

## Research Paper

# Identification and Segmentation of Flood-affected Areas Using Satellite Images and Deep Learning Methods

Mohadeseh.Mesvari<sup>1</sup>,Reza.Shah-Hosseini<sup>2\*</sup>,<sup>1</sup> PhD student, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran<sup>2</sup> Assistant professor, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran

10.22125/IWE.2023.398951.1721

Received:  
**May 25, 2023**  
Accepted:  
**October 2, 2023**  
Available online:  
**May 5, 2024**

**Keywords:**

**Deep convolutional neural network, deep learning, flood detection, segmentation, Sentinel-1 satellite imagery**

**Abstract**

Floods are one of the natural hazards that occur in many parts of the world and cause irreparable financial and human losses. The management of this crisis has a significant impact on reducing these losses. One of the most important aspects of controlling this crisis is accurately identifying flooded areas. Also, it is crucial to predict flood-prone areas to prevent and reduce losses and casualties related to flooding. In this article, the flood phenomenon in the images has been identified and segmented with the help of Sentinel-1 satellite images and a deep learning encoder-decoder network. These images belong to the regions of Nebraska, North Alabama, Bangladesh, Red River North, and Florence, and the ground truth map of each image, in which the target and non-target classes are shown as zero and one, were provided by NASA in 2021. In this article, flood-affected areas have been identified and segmented using encoder-decoder convolutional neural networks and the aforementioned satellite images. Various criteria were used to evaluate the performance of this method, including accuracy, IoU, F1-Score, and Kappa. Based on the results, this method has shown outstanding performance in identifying and segmenting flooded areas. The IoU obtained during the evaluation process was 96.04%, which is higher than the highest IoU obtained in other comparable studies (76.81%). The metrics for other evaluation criteria, such as Precision, F1-Score, and Kappa, consistently exceed the 95% threshold. Additionally, our research introduces a comprehensive model aimed at identifying flood-affected regions across various geographical areas, addressing the challenge posed by the use of satellite images from distinct regions in both the training and test datasets.

## 1. Introduction

Floods are hazardous natural disasters impacting the world and causing millions of fatalities. They are the most impactful natural disasters globally, with a significant presence in the United States and elsewhere. Floods result in severe financial losses and require timely prediction and assessment of

\* **Corresponding Author:** Reza Shah-Hosseini  
**Address:** Geospatial Engineering, College of Engineering,  
University of Tehran, Tehran, Iran

**Email:** rshahosseini@ut.ac.ir  
**Tel:** +989122161949

flood-prone areas. They account for the most fatalities among natural disasters, with 47% of major disasters in 2019 being flood-related. Climate change has contributed to global warming, increasing the likelihood of floods due to rising temperatures and more intense rainfall. Floods can be sudden, riverine, or coastal, with urban areas particularly susceptible due to population density. This research focuses on riverine floods, as urbanization and climate change make these more common.

Accurate flood mapping is crucial for risk reduction and decision-making. Advances in remote sensing, artificial intelligence, and deep learning have improved flood mapping, offering potential cost and time savings. Synthetic-aperture radar (SAR) imaging has gained popularity for capturing images day and night under various conditions. Studies have used remote sensing data and deep learning algorithms for tasks like land use classification, real-time monitoring, flood volume estimation, modeling, detection, and post-flood damage assessment to enhance flood risk understanding and management strategies.

## 2. Materials and Methods

### Study area

The dataset used for the research was obtained from the ETCI 2021 NASA competition website. The images in this dataset are obtained from five different regions: Bangladesh, Florence of Italy, Nebraska, and Alabama in the United States, as well as Red River North, located on the border of the United States and Canada. The study utilized 66,810 satellite images from the Sentinel-1 mission, with VV and VH polarizations, in a dimension of 256×256 pixels. Labeling was performed for all these images, distinguishing the flooded areas and water bodies using a value of 1, while other regions were assigned a value of 0.

### Proposed method

This paper discusses using an encoder-decoder neural network in image processing, particularly flood detection. The network architecture is influenced by U-Net and SegNet models and employs 2D convolutional blocks with batch normalization to prevent overfitting. It uses the ReLU activation function to handle image data effectively. The network extracts features through an encoder path, reconstructs them through a decoder path, and generates the final output (target and non-target classes) using binary cross-entropy loss function.

The encoder path consists of five convolutional layers and employs a weighted loss function due to differences in target and non-target pixels. Softmax activation is used in the final layer to normalize output values. In the decoder path, features are reconstructed in four layers, and the Sigmoid function is applied to generate the final output representing two classes. Model training utilizes the Adam optimizer with a learning rate of 0.01.

## 3. Discussion and Conclusion

This study evaluates a deep learning model's performance for identifying flood-affected areas in satellite images, specifically using Sentinel-1 images and a convolutional encoder-decoder neural network. The model's training process includes assessing accuracy, IoU, F1-Score, and Kappa on a test dataset. Comparatively, previous methods on the same dataset had lower IoU values, with the model in this paper reaching an IoU of 96.04%. The method effectively combines deep learning techniques, considers image characteristics, applies suitable loss and activation functions, and fine-tunes parameters for efficient flood identification and segmentation. It can be applied to various time intervals for flood detection and prediction.

#### 4. Six important references

- 1) Wang, Y., et al., Flood susceptibility mapping in Dingnan County (China) using adaptive neuro-fuzzy inference system with biogeography-based optimization and imperialistic competitive algorithm. *Journal of environmental management*, 2019. 247: p. 712-729.
- 2) Tanguy, M., et al., River flood mapping in urban areas combining Radarsat-2 data and flood return period data. *Remote Sensing of Environment*, 2017. 198: p. 442-459.
- 3) Karamouz, M., A. Hosseinpour, and S. Nazif, Improvement of urban drainage system performance under climate change impact: Case study. *Journal of Hydrologic Engineering*, 2011. 16(5): p. 395-412.
- 4) Cherqui, F., et al., Assessing urban potential flooding risk and identifying effective risk-reduction measures. *Science of the Total Environment*, 2015. 514: p. 418-425.
- 5) Abdulaal, M., et al. Unmanned Aerial Vehicle based flash flood monitoring using Lagrangian trackers. in *International Workshop on Robotic Sensor Networks. Cyber-physical systems*. 2014.
- 6) Li, Y., S. Martinis, and M. Wieland, Urban flood mapping with an active self-learning convolutional neural network based on TerraSAR-X intensity and interferometric coherence. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019. 152: p. 178-191.



