



# Journal of Environmental Studies

Vol. 47, No. 2, Summer 2021

Journal Homepage: [www.Jes.ut.ac.ir](http://www.Jes.ut.ac.ir)

Print ISSN: 1025-8620 Online ISSN 2345-6922

## Deep Learning Network for Flood Extent Mapping Based on the Integration of Sentinel 2 and MODIS Satellite Imagery

Document Type  
Research Paper

Parisa Dodangeh<sup>1</sup>, Hamid Ebadi<sup>1</sup>, Abbas Kiani<sup>2</sup>

Received  
April 3, 2021

<sup>1</sup> Department of Photogrammetry, Faculty of Surveying, Khajeh Nasir Toosi University of Technology, Tehran, Iran

Accepted  
July 14, 2021

<sup>2</sup> Faculty of Civil Engineering, Noshirvani University of Technology, Babol, Iran

DOI: 10.22059/JES.2021.325289.1008187

### Abstract

The occurrence of floods in metropolitan areas always causes a lot of damages to various infrastructures. Therefore, providing methods with the ability to accurately assess these damages in the shortest possible time is a necessity of crisis management. In this regard, various methods for classifying remote sensing images have been developed, which always face challenges in differentiating land uses. Another challenge in flood crisis management is the lack of access to satellite imagery with high temporal resolution while maintaining spatial resolution. The purpose of this study is to evaluate the damage caused by the flood crisis in Khuzestan province following the flood of 1398, which is based on integration of images of Sentinel 2 and MODIS to produce a time series with relatively good spatial and temporal resolution. In order to prepare maps, a patch-based hierarchical convolutional neural network has been designed, which solves the challenge of extracting deep features due to the relatively weak structure of images with a resolution of more than 10 meters. Finally, the area of damage to urban land cover and various agricultural lands has been estimated consecutively during the flood period. The results indicated that the proposed approach was properly faced with the challenge of speed and accuracy in preparing a flood destruction map, implementing on images at different times of the flood shows the generality.

**Keywords:** Deep learning, Convolutional neural network, Image fusion, Flood map, Flood crisis management

---

\* Corresponding author:

Email: [a.kiani@nit.ac.ir](mailto:a.kiani@nit.ac.ir)

## Introduction

Flood is a natural hazard that causes many deaths each year, and due to the effects of climate change, the number of occurrences is increasing worldwide. Therefore, natural disaster damage assessment, such as floods, provides important information to support decision-making and policy development in the field of natural hazard management and climate change planning. In this regard, in recent years, various methods for classifying remote sensing images have been developed, which always face challenges in differentiating a variety of land uses. Another challenge in flood crisis management is the lack of access to satellite imagery with high temporal resolution while maintaining spatial resolution, which is more pronounced in the presence of cloud cover in the area and occurs during floods. The purpose of this study is to identify flooded areas in Khuzestan province following the flood of 1398, which is based on the integration of optical images of Sentinel 2 and MODIS to produce a time series with relatively good spatial and temporal resolution. In order to classify and prepare maps, a patch-based hierarchical convolutional neural network has been designed, which solves the challenge of extracting deep features due to the relatively weak structure of images with a resolution of more than 10 meters. In addition, the effect of different neighborhood dimensions on the extraction of deep features in all images has been investigated. Finally, the area of damage to urban land cover and various agricultural lands has been estimated consecutively during the flood period.

## Material and methods

The data used in this research are two series of different satellite images including Sentinel-2 MSI Level-1C images with a spatial resolution of 10 meters and the product of MODIS daily surface reflectance (MOD09GA) with a spatial resolution of 500 meters. The general process of implementing this research can be summarized in 7 phases. In the first phase, the data is first pre-processed. Then, in the second phase, the image fusion algorithm is implemented to predict the daily surface reflectivity of the images, and if the error and accuracy of the predicted images are appropriate, the time series of the flood period is obtained. In the third phase, Ground truth maps are prepared by the researcher using image interpretation. In the fourth phase, training samples are prepared from these data to perform various classifications such as deep learning approaches and machine learning, and the proposed network is implemented in different input dimensions. It should be noted that the number of training and validation samples in deep learning networks has been very limited and less than half a percent of images to automate and reduce user dependence. In the fifth phase, to perform damage assessment in the agricultural and vegetation regions, the relevant maps are prepared with the best approach tested in the previous phase, and finally, in the sixth phase, accuracy assessments are performed by the confusion matrix and related criteria. In the last phase which is the seventh phase, the area of flood-affected land uses is estimated.

## Discussion

The present study is implemented to improve one of the most important issues in crisis management in the country, namely the assessment of damage caused by the sudden phenomenon of floods. Therefore, presenting a method with appropriate speed compared to existing methods and also increasing the accuracy of final maps due to its challenging has been one of the objectives of this research. First, in order to prepare a suitable time series of optical data with an appropriate spatial and temporal resolution, the ESTARFM fusion algorithm was used. According to the evaluations performed for the two integrated images, this algorithm has high efficiency and accuracy in areas with heterogeneous coverage. Due to the change in environmental conditions between the images, the maximum errors have occurred in water-sensitive bands, but all errors due to their small values in each band indicate the efficiency of the algorithm used. In addition, since the two images are predicted in time series, so the generalizability of the algorithm has been investigated and proven. Furthermore, regarding the classification algorithms for preparing the destruction map, the proposed neural network has a significant difference in accuracy compared to other approaches. In addition, in the study of the extracted classes, in the proposed approach, the built-up areas benefit from a very high identification compared to other algorithms and the appropriateness of other uses, especially the use of water areas, is maintained. According to the studies, the highest rate of flooding in the study area was in the third

week of April and after that, the area has been experiencing a decreasing trend. Therefore, the damage was estimated on April 14 and 21. According to the assessments, flooding has decreased from April 14 to April 21 in built-up areas, rainfed and fallow lands, and has increased in wetland and Aquatic cultivation areas.

