. *Nat. Hazards.* 75, 2467-2487.
- Zhang, Y., Yue, P., Zhang, G., Guan, T., Lv, M., Zhong, D., 2019. Augmented reality mapping of rock mass discontinuities and rockfall susceptibility based on unmanned aerial vehicle photogrammetry. *Remote Sens.* 11, 1311.