## شناسایی و قطعه‌بندی مناطق متاثر از سیلاب به کمک تصاویر ماهواره‌ای و روش‌های

### یادگیری عمیق

محدثه مسواری<sup>۱</sup>، رضا شاه‌حسینی<sup>۲\*</sup>

تاریخ ارسال: ۱۴۰۲/۰۳/۰۴

تاریخ پذیرش: ۱۴۰۲/۰۷/۱۰

مقاله پژوهشی

#### چکیده

سیل از جمله مخاطرات طبیعی است که در بسیاری از نقاط جهان به وقوع پیوسته و خسارات جبران ناپذیری را بر جای می‌گذارد. مدیریت این بحران، تاثیر به سزایی در کاهش این خسارات دارد. شناسایی دقیق مناطق تحت سیلاب از جمله نکات حائز اهمیت در روند کنترل این بحران به شمار می‌آید. همچنین پیش‌بینی مناطق سیل‌خیز می‌تواند گامی اساسی در پیش‌گیری و کاهش خسارات مالی و تلفات جانی تلقی گردد. در این مقاله به کمک تصاویر ماهواره‌ای Sentinel-1 و شبکه یادگیری عمیق کدگذار-کدگشا پدیده‌ی سیل در تصاویر، شناسایی و قطعه‌بندی شده‌است. تصاویر این ماهواره در باند C به صورت تک پلاریزه (HH و VV) و یا به صورت پلاریزاسیون (HH+HV و VV+VH) موجودند. این تصاویر متعلق به مناطق North, Nebraska, Bangladesh, Alabama و Red River North بوده و نقشه واقعیت زمینی هر تصویر که در آن کلاس هدف و غیرهدف به صورت ۰ و ۱ نشان داده شده‌اند، در سال ۲۰۲۱ توسط سازمان ناسا در اختیار شرکت‌کنندگان مسابقه ETICI قرار گرفته‌است. در این مقاله به کمک شبکه عصبی کانوولوشنی کدگذار-کدگشا و تصاویر ماهواره‌ای مذکور، فرایند شناسایی و قطعه‌بندی مناطق متاثر از سیلاب صورت گرفته‌است. نحوه عملکرد این روش توسط معیارهای ارزیابی شامل IoU, Precision, F1-Score و کاپا مورد بررسی قرار گرفته‌است. میزان IoU به دست آمده در روند ارزیابی برابر ۹۶/۰۴ درصد بوده که نسبت به سایر روش‌های مورد بررسی در سایر مطالعات موجود (که حداکثر برابر ۷۶/۸۱ درصد بوده‌است) بالاتر است. مقادیر مربوط به سایر معیارهای ارزیابی همچون Precision, F1-Score و کاپا نیز بالای ۹۵ درصد است. همچنین با توجه به آنکه تصاویر ماهواره‌ای مورد استفاده در مجموعه داده آموزشی و آزمایشی متعلق به مناطق متفاوتی بوده‌اند، در این تحقیق مدلی جامع جهت شناسایی مناطق متاثر از سیلاب در نواحی مختلف ارائه گردیده‌است.

واژه‌های کلیدی: شبکه عصبی کانوولوشنی عمیق، یادگیری عمیق، تشخیص سیلاب، قطعه‌بندی، تصاویر ماهواره‌ای Sentinel-1

<sup>۱</sup> دانشجوی دکترا، دانشکده مهندسی نقشه‌برداری، گروه فوتوگرامتری و سنجش از دور، دانشگاه تهران، تهران، ایران، [m.mesvari@ut.ac.ir](mailto:m.mesvari@ut.ac.ir)

<sup>۲</sup> استادیار، مهندسی نقشه‌برداری، گروه فوتوگرامتری و سنجش از دور، دانشگاه تهران، تهران، ایران، [rshahosseini@ut.ac.ir](mailto:rshahosseini@ut.ac.ir)



## مقدمه

سیل یکی از بلایای طبیعی خطرناک است که تمامی جهان را تحت تاثیر قرار می‌دهد و سبب میلیون‌ها تلفات جانی می‌شود (Jonkman, 2013, Islam et al, 2020). به طوری که از این نظر اولین جایگاه از میان سایر بلایای طبیعی در آمریکا و چندین نقطه دیگر در جهان را به خود اختصاص می‌دهد (Ashley et al, 2008). سیل از جمله بلایای طبیعی متناوب و گسترده بوده و همچنین خسارات مالی جبران ناپذیری را سبب می‌شود (Feng et al, 2015, Abdulaal et al, 2014). به منظور کاهش خسارات ناشی از سیل، پیش‌بینی وقوع و ارزیابی به موقع مناطق سیل زده می‌تواند گامی مهم در روند مدیریت سیلاب در مناطق آسیب‌پذیر محسوب گردد. بر اساس نتایج به دست آمده در سازمان ملل متحد، سیل در مقایسه با سایر فجایای طبیعی بزرگترین سهم را در تعداد تلفات جانی دارد (Kuenzer et al, 2016, Guha-Sapir et al, 2013). مرکز تکنولوژی و دانش بین المللی کاهش فجایای طبیعی (National Science and Technology Center for Disaster Reduction) اعلام کرد (Huffman et al, 2011) که در سال ۲۰۱۹، حدود ۴۷ درصد از ۳۶۱ فاجعه طبیعی بزرگ رخ داده، مرتبط با سیل بوده که سبب تاثیرگذاری بر حیات ۳ میلیون نفر و همچنین ۵۱۰۰ تلفات جانی شده است.

در سال‌های گذشته تغییرات اقلیمی سبب گرمایش زمین و در نتیجه افزایش احتمال سیل شده است. میانگین دمای زمین در سال ۲۰۱۹ حدود ۰/۹۵ سانتیگراد بیش از سال‌های پیشین خود بوده و با افزایش دما به تبع، اتمسفر بخار آب بیشتری در خود نگاه می‌دارد که سبب بارش‌های شدید و در نتیجه افزایش ریسک سیل می‌شود (Ahile et al, 2014). بنابر گرمایش زمین انتظار می‌رود که سیل در طول سال‌های آینده متناوب‌تر و ویرانگرتر شود (Kamilaris et al, 2018).

پدیده سیل به سه گروه اصلی تقسیم می‌گردد (Iqbal et al, 2021): ۱) سیل ناگهانی، که معمولاً به دلیل بارش سنگین کمتر از ۶ ساعت اتفاق می‌افتد، ۲) طغیان رودخانه، که به دلیل بارش طولانی در مناطق وسیع رخ می‌دهد و ۳)

سیل ساحلی، که توسط طوفان ساحلی و یا گردبادها رخ داده و سبب تقویت جزر و مد می‌شوند. در مناطق شهری به دلیل تراکم بالای جمعیت، سیل غالباً خسارات و تلفات چشمگیری را موجب می‌شود و سبب ایجاد اختلال در ارتباطات، خطوط نیرو و همچنین سیستم‌های حمل و نقلی می‌گردد (Zhao et al, 2020, Anni et al, 2020). در (Karamouz et al, 2011, Cherqui et al, 2015). این تحقیق سیل رودخانه‌ای که در اثر طغیان رودخانه به وقوع می‌پیوندد، مورد مطالعه قرار گرفته است. با توجه به توسعه و به تبع آن افزایش جمعیت شهری، انتظار می‌رود تا سال ۲۰۳۰ حدود ۶۰ درصد از جمعیت جهان در شهرها ساکن باشند. شهرهای آسیایی از جمله شهرهای با رشد سریع در جهان هستند (Water, 2020). گسترش سطوح نفوذ ناپذیر (متاثر از ساخت ساختمان‌ها و جاده‌ها) تاثیر عمده‌ای بر فرآیندهای بارندگی - رواناب دارد که باعث کاهش نفوذ و همچنین ظرفیت نگهداری آب می‌شود (Kalantari et al, 2017, Ferreira et al, 2018). در سال‌های اخیر شهری‌سازی و تغییرات اقلیمی سبب افزایش فرکانس سیل شهری شده است.