### **Conclusion**

In this research, the ESTARFM image fusion algorithm, which is known to be suitable for combining images in heterogeneous regions, has been used for April 8 and April 14 images, and the evaluations have been done with the help of scatter plots and least-squares error. The results showed the efficiency of the method in integrating relatively high-resolution Sentinel 2 images and low-resolution MODIS images in the field of flood management. In the field of identifying flooded areas and further due to the poor structure of images with a resolution above 10 meters, the possibility of extracting optimal and deep features is difficult. In the present study, a patch-based convolutional neural network has been designed with a minimum of layers and hyper-parameters, which provides the possibility of training from scratch with the least amount of training samples and without overfitting for images with different environmental conditions. Also, in order to find the optimal state, the dimensions of different inputs in all images have been tested to make a comparison of the effect of different neighborhoods. Thus, patches of sizes 3 to 11 were tested, patches 5 and 7 in the pre-flood image, and patches 9 and 11 in the post-flood images were the best. The results were compared with approaches such as object and pixel-based SVM, LCNN, and DCNN neural networks with dimensions of  $3 \times 3$  and  $5 \times 5$  according to the reference research, and had a significant improvement in accuracy. Time evaluations were performed between all approaches and the lowest time was related to the proposed approach with patch dimensions of  $3 \times 3$  and  $5 \times 5$  and the highest time was related to DCNN network with dimensions of  $5 \times 5$ . However, due to the importance of time in crisis management and the need to prepare a high-speed map, the proposed approach has provided an appropriate response. If the time and accuracy are proportionally considered in implementing the research, the designed network in  $9 \times 9$  input dimensions is recommended because in this case, both the accuracy and the time superiority are satisfied.

## استخراج محدوده‌های سیل‌زده بر پایه ادغام تصاویر ماهواره‌ای سنتینل ۲ و مادیس و مبتنی بر شبکه یادگیری عمیق

پریسا دودانگه<sup>۱</sup>، حمید عبادی<sup>۱</sup>، عباس کیانی<sup>۲\*</sup>

۱ گروه فتوگرامتری، دانشکده نقشه‌برداری، دانشگاه خواجه‌نصیرالدین طوسی، تهران، ایران

۲ عضو قطب علمی فناوری اطلاعات مکانی، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران، ایران

۳ گروه نقشه‌برداری، دانشکده عمران، دانشگاه صنعتی نوشیروانی بابل

تاریخ وصول مقاله: ۱۴۰۰/۱/۱۴

تاریخ پذیرش مقاله: ۱۴۰۰/۴/۲۳

### چکیده

رخداد سیلاب در مناطق نیمه‌شهری همواره با خسارات زیادی به زیرساخت‌های مختلف همراه است. لذا ارائه رویکردهایی با توانایی ارزیابی دقیق مناطق سیل‌زده در کمترین زمان ممکن از ضرورت‌های مدیریت بحران می‌باشد. بدین منظور روش‌های طبقه‌بندی تصاویر توسعه داده‌شده که با چالش‌هایی در تفکیک کاربری‌ها روبه‌رو می‌باشند. از جمله چالش‌های موجود در مطالعات سیل، عدم دسترسی به تصاویر ماهواره‌ای با وضوح زمانی بالا ضمن حفظ دقت مکانی می‌باشد. هدف این تحقیق، برآورد میزان آب‌گرفتگی کاربری‌های مختلف در پی رخداد سیل در استان خوزستان در سال ۱۳۹۸ می‌باشد که بر اساس تلفیق تصاویر انجام‌گرفته است. به‌منظور تهیه نقشه‌ی مناطق تحت تأثیر سیلاب نیز اقدام به طراحی شبکه عصبی کانولوشنی مبتنی بر پنجره تصویری شده که چالش موجود در استخراج ویژگی‌های عمیق با توجه به ساختار نسبتاً ضعیف تصاویر مورد‌استفاده را برطرف می‌نماید. درنهایت نقشه سیلاب در کاربری‌های مختلف به‌صورت متوالی در دوران سیلاب برآورد شده است. نقشه‌های کاربری قبل از سیل توسط روش پیشنهادی دقت ۷۳ و نقشه‌های کاربری پس از سیل به ترتیب زمانشان، دقت‌های ۷۵، ۷۷/۵ و ۷۹ را کسب نمودند. نتایج حاکی از عملکرد مناسب رویکرد پیشنهادی در مواجهه با چالش سرعت و دقت بوده که پیاده‌سازی آن بر روی تصاویر مختلف سیلاب بیانگر عمومیت داشتن فرآیند می‌باشد.

### کلیدواژه

یادگیری عمیق، شبکه عصبی کانولوشنی، تلفیق تصاویر، نقشه سیلاب، مدیریت بحران سیل.

### سرآغاز

تصمیم‌گیری و توسعه سیاست‌ها در زمینه‌ی مدیریت مخاطرات طبیعی و برنامه‌ریزی‌های لازم مطابق با تغییرات اقلیم فراهم می‌کند (Merz et al., 2010). با پیشرفت فناوری ماهواره‌ای در دهه‌های اخیر، سنجنش‌ازدور به‌طور گسترده‌ای برای استخراج اطلاعات مربوط به سطح زمین

سیل یک خطر طبیعی است که هر ساله باعث مرگ بسیاری می‌شود و به دلیل اثرات تغییر اقلیم، تعداد رخداد آن در سراسر جهان در حال افزایش است (Zaffaroni and Rossi, 2020)؛ بنابراین ارزیابی خسارت فجایع طبیعی مانند سیلاب، اطلاعات مهمی را برای حمایت از

به دلیل رزولوشن مکانی پایین تصاویر، در این مقاله اقدام به انجام فیوژن با تصاویر لندست شده است. بدین ترتیب با کمک تصاویر لندست دقت مکانی و با کمک تصاویر مادیس دقت زمانی تأمین می‌شود. در این پژوهش فیوژن بین تصاویر لندست و مادیس با مدل ESTARFM صورت گرفت و در نهایت نقشه سیل توسط تصویر قطعه‌بندی شده با طبقه‌بندی کننده ماشین بردار پشتیبان<sup>۳</sup> تهیه شد. ارزیابی نتایج حاصل نیز با نقشه سیل به‌عنوان داده واقعیت زمینی صورت گرفته است. در نهایت نتایج بیانگر توانایی بالای این الگوریتم تلفیق تصاویر بوده است (Dao et al., 2019). در کاربردهای دیگر نیز تحقیقاتی جدید در زمینه‌ی تلفیق تصاویر مختلف با الگوریتم فیوژن یادشده، صورت گرفته است. برای مثال Wang و همکاران (۲۰۲۰)، یک روش عملی برای تولید محصولات پوشش گیاهی با قدرت تفکیک مناسب از نظر مکانی و زمانی با مقیاس لندست و مادیس که به ترتیب ۳۰ متر و ۲۵۰ متر هستند، ارائه نمودند. روش تلفیق مورد استفاده در پژوهش ذکر شده، الگوریتم ESTARFM بوده که پس از انجام ارزیابی‌های لازم کارایی آن ثابت گردیده است (Wang et al., 2020). در ادامه جهت نظارت مستمر بر رشد محصول در طول دوره رشد و مدیریت محصول، Zhou و همکاران (۲۰۲۰) نیز از الگوریتم ESTARFM برای ادغام تصاویر بازتاب Sentinel-2 و Sentinel-3 و از یک مدل رگرسیون خطی بین داده‌های LAI بازیابی شده از تصاویر فیوژن جهت بررسی رشد محصول استفاده نمودند (Zhou et al., 2020). بررسی‌ها نشان از کاربرد این الگوریتم در زمینه‌های مختلفی که نیاز به بررسی‌های فشرده از نظر زمانی دارند و در عین حال نیازمند حفظ وضوح مکانی نیز می‌باشند، دارد. تحقیقاتی که صرفاً بر روی افزایش قدرت تفکیک مکانی تصاویر با استفاده از ادغام باندهای مختلف یک تصویر متمرکز بوده‌اند غالباً از محدودیت قدرت تفکیک زمانی برخوردار هستند زیرا با توجه به توضیحات داده شده، اگرچه این تصاویر قدرت تفکیک مکانی مناسب دارند

با دقت بالا استفاده می‌شود. با این حال، برای ارزیابی تأثیرات ناشی از سیل، تصاویر مکانی و زمانی با وضوح بالا قبل و بعد از وقوع رویداد مورد نیاز است تا وضعیت قبلی را با وضعیت پس از رویداد مقایسه کند (Jiménez-Jiménez et al., 2020). به‌طور معمول برای به دست آوردن تصاویر با قدرت تفکیک مکانی و زمانی بالا، از تکنیک‌های تلفیق داده استفاده می‌شود؛ بنابراین ترکیب داده‌های سنجنش‌ازدوری از سنجنده‌های مختلف راهی به‌منظور افزایش توانایی سنجنش از دور برای نظارت بر سطح زمین است (Mohammadizadeh et al., 2018).

در دهه اخیر تحقیقاتی مرتبط با روش‌های تلفیق داده در زمینه‌ی سیل انجام شده است. برای مثال Zhang و همکاران (۲۰۱۴)، جهت تلفیق تصاویر مادیس و لندست و تهیه تصویر با قدرت تفکیک مکانی زمانی نسبتاً خوب در راستای پایش سیلاب شهری اقدام به آزمایش دو الگوریتم STARFM<sup>۱</sup> و ESTARFM<sup>۲</sup> نمودند. آن‌ها اظهار داشتند که اگرچه هر دو الگوریتم از دقت بالایی در زمینه‌ی پیش‌بینی مقادیر سطح روزانه تصاویر برخوردارند ولیکن ESTARFM در این زمینه بهتر عمل کرده است (Zhang et al., 2014). در ادامه، Du و همکاران (۲۰۱۶)، ابتدا به کمک روش‌های مختلف فیوژن، باند مادون‌قرمز کوتاه ماهواره‌ی سنتینل ۲، با قدرت تفکیک مکانی بیست متر را به ده متر تبدیل کرده و پس از آن توسط شاخص MNDWI که با استفاده از باندهای سبز و فرورسرخ کوتاه محاسبه می‌گردد، اقدام به شناسایی پهنه‌های آبی در منطقه نمودند (Du et al., 2016). در سال ۲۰۱۹ پژوهشی با عنوان "فیوژن تصویر Landsat-MODIS و تجزیه و تحلیل تصویر مبتنی بر روش شیء‌گرا برای مشاهده مناطق سیل‌زده در یک صحنه گیاهی ناهمگن" با هدف تهیه نقشه سیل در منطقه‌ای با پوشش گیاهی ناهمگن صورت گرفت. چون سیل‌های ناشی از طوفان نیازمند بررسی‌های پیوسته می‌باشند و اخذ تصاویر مادیس به‌صورت روزانه انجام می‌گیرد، این داده‌ها برای پیاده‌سازی انتخاب شده‌اند. ولیکن