نقشه‌برداری دقیق سیل می‌تواند اطلاعات معناداری در جهت کاهش خطر سیلاب و اتخاذ تصمیمات مدیریتی ارائه نماید. اگرچه هیدرولوژی شهری در چندین دهه اخیر مورد مطالعه قرار گرفته است، اثر متقابل پیچیده بین هیدرولوژی، آب و هواشناسی و فاکتورهای سطح و همچنین نقش آن‌ها در سیل شهری مبهم باقی مانده است (Nguyen et al, 2020). به منظور مدیریت سیلاب و جلوگیری از تلفات جانی و خسارات، شناسایی مناطق مستعد سیل ضروریست (Lee et al, 2017, Wang et al, 2019). روش‌های نقشه‌برداری سیل در طی سال‌ها با توجه به پیشرفت‌های حاصل در سنجش از دور، هوش مصنوعی، ظرفیت محاسباتی و سیستم‌های اطلاعات جغرافیایی تحولات قابل توجهی داشته است (Lei et al, 2021). در سال‌های اخیر روش‌های یادگیری ماشین و همچنین الگوریتم‌های یادگیری عمیق در مطالعات مرتبط با نقشه برداری سیل مورد استفاده قرار گرفته است. این روش‌ها در زمینه شناسایی مناطق تحت سیل و همچنین پیش‌بینی روند سیلاب به کار می‌روند. پیش‌بینی سیلاب خود نیازمند

خودکار مبتنی بر حدآستانه‌گذاری و منطق فازی برای تشخیص و پایش آبی سیل با استفاده از تصاویر Sentinel-1 پرداختند. سیستم طراحی شده به دقتی بین ۹۴٪ تا ۹۶.۱٪ در محدوده یونان تا ترکیه دست‌یافت. نتایج این تحقیق نشان داد استفاده از داده با پولاریزاسیون VV به جای VH دقت بالاتری را حاصل می‌نماید. ماریون تانگار و همکاران (Tanguy et al, 2017) در سال ۲۰۱۷ با تلفیق تصاویر SAR ماهواره RADARSAT-2 با رزولوشن بالا (رزولوشن ۳ متر و در پولاریزاسیون HH) و داده‌های هیدرولیک یک دوره زمانی خاص در محدوده سیلاب، به روش طبقه‌بندی با کمک قوانین فازی اقدام به بدست آوردن نقشه سیل در مناطق شهری و روستایی با دقت ۸۷٪ نمودند. در سال ۲۰۱۹ لی و همکاران (Li et al, 2019) با استفاده از تصاویر ماهواره‌ای TerraSAR-X یک شبکه عصبی کانولوشنی خودآموز (A-SLCCNN) معرفی کرده و ضمن برطرف کردن مسئله محدودیت داده‌های آموزشی، نشان دادند که استفاده از تصاویر در بازه‌های زمانی مختلف مهم‌ترین نقش را در تشخیص سیلاب دارد. در سال ۲۰۲۱ دیوید مونز و همکاران (Muñoz et al, 2021) عملکرد شبکه عصبی کانولوشن و data fusion را برای تهیه نقشه سیل با استفاده از تصاویر چند طیفی لندست با رزولوشن مکانی ۳۰ متر را مورد بررسی قرار داده و به دقت ۹۷٪ رسیدند. در همین سال لی و همکاران (Lei et al, 2021) ۱۰ پارامتر اثرگذار بر پدیده سیل به عنوان متغیرهای پیش‌بینی کننده را در نظر گرفته و با استفاده از شبکه عصبی کانولوشنی و شبکه عصبی بازگشتی اقدام به نقشه‌برداری سیلاب نمودند. در نهایت مدل شبکه عصبی کانولوشنی با ۸۴٪ دقت عملکرد مناسب‌تری از شبکه دیگر از خود بر جای گذاشت. از جمله نکات مورد توجه در این مطالعات آن است که این تحقیقات عمدتاً بر روی نواحی خاصی صورت گرفته‌اند و در نتیجه به طور قطع نمی‌توان میزان کارایی روش مورد استفاده در هر تحقیق را برای نواحی دیگر به دست آورد. همچنین در برخی از این تحقیقات تصاویر ماهواره‌ای کافی جهت آموزش شبکه‌های عصبی به کار رفته، موجود نیست. همچنین میزان دقت در برخی از این مطالعات پایین بوده‌است. این در حالیست که به دلیل اهمیت شناسایی دقیق پدیده سیلاب و قطع‌بندی مناطق

شناسایی مناطق متاثر از سیلاب در بازه‌های زمانی متفاوت است.

امروزه بهبود رزولوشن‌های مکانی و طیفی تصاویر ماهواره‌ای و پیشرفت روش‌ها و الگوریتم‌های یادگیری عمیق پتانسیل بالایی را در توسعه روش‌های سنجش از دوری ایجاد نموده است. توسعه این روش‌های دورسنجی می‌تواند کمک شایانی در جهت صرفه جویی در وقت و هزینه در نقشه برداری سیل نماید. از طرفی پیش‌بینی مناطق متاثر از سیل به کمک شناسایی سیلاب در بازه‌های زمانی مختلف صورت می‌پذیرد. بنابراین شناسایی سیلاب گامی مهم در راستای پیش‌بینی مناطق آسیب‌پذیر بوده و می‌تواند معیاری جهت مکان‌یابی نواحی مناسب جهت به-کارگیری مخازن سیل تلقی گردد؛ این امر بدین صورت انجام می‌گیرد که احتمال وقوع سیل برای تمامی محدوده مورد نظر محاسبه می‌گردد (یوسفی et al, 2022, مرادیانی et al, 2020, معنوی et al, 2022).

استفاده از تصاویر ماهواره‌ای به صورت گسترده به عنوان یک منبع مناسب جهت کاهش هزینه و زمان و بهبود روند مدیریتی در مناطق بزرگ در حوزه بلایای طبیعی هستند. تصویربرداری رادار روزنه مصنوعی (SAR) با توجه به قابلیت تصویربرداری در روز و شب تحت تمامی شرایط آب و هوایی بسیار مرسوم است. تصاویر اپتیک مشخصات شیمیایی سطح زمین و داده SAR (-Synthetic aperture radar) ویژگی‌های فیزیکی همچون زبری و نفوذ سطح را مشخص می‌کنند. در دو دهه اخیر با افزایش تعداد ماهواره‌های SAR در مدار مربوطه می‌توان تصاویری با رزولوشن مکانی و زمانی مناسب اخذ نمود (Arabameri et al, 2019). مطالعاتی در زمینه طبقه‌بندی کاربری اراضی جهت به دست آوردن ریسک سیل (Castelluccio et al, 2015, Helber et al, 2019) صورت گرفته که شامل مانیتورینگ سیل به صورت آبی (Udomsiri et al, 2008)، اندازه‌گیری حجم سیلاب (Perks et al, 2020)، مدل کردن سیل (Langhammer et al, 2018)، تشخیص سیل (Ip et al, 2006) و همچنین ارزیابی خسارات پس از سیل (Balkaya et al, 2015) می‌شود.

در این راستا آندره توئل و همکاران در سال ۲۰۱۶ (Twele et al, 2016) به طراحی رشته‌ای از پردازش‌های



شکل (۱): منطقه مربوط به ایالت نبراسکا

قسمت شمالی ایالت آلاباما آمریکا، به دلیل آب و هوای مرطوب و وجود رودخانه‌های بزرگ تنسی، کوسا و فینت، سیلاب‌های فراوانی را به خود دیده است. از جمله سیلاب‌های مطرح این ناحیه، می‌توان به سیلاب سال ۱۹۲۹ رودخانه تنسی، سیلاب بزرگ ۱۹۷۴ و سیلاب‌های سال ۲۰۱۹ اشاره نمود که آسیب‌های فراوانی به زیرساخت‌ها، املاک و زمین‌های زراعی این ایالت وارد نمودند.



شکل (۲): منطقه مربوط به ایالت آلاباما

منطقه Red river north، در کشورهای آمریکا و کانادا واقع شده است. این ناحیه به سبب زمین مسطح و نزدیکی به رودخانه Red river، در طول سال‌ها سیلاب‌های بسیاری را به خود دیده است. شهرهای فارگو در داکوتای شمالی و مورهد در مینسوتا که در ساحل این رودخانه بنا شده‌اند، هر ساله با سیلاب‌های بزرگی رو به رو می‌شوند. از جمله این سیلاب‌ها می‌توان به سیلاب‌های سال ۱۹۹۷، ۲۰۰۹ و ۲۰۱۱ اشاره نمود.