مناطق سیل زده از تصاویر پهپاد پرداختند. در این تحقیق از یک شبکه VGG-based استفاده شده است. مدل تنظیم دقیق شده<sup>۶</sup> و یک k-fold cross validation جهت تخمین عملکرد مدل بر روی تصاویر جدید پهپاد اعمال گردید. برای تخمین دقت روش پیشنهادی ماتریس ابهام محاسبه شد و در نهایت جهت ارزیابی، نتایج قطعه‌بندی تصویر به دست آمده از FCN-16 با نتایج به دست آمده از FCN-32 و FCN-8 و SVM مقایسه گردید و ثابت شد که FCN-8 بهترین دقت را داراست (Gebrehiwot et al., 2019). در ادامه‌ی مطالعات بر روی سیلاب، Jain و همکاران (۲۰۲۰) در راستای در نظر گرفتن محدودیت مقدار داده‌های موجود برای طبقه‌بندی ماهواره‌ای سیل با شبکه‌های یادگیری عمیق آموزش از ابتدا، از یک شبکه از پیش آموزش دیده استفاده کردند که قبلاً بر روی مجموعه داده‌های بزرگ تصویر مانند ImageNet آموزش دیده بود. در چنین رویکردی لایه‌های اولیه شبکه معمولاً ویژگی‌های بسیار کلی را می‌آموزند، در حالی که ویژگی‌های عمیق‌تر در لایه‌های بعدی شبکه آموخته می‌شود. آن‌ها نتایج کار خود را با مناطق شناسایی شده توسط شاخص‌های آب مقایسه نمودند که نشانگر بهبود دقت در رویکرد پیشنهادی بود (Jain et al., 2020). Hashemi-beni و همکاران (۲۰۲۱) نیز تحقیقی در زمینه‌ی مدیریت بحران سیل به کمک الگوریتم‌های یادگیری عمیق ارائه نمودند. آن‌ها در پژوهش خود سعی کردند تا با ترکیب یک شبکه عصبی کانولوشنی و روش Region Growing مناطق پوشش گیاهی غرقاب شده را شناسایی نمایند. شبکه عصبی کانولوشنی انتخابی آن‌ها FCN بود که در راستای استخراج ویژگی‌های استفاده شد. نتایج نشان داد که استفاده از تکنیک data augmentation در FCN در طول روند آموزش می‌تواند در صورت وجود مجموعه داده کوچک، شبکه را بهبود دهد. اگرچه FCN نتایج امیدوارکننده‌ای برای شناسایی مناطق تحت تأثیر سیل ارائه می‌دهد، اما قادر به شناسایی میزان سیل در مناطق تحت پوشش سایه به صورت متراکم نیست. به همین علت

ولیکن مدت‌زمان اخذ مجدد از منطقه برای پایش پدیده سیل طولانی بوده و در اکثر مواقع شرایط جوی نظیر وجود ابر و مه برای هدف آشکارسازی تغییرات مشکل‌ساز می‌باشد. در تحقیقات مبتنی بر هدف تلفیق تصاویر متوسط مقیاس با تصاویر دارای قدرت تفکیک مکانی پایین از تصاویر لندست با وضوح ۳۰ متر جهت بهبود رزولوشن مکانی بهره گرفته می‌شود که این توان تفکیک مکانی برای پایش تغییرات و شناسایی عوارض در برخی موارد چالش برانگیز بوده است؛ بنابراین به جهت لزوم استفاده از سری زمانی برای مطالعات سیلاب با قدرت تفکیک مکانی نسبتاً خوب، در تحقیق حاضر از تصاویر سنتینل ۲ و مادیس استفاده گردیده است.

در کنار لزوم استفاده از سری‌های زمانی، استفاده از روش‌های خودکار شناسایی و آشکارسازی تغییرات می‌تواند در ارزیابی سریع خسارات بحران‌هایی نظیر سیل کمک شایانی نماید. در چند سال اخیر، یادگیری عمیق به‌عنوان یکی از روش‌های موفق استخراج ویژگی خودکار و طبقه‌بندی تصاویر سنجنش‌ازدوری شناخته شده است. به‌طورکلی روش‌های مختلفی در زمینه‌ی کلاسه‌بندی تصاویر سنجنش‌ازدور موجود است که از میان آن‌ها، روش شبکه عصبی کانولوشنی<sup>۴</sup> در یادگیری عمیق یکی از پرکاربردترین رویکردها در زمینه‌ی آشکارسازی تغییرات ناشی از سیل بوده است. به‌عنوان مثال در پژوهشی در سال ۲۰۱۷، یک رویکرد مبتنی بر یادگیری عمیق برای نگاشت پهنه‌های آبی ارائه شده است. پژوهشگران، یک شبکه F-CNN<sup>۵</sup> را برای شناسایی آب در تصاویر لندست آموزش دادند. محققان این مقاله یک معماری جدید CNN را طراحی کردند که قادر به یادگیری ویژگی‌های پوشش زمین در مقیاس‌های مختلف از تصاویر چند طیفی سنجنش‌ازدوری است. در این مدل، تعداد قابل‌توجهی از پارامترهای آموزش کاهش می‌یابد و آنالیز در مقیاس‌های مختلف ممکن می‌شود (Isikdogan et al., 2017). Gebrehiwot و همکاران (۲۰۱۹)، به بررسی پتانسیل رویکردهای شبکه عصبی کانولوشنی برای استخراج