متاثر از آن، دقت روش به کار رفته بایستی تا حد ممکن بالا باشد.

این تحقیق به بررسی و تشخیص سیلاب با استفاده از تصاویر ماهواره‌ای و همچنین روش‌ها و الگوریتم‌های یادگیری عمیق جهت شناسایی هر چه سریع‌تر مناطق تحت سیلاب به منظور مدیریت این بحران طبیعی در مناطق آسیب‌پذیر می‌پردازد. آنچه در این تحقیق مد نظر قرار گرفته است، ارائه یک روش نوین با دقتی بالا در تشخیص مناطق تحت سیلاب است. در این تحقیق به کمک تلفیقی از مدل‌های یادگیری عمیق که عملکرد مناسبی در شناسایی و طبقه‌بندی دارا هستند و همچنین با توجه به ماهیت تصاویر ماهواره‌ای ورودی، روند آموزش مدل صورت گرفته و نهایتاً به کمک مجموعه داده تصاویر در دسترس، مدل نهایی ایجاد شده است.


## مواد و روش‌ها

### معرفی مناطق مورد مطالعه

نبراسکا ایالتی کوچک در غرب ایالات متحده آمریکا است. این ایالت به سبب واقع شدن در دشتهای بزرگ در معرض سیلاب قرار داشته و به خصوص سیلاب‌های ناگهانی آن را تهدید می‌کنند. در سال‌های اخیر به علت گرمایش زمین و تغییر الگوهای شهرنشینی تعداد سیلاب‌ها در نبراسکا افزایش یافته به طوری که در سیلاب سال ۲۰۱۱ رودخانه میسوری و سیلاب سال ۲۰۱۹، بخش‌های بزرگی از این ایالت را تحت تاثیر قرار داده و میلیاردها دلار خسارات بر جای گذاشت.

جدول (۱): مناطق مورد مطالعه و مساحت هر یک

منطقه	مساحت (کیلومتر مربع)
Nebraska	۱۷۴۱
North Alabama	۱۳۷۸۹
Bangladesh	۷۱۵۰
Red River North	۶۷۴۶
Florence	۷۱۹۷



شکل (۵): منطقه مربوط به شهر فلورانس

در شکل موقعیت هریک از این مناطق نشان داده شده است.



شکل (۶): موقعیت مناطق مربوط به اخذ تصاویر ماهواره‌ای

در جدول مشخصات ماهواره Sentinel-1، به صورت خلاصه قابل ملاحظه است.

جدول (۲): مشخصات ماهواره Sentinel-1

Sentinel-1A: ۳ آوریل ۲۰۱۴	تاریخ پرتاب
Sentinel-1B: ۲۵ آوریل ۲۰۱۶	
مدار قطبی خورشید آهنگ	مدار
۶۹۳ کیلومتر	ارتفاع
۹۸.۱۸ درجه	زاویه
۱۲ روز	دوره تکرار
تداخل: ۲۵۰ کیلومتر	
	پهنای باند
نواری: ۸۰ کیلومتر	
باند C (۵.۴۰۵ گیگاهرتز)	فرکانس
پولاریزاسیون دوگانه (HH/HV) یا (VV/VH)	پولاریزاسیون
تداخلی: ۲۰×۵ متر	
	رزولوشن
نواری: ۵×۵ متر	
پایش اقیانوس‌ها و سرزمین‌ها، نقشه-برداری بلایا، مطالعات اقلیمی، نظارت دریایی و ...	کاربردها



شکل (۳): منطقه مربوط به Red River

بنگلادش کشوری با ارتفاع کم در جنوب آسیا است که در دلتای سه رودخانه Ganges، Brahmaputra و Meghna واقع شده است. به این سبب همواره در معرض سیل بوده و حدود یک سوم مساحت این کشور در فصل باران‌های موسمی تحت تاثیر سیلاب قرار می‌گیرد. طوفان‌های استوایی و دریایی از جمله دیگر عوامل وقوع سیل در این کشور است. گرمایش زمین و عوامل انسانی از جمله جنگل-زدایی و شهری‌سازی بی‌برنامه، در سال‌های اخیر بر شدت سیلاب‌ها افزوده است.



شکل (۴): منطقه مربوط به کشور بنگلادش


فلورانس در مرکز کشور ایتالیا و در ساحل رودخانه آرنو بنا شده و به این سبب در فصول بارندگی شاهد سیل‌های مختلفی است. بزرگ‌ترین سیل این ناحیه مربوط به سال ۱۹۶۶ است که در پی بارندگی شدید و طغیان رودخانه، ارتفاع سیلاب در برخی از نقاط شهر به ۶ متر نیز رسید و آسیب‌های فراوانی را به زیرساخت‌ها وارد نمود.





کانولووشنی اندازه فیلتر، به صورت  $3 \times 3$  در نظر گرفته شده- است. علاوه بر این، نرمال سازی دسته‌ای به منظور پیش-گیری از فرایند بیش‌برازش، در این شبکه عصبی کانولووشنی به کار رفته‌است. همچنین ابعاد تصاویر ورودی و خروجی در این شبکه با یکدیگر مشابه است. در هر بلوک، یک تابع فعال سازی برای هر نورون کانولووشنی در نظر گرفته شده‌است. با توجه به ویژگی‌های کاربردی تابع فعال-سازی Relu که در مقالات متعددی مورد توجه قرار گرفته- است، در این تحقیق نیز از این تابع فعال سازی استفاده شده‌است. دو ویژگی شاخص این تابع فعال سازی عبارت است از:


۱. این تابع مقادیر منفی ورودی را صفر در نظر می-گیرد.
  ۲. مشتق این تابع فعال سازی برای مقادیر مثبت برابر یک است.
- بدین جهت که اگر مشتق تابع برای مقادیر مثبت مخالف یک باشد، مقادیر خروجی ممکن است خارج از محدوده مورد نظر قرار گیرند و سبب ایجاد خطا در شبکه کانولووشنی گردند. رفتار این تابع در شکل نشان داده شده‌است.



شکل (۸): رفتار تابع Relu

در این شبکه، مسیر کدگذار اطلاعات موجود در تصاویر را استخراج می‌نماید. در مسیر کدگشا نیز ویژگی‌های بدست آمده بازبایی می‌گردند. در نهایت این ویژگی‌ها

در شکل نمونه‌ای از داده‌های برچسب گذاری شده قابل مشاهده است.



شکل (۷): (الف) تصویر پلاریزاسیون  $VV$  sentinel-1، (ب) تصویر پلاریزاسیون  $VH$  sentinel-1، (ج) کلاس سیل و (د) کلاس پهنه آبی

این مجموعه داده مربوط به مسابقات ETCI ناسا بوده و از طریق وبگاه این مسابقات اخذ گردیده است. در این تحقیق به کمک  $66810$  تصویر ماهواره‌ای sentinel-1 دو پلاریزاسیون  $VH$  و  $VV$  و در ابعاد  $256 \times 256$  پیکسل فرایند آموزش شبکه صورت پذیرفته است. فرایند برچسب-گذاری برای تمامی این تصاویر انجام شده و دو عارضه پهنه آبی و مناطق تحت سیل به تفکیک برای تصاویر متعلق به هر منطقه در زمان‌های متفاوت مشخص گردیده است. در این فرایند پهنه آبی و منطقه تحت سیل با عدد ۱ و سایر نواحی با عدد ۰ مقداردهی شده‌اند. این تصاویر متعلق به ۵ منطقه در نقاط مختلف جهان با مساحت‌های مختلف است. جدول نام و مساحت هر یک از این مناطق را ارائه می‌نماید.