ساختارهای ریز در تشخیص دقیق عوارض می‌باشد که امکان اخذ نتایج بسیار دقیق در نقشه نهایی را با سختی مواجه می‌نماید. به همین دلیل شبکه یادگیری عمیق ارائه شده از ویژگی‌های طیفی-مکانی به صورت هم‌زمان استفاده کرده تا دارای مزیت بهبود اطلاعات استخراجی از تصاویر باشد. لذا جهت بررسی‌های جامع‌تر، اندازه‌های مختلف ابعاد ورودی شبکه نیز برای بررسی تأثیر ابعاد همسایگی آزمایش شده و نتایج آن با نتایج حاصل از روش‌های مرسوم دیگر، مقایسه گردیده است. این تحلیل‌های قیاسی به منظور اجرای ارزیابی‌های نسبی صورت گرفته و به تحقیق حاضر عمومیت می‌بخشند.

### مواد و روش بررسی

#### منطقه مورد مطالعه

منطقه مورد مطالعه در این تحقیق شامل بخش‌های وسیعی از استان خوزستان که در سال ۱۳۹۸ تحت تأثیر سیل واقع شدند، می‌باشد. طبق بررسی‌ها، از اواخر اسفندماه سال ۱۳۹۷ بارش‌ها در کشور آغاز گردیده و با ادامه و تشدید روند آن در استان خوزستان، سیلاب از اوایل فروردین شروع شده و تا اواسط آن روند صعودی داشته است که در این بازه زمانی شهرهایی نظیر اهواز، حمیدیه و ... را به همراه بخش وسیعی از مناطق کشاورزی تحت تأثیر قرار داده است. در تحقیق حاضر، اقدام به تهیه نقشه‌های کاربری اراضی در ۴ دوره شامل یک دوره قبل سیل و سه دوره بعد از سیل از این منطقه به وسعت تقریبی ۶۵۰۰ کیلومتر مربع شده است. در شکل ۱، نمای کلی از منطقه مورد مطالعه قابل مشاهده است. لازم به ذکر است که ترکیب باندی کاذب مورد استفاده در شکل ۱ به ترتیب باندهای مادون قرمز کوتاه، مادون قرمز نزدیک و قرمز سنجنده لندست ۸ با نام‌های SWIR1، NIR و Red هستند.

#### داده‌های مورد استفاده

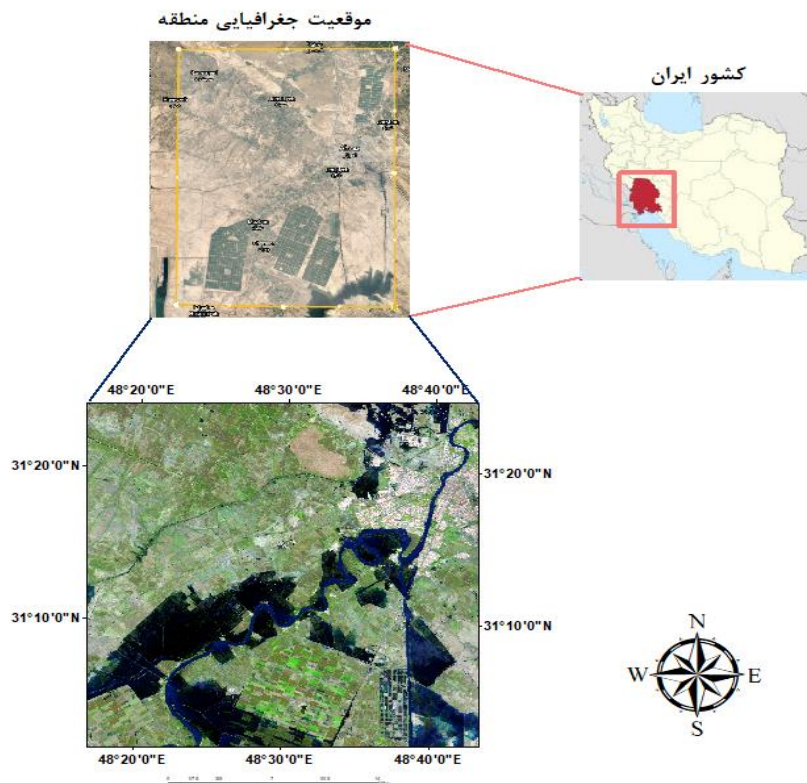
داده‌های مورد استفاده در این تحقیق دو سری تصاویر

رویگرد Region Growing به کمک DEM برای تشخیص سیلاب زیرپوشش گیاهی پیاده‌سازی شد و نتایج خوبی را در این زمینه ارائه کرد (Hashemi-Beni and Gebrehiwot, 2021).