### روش پیشنهادی


در این مقاله، شبکه عصبی رمزگذار-رمزگشا در این روش پیشنهادی با SegUnet [encoder-decoder] با توجه به کاربردهای اساسی که در پردازش تصاویر داراست، مورد استفاده قرار گرفته‌است. این شبکه‌ها کاربردهای بسیاری در فتوگرامتری و سنجش از دور در روند استخراج اطلاعات از تصاویر دارا هستند. ساختار این شبکه یادگیری عمیق از دو بلوک کانولووشنی دو بعدی تشکیل شده‌است. طراحی کلی این شبکه برگرفته از ایده شبکه‌های U-Net و SegNet (Badrinarayanan et al, 2017, Mesvari et al, 2023). در معماری این شبکه، هر بلوک کانولووشنی دو بعدی متشکل از دو لایه کانولووشنی است، که هر لایه به کمک یک نورون کانولووشنی سبب استخراج ویژگی‌های بیشتر در هر بلوک می‌گردد. در هر یک از این بلوک‌های

در این رابطه  $Z_i$  بردار ورودی تابع شامل بازه  $(Z_0 \dots Z_k)$ ،  $Z_i$  مقادیر ورودی تابع هستند که می‌توانند هر مقدار مثبت، منفی و یا صفر را شامل شوند.  $K$  نیز تعداد کلاس‌ها را نشان می‌دهد.

در مسیر کدگشا، بازسازی ویژگی‌های استخراج شده در ۴ لایه کلی صورت می‌پذیرد و نهایتاً آخرین تابعی که خروجی‌های شبکه را از خود عبور داده و ویژگی‌های استخراج شده را در دو کلاس کلی قرار می‌دهد، تابع Sigmoid است. معادله ۲ رابطه مربوط به این تابع را ارائه می‌دهد. در این رابطه نیز  $x$  مقدار ورودی تابع است.

$$\text{Sigmoid } S(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

تابع Sigmoid و Soft-max مشابه یکدیگرند. تابع Sigmoid یک مورد خاص از تابع Soft-max برای یک طبقه‌بندی کننده با دو کلاس ورودی است. شکل رفتار این تابع را نشان می‌دهد.



شکل (۹): رفتار تابع Sigmoid

در این شبکه از بهینه‌ساز Adam و نرخ یادگیری ۰.۰۱ در فرایند آموزش مدل استفاده شده است. معماری این شبکه در شکل زیر قابل مشاهده است. لایه‌های مختلف این شبکه نیز در شکل نشان داده است.

بازسازی شده و به کمک تابع اتلاف [Loss Function] خروجی نهایی شامل کلاس‌های هدف و غیر هدف تولید می‌گردد. در مسیر کدگذار ۵ لایه کانولووشنی متشکل از بلوک‌های کانولووشنی در نظر گرفته شده است.

با توجه به ماهیت تصاویر موجود و کلاس هدف تعداد پیکسل‌های هدف نسبت به پیکسل‌های غیر هدف متغیر است. بدین جهت، این مسئله به کمک یک تابع اتلاف وزن-دار، رفع شده است. ایجاد یک تابع فعال‌سازی که عمل فعال و غیر فعال نمودن نورون را بر عهده دارد و در روند به روزرسانی وزن‌ها و فرایند مشتق‌گیری و گرادیان‌گیری نیز نقش مهمی را بر عهده دارد، از اهمیت بالایی برخوردار است. بنابراین، انتخاب یک تابع فعال‌سازی مناسب می‌تواند از بیش‌برازش شبکه جلوگیری نموده و در حل مسائل غیر خطی و الگوهای پیکسل‌مبنا راهگشا باشد. تابع اتلاف مورد استفاده در این شبکه، Binary-cross entropy است که این تابع در مدل یک وزن متناسب با پیکسل‌های هدف و غیر هدف در نظر می‌گیرد. تابع فعال‌سازی مورد استفاده در این لایه نیز، Soft-max است که غالباً عملکرد مناسبی در قطعه‌بندی تصاویر دارد. تابع Soft-max تابعی است که مقادیر حقیقی یک بردار را به صورتی تغییر می‌دهد که جمع مقادیر آن بردار برابر ۱ شود. مقادیر ورودی می‌توانند مثبت، منفی، صفر و یا بزرگ‌تر از ۱ باشند. تابع Soft-max این مقادیر را به بازه ۰ تا ۱ تبدیل می‌نماید. بنابراین می‌توان این مقادیر را همچون مقادیر احتمال در نظر گرفت. چنانچه ورودی این تابع کوچک و یا منفی باشد، تابع مقادیر احتمالاتی کوچکی را به آن‌ها اختصاص می‌دهد و برعکس. بسیاری از شبکه‌های عصبی چند لایه، در لایه ماقبل آخر که مقادیر با ارزشی را خروجی می‌دهند، ممکن است به دلیل عدم مقیاس‌بندی این مقادیر، با مشکل مواجه شوند. در این صورت، استفاده از تابع Soft-max بسیار مفید خواهد بود (Qi et al, 2017)؛ چرا که به نوعی این مقادیر را به یک توزیع احتمالاتی نرمال تبدیل می‌نماید. به همین دلیل اضافه نمودن تابع Soft-max به عنوان لایه آخر شبکه عصبی امری رایج است. معادله ۱ رابطه تابع Soft-max را نشان می‌دهد.

$$\text{Softmax } \sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (1)$$



می‌گیرد. در نهایت، بهترین پارامترهای مدل برآورد شده و فرایند ارزیابی به کمک مجموعه داده آزمایشی صورت می‌پذیرد.

### معیارهای ارزیابی و دقت

براساس نتایج به دست آمده از روش به کار رفته در این مطالعه، معیارهای مدنظر جهت ارزیابی عملکرد مدل عبارتند از: Precision، (Intersection – Over - Union)

و کاپا [Kappa] و F1-Score، IoU (Union Precision) به نسبت پیکسل‌های متعلق به یک کلاس که توسط مدل به درستی شناسایی شده‌اند به کل تعداد پیکسل‌هایی که مدل چه به صورت درست و چه به صورت اشتباه در آن کلاس شناسایی نموده‌است. معیار یادآوری [Recall] نیز نسبت پیکسل‌های متعلق به یک کلاس که به درستی تشخیص داده شده‌اند به کل پیکسل‌هاییست که توسط مدل شناسایی شده‌اند. حداقل مقدار این معیارها برابر صفر و حداکثر مقدار آنها برابر ۱ است. این دو معیار به صورت زیر محاسبه می‌گردند:

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$


در این روابط TP و TN به ترتیب پیکسل‌هایی هستند که به درستی توسط مدل شناسایی و رد شده‌اند. همچنین FP و FN نیز به ترتیب پیکسل‌هایی هستند که مدل به اشتباه شناسایی و رد نموده‌است.

معیار F1-Score نیز به صورت میانگین هارمونیک دو معیار پیشین در نظر گرفته می‌شود. معادله ۵ نحوه محاسبه این معیار را نشان می‌دهد.

$$F1 \text{ score} = \frac{2 \times (Precision \times Recall)}{(Precision + Recall)} \quad (5)$$

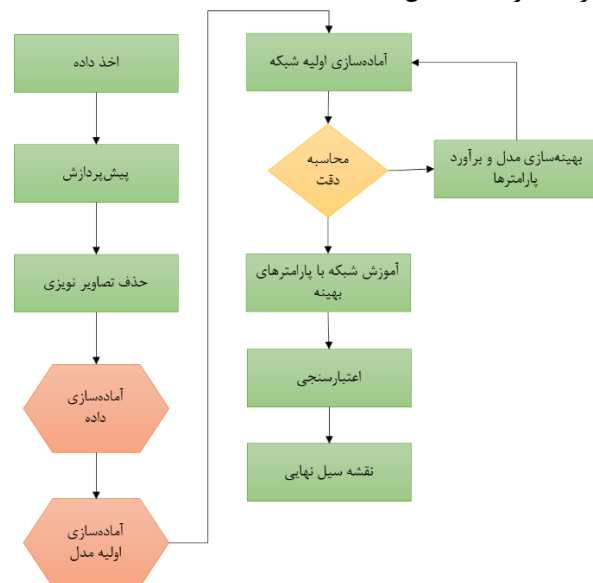
معیار IoU نیز نسبت اشتراک به اجتماع دو مجموعه پیشبینی شبکه و واقعیت است که پارامتری آماری برای درک بهتر شباهت این دو مجموعه است. این معیار نیز به صورت معادله ۶ ذیل محاسبه می‌گردد.

در این رابطه نیز مجموعه A پیشبینی شبکه و مجموعه B نقشه واقعیت است. این معیار از جمله مهم‌ترین معیارها در



شکل (۱۰): معماری کلی شبکه

به منظور پیاده‌سازی این مدل، ابتدا مجموعه تصاویر sentinel-1 از درگاه مسابقات ETCI دریافت، و سپس فرایند یادگیری شبکه برای این تصاویر با اندازه ۲۵۶×۲۵۶ و با دسته‌بندی‌های ۱۵ تایی، صورت گرفت. پس از آموزش شبکه و با به دست آوردن مدل نهایی، این مدل به منظور شناسایی مناطق تحت سیلاب در مجموعه داده آزمایشی مورد استفاده قرار گرفت و در نتیجه این امر نقشه پیش‌بینی شبکه برای هر تصویر ایجاد گردید. روند کلی انجام این فرایند در شکل قابل ملاحظه است.



شکل (۱۱): روند کلی انجام تحقیق

همانطور که در این شکل ملاحظه می‌گردد، پس از اخذ داده و انجام پیش‌پردازش، که این روند توسط سازمان ناسا انجام یافته‌است، و همچنین حذف تصاویر نویزی، آماده‌سازی اولیه شبکه صورت می‌گیرد. سپس بهینه‌سازی

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (6)$$

پارامترهای مدل در طول فرایند آموزش شبکه انجام

که تا به حال در زمینه پهنه‌بندی مناطق متاثر از سیل به انجام رسیده‌اند، این روش با توجه به معماری به کار رفته، نتایج بهتری حاصل نموده‌است.

پس از پایان فرایند آموزش، با اعمال مدل ایجاد شده بر روی مجموعه داده آزمایشی، عملکرد مدل به کمک معیارهای ارزیابی کلی شامل IoU, Precision, F1-Score و کاپا مورد بررسی قرار می‌گیرد. در این تحقیق با توجه به توزیع غیر یکنواخت پیکسل‌های هدف و غیرهدف، معیار IoU مناسب‌ترین معیار جهت ارزیابی عملکرد مدل است؛ در روند مسابقه برگزار شده توسط ناسا نیز این معیار مدنظر قرار گرفته‌است. این نتایج حاکی از آن است که مدل ایجاد شده در شناسایی مناطق تحت سیلاب عملکرد قابل توجهی داشته و این روش جهت شناسایی و قطعه‌بندی این نواحی از قابلیت بالایی برخوردار است. این نتایج در جدول نشان داده شده است.

جدول (۳): معیارهای ارزیابی عملکرد شبکه

مقادیر	معیارها
۹۷/۹	Precision
۹۶/۰۴	IoU
۹۷/۹۸	F1-Score
۹۵/۹۶	کاپا

بر اساس جدول فوق، مقادیر مرتبط با معیارهای ارزیابی این مدل به صورت کلی بالای ۹۵ درصد بوده و این خود نشان از آن دارد که پیکسل‌های کلاس سیل به خوبی به کمک این روش تشخیص داده شده‌اند.

در این تحقیق فرایند آموزش و اعتبارسنجی شبکه به کمک تصاویر ماهواره‌ای متعلق به کشور بنگلادش، ایالت نبراسکا و شهر فلورنس صورت پذیرفته‌است. سپس عملکرد مدل به کمک مجموعه داده آزمایشی متشکل از تصاویر ماهواره‌ای اخذ شده از ایالت آلاباما مورد ارزیابی قرار گرفته‌است. چراکه نقشه واقعیت متعلق به تصاویر منطقه Red River North در مجموعه داده مذکور در دسترس عموم قرار نگرفته‌است؛ بنابراین، روند آزمایش به کمک تصاویر متعلق به منطقه‌ی آلاباما که در روند آموزش شبکه مورد استفاده قرار نگرفته‌است، انجام شده و نتایج حاصل نشان دهنده آن است که مدل ارائه شده برای سایر مناطقی که در روند آموزش با

روند قطعه‌بندی تصاویر محسوب می‌شود و در اکثر مطالعات موجود در این حیطه از این معیار جهت ارزیابی روش استفاده می‌نمایند. حداقل و حداکثر مقدار این معیار به ترتیب برابر صفر و یک است.

معیار کاپا یک معیار آماریست که اغلب در روش‌های یادگیری ماشین که بر روی مجموعه داده‌های نامتعادل و چند کلاسه اعمال می‌گردند، محاسبه می‌شود (De Raadt et al, 2019). حداقل مقدار این پارامتر برابر ۱- و حداکثر مقدار آن برابر ۱ است. بدیهیست که هرچه این معیار بیشتر نزدیک به یک باشد، روش به کار رفته عملکرد بهتری داشته‌است. به صورت کلی مقادیر بالای ۰/۷۵ این معیار بیانگر عملکرد مناسب روش و مقادیر کمتر از ۰/۴ نمایانگر عملکرد ضعیف آن است. نحوه محاسبه این پارامتر در معادله زیر قابل ملاحظه است. در این معادله  $P_e$  درصد توافق مورد انتظار و  $P_0$  میزان توافق بین دو کدگذار است. چنانچه این معیار برابر ۱ باشد، نشان از توافق کامل میان ارزیاب‌هاست و چنانچه این معیار برابر صفر باشد، نمایانگر عدم توافق کامل است. معادله ۷ نحوه محاسبه این معیار را نشان می‌دهد.


$$K = \frac{P_0 - P_e}{1 - P_e} \quad (7)$$

## بحث و نتایج

هدف کلی از انجام این تحقیق، شناسایی مناطق متاثر از سیل و تعیین گستره دقیق این نواحی است. در این راستا این مقاله قصد دارد با ارائه مدلی جامع و به کمک قابلیت‌های موجود در تصاویر ماهواره‌ای، فرایند پهنه‌بندی سیلاب را به صورت خودکار و بدون دخالت کاربر و با صرف حداقل هزینه و زمان، به انجام رساند. همانطور که پیش‌تر نیز گفته شد، مطالعات فراوانی در این حوزه صورت پذیرفته‌است. برخی از این مطالعات مبتنی بر داده‌های متنوعی همچون داده‌های هیدرولیکی و هیدرولوژیکی بوده که غالباً تهیه این داده‌ها نیازمند صرف هزینه و زمان بالاییست؛ این در حالیست که در این تحقیق، روند نقشه‌برداری سیلاب تنها با اتکا به تصاویر ماهواره‌ای راداری و روش‌های یادگیری عمیق صورت می‌پذیرد. هم‌چنین در مقایسه با سایر روش‌های یادگیری ماشین و یادگیری عمیق



شده است. به کارگیری توابع اتلاف و فعال سازی و هم چنین تنظیم پارامترها متناسب با داده سبب ایجاد یک مدل کارآمد در امر شناسایی و قطعه بندی شده است. بنابراین می توان به کمک تصاویر Sentinel-1 و روش مذکور این نواحی را برای هر بازه زمانی شناسایی و قطعه بندی نموده و همچنین به کمک سری زمانی حاصل از شناسایی سیل در تصاویر ماهواره ای در بازه های زمانی مختلف میزان سیل خیزی هر منطقه را به دست آورده و برای بازه های زمانی آتی این پارامتر را پیش بینی نمود.