نکته حائز اهمیت تمامی تحقیقات بررسی شده در این است که در آن‌ها از شبکه‌های تنظیم دقیق شده که اغلب دارای پارامترهای زیاد و محاسبات سنگین هستند، استفاده گردیده و طراحی شبکه‌های با آموزش از ابتدا<sup>۱</sup> با چالش روبه‌رو بوده است. شبکه‌های تنظیم دقیق اگرچه ارائه‌دهنده دقت‌های تقریباً مناسبی بوده‌اند ولیکن به دلیل آموزش آن‌ها با داده‌های غیر سنجنش‌ازدوری که از نظر ویژگی‌های طیفی، متفاوت از داده‌های سنجنش‌ازدوری هستند، از دقت‌های بالا برخوردار نمی‌باشند. از طرفی شبکه‌های با آموزش از ابتدا نیز جهت جلوگیری از مسائلی همچون بیش‌برازش<sup>۲</sup> نیازمند نمونه‌های آموزشی زیاد می‌باشند و چون در سنجنش‌ازدور در تهیه داده‌های مرتبط با مسئله مورد مطالعه محدودیت وجود دارد، این قضیه همواره با مشکل مواجه بوده است. در این تحقیق یکی از اهداف، استفاده از یک الگوریتم فیوژن کارا در کاربرد شناسایی محدوده‌های سیل‌زده به کمک تصاویر سنتینل ۲ (با قدرت تفکیک مکانی نسبتاً بالا) و تصاویر بازتابندگی سطحی روزانه مادیس (با قدرت تفکیک زمانی بالا) بوده که قدرت تفکیک مکانی سری زمانی تولید شده از سیلاب را نسبت به تحقیقات گذشته بهبود داده است. اهمیت تهیه سری زمانی نیز به جهت ایجاد امکان بررسی‌های دقیق‌تر در روند وارد شدن خسارات به منطقه‌ی متأثر می‌باشد. از اهداف دیگر این تحقیق، طراحی یک معماری عصبی کانولوشنی جدید با آموزش از ابتدا به طوری که در عین داشتن تعداد لایه‌های محدود و حداقل نیاز به تعداد نمونه‌های آموزشی بتواند ویژگی‌های عمیق را با سرعت بالا استخراج نماید و در کنار آن دچار بیش‌برازش نشود، می‌باشد. از چالش‌های دیگر استفاده از تصاویر با قدرت تفکیک مکانی بالای ۱۰ متر در شبکه‌های عصبی کانولوشنی با لایه‌های عمیق، کمبود

مکانی ۵۰۰ متر می‌باشد. تاریخ هر یک از تصاویر مورداستفاده در جدول ۱ ارائه شده است.

ماهواره‌ای مختلف شامل تصاویر Sentinel-2 MSI Level-1C با قدرت تفکیک مکانی ۱۰ متر و محصول بازتابندگی سطحی روزانه مادیس (MOD09GA) با قدرت تفکیک



شکل ۱. موقعیت جغرافیایی منطقه مورد مطالعه در زمان سیلاب

جدول ۱. تاریخ تصاویر مورداستفاده در تحقیق

وضعیت منطقه	تاریخ اخذ (شمسی)	تاریخ اخذ (میلادی)	نوع سکو	نام سنجنده
قبل از سیل	۱۳۹۸/۰۱/۰۲	۲۰۱۹/۰۳/۲۲	Sentinel-2B	سنتینل ۲
بعد از سیل	۱۳۹۸/۰۲/۰۱	۲۰۱۹/۰۴/۲۱	Sentinel-2B	
قبل از سیل	۱۳۹۸/۰۱/۰۲	۲۰۱۹/۰۳/۲۲	MOD09GA	مادیس
بعد از سیل	۱۳۹۸/۰۱/۱۹	۲۰۱۹/۰۴/۰۸	MOD09GA	
بعد از سیل	۱۳۹۸/۰۱/۲۵	۲۰۱۹/۰۴/۱۴	MOD09GA	
بعد از سیل	۱۳۹۸/۰۲/۰۱	۲۰۱۹/۰۴/۲۱	MOD09GA	

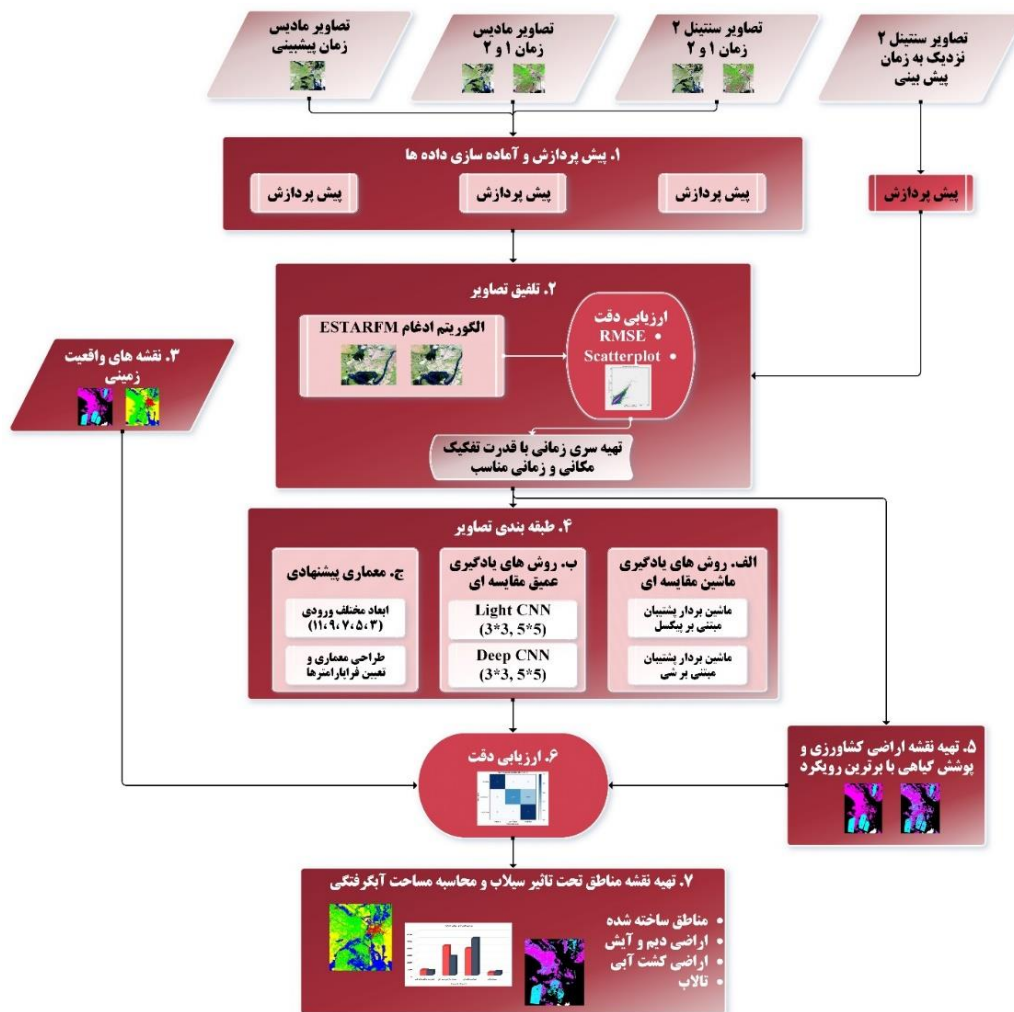
تصاویر اجرا گشته و در صورت مناسب بودن خطا و دقت تصاویر پیش‌بینی شده، سری زمانی از دوره سیلاب به دست می‌آید. در فاز سوم، نقشه‌های واقعیت زمینی توسط پژوهشگر به روش تفسیر تصاویر تهیه می‌شوند. در فاز چهارم، از این داده‌ها جهت انجام طبقه‌بندی‌های مختلف نظیر رویکردهای یادگیری عمیق و یادگیری ماشین، نمونه‌های آموزشی تهیه گشته و اقدام به اجرای شبکه