شکل (۱۲): الف) تصویر در پلاریزاسیون VV، ب) پیش بینی روش مورد مطالعه، ج) نقشه واقعیت زمینی

### نتیجه گیری

در این مطالعه روند شناسایی سیلاب به کمک تصاویر ماهواره ای Sentinel-1 و همچنین شبکه عصبی کانولوشنی کدگذار-کدگشا برای نواحی مختلف صورت پذیرفته است. این روش با الهام از ایده کلی مدل های یادگیری عمیق که عملکرد مناسبی در قطعه بندی عوارض مختلف دارا هستند و همچنین با توجه به ماهیت تصاویر موجود در نظر گرفته شده است. همچنین در این شبکه

تصاویر ماهواره ای آن ها مواجه نشده است نیز عملکرد مناسبی را از خود نشان می دهد.

همچنین همانطور که پیش از این نیز ذکر شد، مجموعه داده مورد استفاده در این تحقیق مربوط به مسابقات ETCI ۲۰۲۱ ناسا بوده و بنابراین روش های متنوعی بر روی این مجموعه داده به منظور شناسایی سیلاب اعمال شده اند. مقادیر IoU به دست آمده در این روش ها حداکثر برابر ۷۶/۸۱ درصد بوده اند (Paul et al, 2021, GHOSH et al, 2022). این در حالیست که روش به کار رفته در این مقاله به IoU ۹۶/۰۴ درصد دست یافته است. تمامی نتایج به دست آمده در این مطالعات برای منطقه Red river north به دست آمده اند. تصاویر مربوط به این منطقه به عنوان داده آزمایشی در این مجموعه داده قرار گرفته و عملکرد تمامی روش ها با توجه به این مجموعه داده آزمایشی ارزیابی شده است. جدول مقایسه ای میان مقادیر IoU به دست آمده در این تحقیق و روش های برگزیده در این مسابقه ارائه می نماید. همانطور که در این جدول ملاحظه می گردد، این روش در مقایسه با سایر روش های مورد استفاده توسط تیم های برگزیده مسابقه ناسا، عملکرد مناسب تری داشته و مقادیر IoU بالاتری را حاصل نموده است.

جدول (۴): مقایسه روش به کار رفته با روش های برگزیده سایر

#### شرکت کنندگان

مقادیر IoU	روش مورد استفاده	گروه های شرکت کننده
۷۶/۸۱	ذکر نشده	Team Arren (Xidian University)
۷۶/۵۴	Pseudo labeling + Ensembles with CRF post processing	Siddha Ganju (NVIDIA) & Sayak Paul (Carted)
۷۵/۰۶	FPN + UNet	Shagun Garg (GFZ Postdam)
۹۶/۰۴	SegUnet	مدل ارائه شده در این مقاله

**شکل** نواحی شناسایی شده توسط مدل را در مقایسه با نقشه واقعیت زمینی نشان می دهد. همانطور که در شکل زیر قابل ملاحظه است، نواحی تحت سیلاب به خوبی در تصاویر ماهواره ای که به صورت تصادفی انتخاب شده اند، توسط مدل شناسایی شده اند. این روش که تلفیقی از مدل های یادگیری عمیق است، با توجه به ماهیت تصاویر موجود در نظر گرفته

این مدل می‌توان فرایند شناسایی و قطعه‌بندی مناطق متأثر از سیل را در تصاویر ماهواره‌ای در بازه‌های زمانی مختلف و سال‌های آتی نیز به انجام رساند. استفاده از یک مجموعه داده دقیق‌تر و با کلاس‌های بیشتر می‌تواند سبب بهبود مدل‌های ایجاد شده گردد. به عنوان مثال به جای آن که نقشه واقعیت در دو کلاس سیل و غیرسیل طبقه‌بندی گردد، پدیده سیل را در کلاس‌های مختلف شامل سیلاب دشتی، پهنه پوشش گیاهی و سیلاب شهری طبقه‌بندی نماید. همچنین توسعه شبکه‌های عصبی می‌تواند همچون گذشته به صورت مستقیم در بهبود نتایج حاصل اثر گذار باشد. از آن جا که شناسایی تصاویر در روند پیش‌بینی مناطق سیل خیز از اهمیت بالایی برخوردار است و می‌تواند سبب پیش‌گیری و کاهش خسارات جانی و مالی گردد، از جمله اقدامات آتی این مطالعه بررسی این نواحی با اتکا به توانایی روش به کار رفته در این پژوهش است.

به‌کارگیری توابع اتلاف و فعال‌سازی و هم‌چنین تنظیم پارامترها متناسب با مجموعه داده مدنظر سبب ایجاد یک مدل کارآمد در امر شناسایی و قطعه‌بندی تصاویر ماهواره‌ای شده‌است. نتایج به دست آمده از معیارهای ارزیابی گواه آن است که فرایند آموزش مدل به خوبی صورت گرفته و این مدل عملکرد مناسبی در راستای تشخیص و قطعه‌بندی مناطق تحت سیلاب داراست. هم‌چنین این مدل به نسبت سایر تحقیقات موجود در این حوزه دقت بالاتری داشته و در راستای شناسایی مناطق متأثر از سیلاب در تصاویر اخذ شده از مناطقی که در روند آموزش حضور نداشته‌اند، عملکرد مناسبی را از خود نشان می‌دهد. بنابراین، این مدل قابلیت شناسایی و پهنه‌بندی سیلاب در سایر مناطق را نیز داراست؛ به عبارت دیگر در این مقاله مدلی جامع جهت شناسایی و پهنه‌بندی سیلاب ارائه گردیده‌است که برای سایر نقاط جهان نیز تعمیم‌پذیر است. هم‌چنین به کمک