## روش تحقیق

روند کلی اجرای این تحقیق را در ۷ فاز می‌توان خلاصه نمود، شکل ۲ روندنمای پژوهش حاضر را نمایش می‌دهد.

در فاز اول، ابتدا داده‌های یادشده در جدول ۱ پیش‌پردازش می‌شوند. سپس در فاز دوم، الگوریتم تلفیق تصاویر به منظور پیش‌بینی بازتابندگی سطحی روزانه





شکل ۲. روند نمای کلی تحقیق

شرح جزئیات فازهای نامبرده شده پرداخته خواهد شد.

### فاز اول) پیش‌پردازش تصاویر

با توجه به آنکه در این پژوهش از دو سنجنده مختلف استفاده شده است، پیش‌پردازش‌ها متفاوت خواهد بود. از آنجایی که داده‌های سنتینل ۲ مورد استفاده از نوع سکوی 2B هستند بنابراین نیاز به تصحیحات اتمسفریکی دارند. در خصوص تصاویر مادیس، از آنجایی که از محصولات بازتابندگی سطحی استفاده شده است بنابراین تنها تصحیحات لازم تبدیل سیستم مختصات به UTM معادل با تصاویر سنتینل و کورجیستر سازی است.

پیشنهادی در ابعاد مختلف ورودی شده و در قیاس با سایر روش‌ها، الگوریتم‌های نامبرده در شکل ۲ نیز اجرا می‌گردد. لازم به ذکر است که تعداد نمونه‌های آموزشی و اعتبارسنجی در شبکه‌های یادگیری عمیق بسیار محدود و کمتر از نیم درصد تصاویر بوده است تا اتوماسیون و کاهش وابستگی به کاربر نیز رعایت گردد. در فاز پنجم برای شناسایی مناطق تحت تأثیر سیل در بخش‌های کشاورزی و پوشش گیاهی اقدام به تهیه نقشه‌های مربوطه با بهترین رویکرد آزمون شده در فاز قبل گشته و در نهایت در فاز ششم اقدام به انجام ارزیابی‌های دقت توسط ماتریس ابهام و معیار مرتبط با آن می‌گردد. در فاز هفتم میزان مساحت کاربری‌های تحت تأثیر سیلاب برآورد می‌شود. در ادامه به

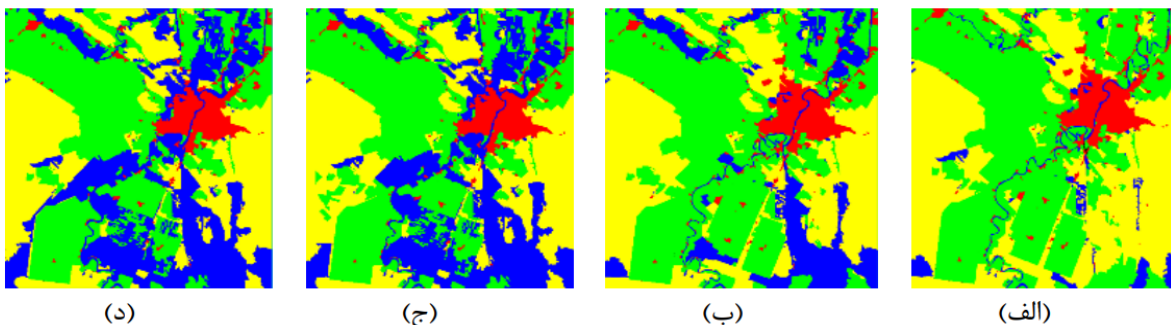
بیان شده در جدول ۱ به دست می‌آید و از آن‌ها در مراحل بعدی استفاده می‌شود.