## منابع

- یوسفی، et al., 2022, تعیین پتانسیل سیل با استفاده از مدل‌های یادگیری ماشین *CART*، *GLM* و *GAM* (مطالعه موردی: حوضه کشکان). نشریه علمی پژوهشی مهندسی آبیاری و آب ایران. ۱۱۲(۴): 84-105.
- مرادیانی، اختری، and آذری. ۲۰۲۰. پیش‌بینی سیل با استفاده از تلفیق تصاویر ماهواره‌ای و مدل بارش-رواناب در مناطق فاقد آمار. نشریه علمی پژوهشی مهندسی آبیاری و آب ایران. ۱۱۱(۱): 211-226.
- معنوی، et al., 2022, پتانسیل تولید سیلاب و تعیین مناطق مولد سیل با استفاده از نرم افزار *ArcGIS* و مدل *ModClark* در حوضه تالار. نشریه علمی پژوهشی مهندسی آبیاری و آب ایران. ۱۱۲(۴): 470-486.
- (، اف.و.ه.، ارزیابی خسارات سیل شهر تبریز و راهکارهای مدیریت آن. اولین کنفرانس ملی مدیریت سیلابهای شهری. Water, U., 2020, *Water and climate change*. The United Nations World Water Development Report; UNESCO: Paris, France.
- Kalantari, Z., et al., 2017, *Urbanization development under climate change: Hydrological responses in a peri-urban Mediterranean catchment*. Land degradation & development. **28**(7): p. 2207-2221.
- Zhao, G ,et al., 2020, *Urban flood susceptibility assessment based on convolutional neural networks*. Journal of Hydrology. **590**: p. 125235.
- Lei, X., et al., 2021, *Urban flood modeling using deep-learning approaches in Seoul, South Korea*. Journal of Hydrology :۶۰۱ .p. 126684.
- Li, Y., S. Martinis, and M. Wieland, 2019, *Urban flood mapping with an active self-learning convolutional neural network based on TerraSAR-X intensity and interferometric coherence*. ISPRS Journal of Photogrammetry and Remote Sensing. **152**: p. 178-191.
- Feng, Q., J. Liu, and J. Gong, 2015, *Urban flood mapping based on unmanned aerial vehicle remote sensing and random forest classifier—A case of Yuyao, China*. Water. **7**(4): p. 1437-1455.
- Abdulaal, M., et al. *Unmanned Aerial Vehicle based flash flood monitoring using Lagrangian trackers*. in *International Workshop on Robotic Sensor Networks. Cyber-physical systems*. 2014.
- Perks, M.T., et al., 2020, *Towards harmonisation of image velocimetry techniques for river surface velocity observations*. Earth System Science Data. **12**(3): p. 1545-1559.
- Lee, S., et al., 2017, *Spatial prediction of flood susceptibility using random-forest and boosted-tree models in Seoul metropolitan city, Korea*. Geomatics, Natural Hazards and Risk :<sup>(۲)</sup>.p. 1185-1203.



- Twele, A., et al., 2016, *Sentinel-1-based flood mapping: a fully automated processing chain*. International Journal of Remote Sensing. **37**(13): p. 2990-3004.
- Anni, A.H., S. Cohen, and S. Praskievicz, 2020, *Sensitivity of urban flood simulations to stormwater infrastructure and soil infiltration*. Journal of Hydrology. **588**: p. 125028.
- Badrinarayanan, V., A. Kendall, and R. Cipolla, 2017, *Segnet: A deep convolutional encoder-decoder architecture for image segmentation*. IEEE transactions on pattern analysis and machine intelligence. **39**(12): p. 2481-2495.
- Mesvari, M. and R. Shah-Hosseini, 2023, *SEGMENTATION OF ELECTRICAL SUBSTATIONS USING DEEP CONVOLUTIONAL NEURAL NETWORK*. ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci. **X-4/W1-2022**: p. 495-500.
- Tanguy, M., et al., 2017, *River flood mapping in urban areas combining Radarsat-2 data and flood return period data*. Remote Sensing of Environment. **198**: p. 442-459.
- Balkaya, C., et al., 2015, *Real-time identification of disaster areas by an open-access vision-based tool*. Advances in Engineering Software. **88**: p. 83-90.
- Jonkman, S., 2013, *Loss of life due to floods: General overview*. Drowning: Prevention, Rescue, Treatment: p. 957-965.
- Castelluccio ,M., et al., 2015, *Land use classification in remote sensing images by convolutional neural networks*. arXiv preprint arXiv:1508.00092.
- De Raadt, A., et al., 2019, *Kappa coefficients for missing data*. Educational and Psychological Measurement. **79** :(\*)p. 558-576.
- Huffman, M.D., et al. 2011, *Incidence of cardiovascular risk factors in an Indian urban cohort: results from the New Delhi Birth Cohort*, American College of Cardiology Foundation Washington, DC. p. 1765-1774.
- Karamouz, M., A. Hosseinpour, and S. Nazif, 2011, *Improvement of urban drainage system performance under climate change impact: Case study*. Journal of Hydrologic Engineering. **16**(5): p. 395-412.
- Iqbal, U., et al., 2021, *How computer vision can facilitate flood management :A systematic review*. International Journal of Disaster Risk Reduction. **53**: p. 102030.
- Ahile, S. and E. Andityavyar, 2014, *Household Perception and Preparedness against Flooding in Makurdi Town, Benue State, Nigeria*. IOSR Journal of Environmental Science, Toxicology and Food Technology. **8**(11): p. 01-06.
- Muñoz, D.F., et al., 2021, *From local to regional compound flood mapping with deep learning and data fusion techniques*. Science of The Total Environment. **782**: p. 146927.
- Wang, Y., et al ,۲۰۱۹ ,*Flood susceptibility mapping in Dingnan County (China) using adaptive neuro-fuzzy inference system with biogeography based optimization and imperialistic competitive algorithm*. Journal of environmental management. **247**: p. 712-729.
- Paul, S. and S. Ganju, 2021, *Flood segmentation on Sentinel-1 SAR imagery with semi-supervised learning*. arXiv preprint arXiv:2107.08369.
- Kuenzer, C., et al., 2013, *Flood mapping and flood dynamics of the Mekong Delta: ENVISAT-ASAR-WSM based time series analyses*. Remote Sensing. **5**(2): p. 687-715.
- Ashley, S.T. and W.S. Ashley, 2008, *Flood fatalities in the United States*. Journal of Applied Meteorology and Climatology. **47**(3): p. 805-818.
- Islam, K.A., et al., 2020, *Flood detection using multi-modal and multi-temporal images: A comparative study*. Remote Sensing. **12**(15): p. 2455.
- Ip, F., et al., 2006, *Flood detection and monitoring with the Autonomous Sciencecraft Experiment onboard EO-1*. Remote Sensing of Environment. **101**(4): p. 463-481.
- Helber, P., et al., 2019, *Eurosat: A novel dataset and deep learning benchmark for land use and land cover classification*. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. **12**(7): p. 2217-2226.
- Guha-Sapir, D., R. Below ,and P. Hoyois, 2016, *EM-DAT: the CRED/OFDA international disaster database*.



- Ferreira, C.S., et al., 2018, *Effect of peri-urban development and lithology on streamflow in a Mediterranean catchment*. Land Degradation & Development. **29**(4): p. 1141-1153.
- Kamilaris, A. and F.X. Prenafeta-Boldú, 2018, *Disaster monitoring using unmanned aerial vehicles and deep learning*. arXiv preprint arXiv:1807.11805.
- Langhammer, J. and T. Vacková, 2018, *Detection and mapping of the geomorphic effects of flooding using UAV photogrammetry*. Pure and Applied Geophysics. **175**: p. 3223-3245.
- Udomsiri, S. and M. Iwahashi, 2008, *Design of FIR filter for water level detection*. World Academy of Science, Engineering and Technology. **48**: p. 47-52.
- Nguyen, D.H. and D.-H. Bae, 2020, *Correcting mean areal precipitation forecasts to improve urban flooding predictions by using long short-term memory network*. Journal of Hydrology. **584**: p. 124710.
- Qi, X., T. Wang, and J. Liu. *Comparison of support vector machine and softmax classifiers in computer vision*. in *2017 Second International Conference on Mechanical, Control and Computer Engineering (ICMCCE)*. 2017. IEEE.
- Arabameri, A., et al., 2019, *A comparison of statistical methods and multi-criteria decision making to map flood hazard susceptibility in Northern Iran*. Science of the Total Environment. **660**: p. 443-458.
- GHOSH, B., S. Garg, and M. Motagh, 2022, *Automatic Flood Detection from SENTINEL-1 Data Using Deep Learning Architectures*. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. **3**: p. 201-208.
- Cherqui, F., et al., 2015, *Assessing urban potential flooding risk and identifying effective risk-reduction measures*. Science of the Total Environment. **514**: p. 418.۴۲۵-