### فاز سوم) تهیه نقشه‌های واقعیت زمینی

به منظور ارزیابی نتایج، تصاویر طبقه‌بندی شده باید با داده‌ی واقعیت زمینی مربوط به آن تاریخ مورد ارزیابی قرار گیرند. لذا نقشه واقعیت زمینی توسط فرد خبره به صورت تفسیر تصاویر چندطیفی و با کمک تصاویر گوگل ارث تهیه گشته است. این نقشه‌ها در ۴ کلاس شامل آب، پوشش گیاهی، زمین بایر و مناطق ساخته شده از روی همان سری زمانی تولید شده در مرحله قبل تولید می‌شوند. نقشه‌های واقعیت زمینی تهیه شده در شکل ۳ نمایش داده شده است.

### فاز دوم) تلفیق تصاویر با الگوریتم ESTARFM

مدل ESTARFM با استفاده از روند بازتاب مشاهده شده در زمان و الگوریتم اختلاط خطی طیفی، الگوریتم اصلی STARFM را بهبود می‌بخشد تا پیش‌بینی بهتری از بازتاب در مناظر متغیر و ناهمگن داشته باشد. از آنجاکه این روش تفاوت بازتابندگی در تغییر چشم‌اندازها را حساب می‌کند، نیاز به حداقل دو جفت تصویر سنتینل ۲ و مادیس دارد که در تاریخ‌های مشابه به دست آمده‌اند؛ بنابراین در این تحقیق به جهت تولید دو تصویر پیش‌بینی در مقیاس سنتینل ۲، از ۴ تصویر مادیس و ۲ تصویر سنتینل ۲ بهره گرفته شده است. تصاویر مادیس پیش‌بینی، در دو تاریخ ۱۹ و ۲۵ فروردین و تصاویر زمان ۱ و ۲ الگوریتم، ۲ فروردین و ۱ اردیبهشت برای هر دو سری سنجنده در نظر گرفته شده است. بدین ترتیب سری زمانی از منطقه در ۴ تاریخ



شکل ۳. نقشه‌های واقعیت زمینی تهیه شده از منطقه؛ الف) ۲ فروردین، ب) ۱۹ فروردین، ج) ۲۵ فروردین، د) ۱ اردیبهشت.

### فاز چهارم) تهیه نمونه‌های آموزشی و طبقه‌بندی تصاویر

یکی از اهداف این پژوهش، طراحی یک شبکه سبک وزن و آموزش آن از ابتدا بوده است تا بتوان نسبت به شبکه‌های تنظیم دقیق که جهت آموزش از داده‌های غیر سنجنش‌زدوری استفاده می‌کنند، دقت بالاتری برای طبقه‌بندی کسب نمود. این موضوع با توجه به کمبود حجم زیادی از تصاویر سنجنش‌زدوری و نیاز مبرم به ساخت‌افزارهای قوی همواره از چالش‌های یادگیری عمیق به حساب آمده است. در این تحقیق برای آموزش و

اعتبارسنجی شبکه طراحی شده از تعداد بسیار کمی نمونه‌های آموزشی<sup>۹</sup> و اعتبارسنجی<sup>۱۰</sup> استفاده و درعین حال از بیش برآزش نیز جلوگیری شده است. مجموع تعداد نمونه‌های آموزشی برای هر تصویر تقریباً ۰/۳۵ درصد کل پیکسل‌های تصویر و تعداد نمونه‌های اعتبارسنجی نیز ۰/۲ درصد بوده است. این نمونه‌ها برای آموزش هر سه معماری یادگیری عمیق پیاده‌سازی شده به صورت یکسان استفاده شده‌اند.

هدف اصلی از طبقه‌بندی، گروه‌بندی پیکسل‌های تصویر در طبقات سطح زمین است ( Tamimi et al., )

CNN مبتنی بر پیکسل و ماشین بردار پشتیبان مقایسه شده است. نتایج طبقه‌بندی نشان می‌دهد که سیستم پیشنهادی به پیشرفت‌های قابل‌توجهی در دقت طبقه‌بندی نسبت به روش‌های مقایسه‌ای رسیده است. همچنین نویسندگان اظهار داشتند که این شبکه بر روی سایر داده‌های متوسط مقیاس نیز عملکرد خوبی خواهد داشت. با این حال، به دلیل ساختار پیچیده عمیق، این شبکه برای جلوگیری از بیش‌برازش و محاسبات سنگین، به نمونه‌های آموزشی زیادی نیاز داشت.

### شبکه عصبی کانولوشنی LCNN<sup>۱۲</sup>

در ادامه کار بر روی داده‌های متوسط مقیاس، Song و همکاران در سال ۲۰۱۹، معماری جدیدی تحت عنوان شبکه عصبی کانولوشن سبک را برای نقشه‌برداری از پوشش زمین با وضوح متوسط، جهت دستیابی به دقت بالا با ورودی طیفی تصاویر لندست ۸، پیشنهاد دادند (Song et al., 2019). LCNN حتی با وجود تعداد کمی از نمونه‌های آموزشی، توانست بدون بیش‌برازش، به دقت بالایی دست یابد. این معماری هزینه محاسباتی کمی دارد، زیرا در مقایسه با CNN های معمولی که برای کارهای طبقه‌بندی تصویر با وضوح بالا یا فرا طیفی استفاده می‌شوند، از نظر طراحی بسیار ساده‌تر است. شکل معماری این الگوریتم مطابق شکل ۵ می‌باشد.

این شبکه نیز مبتنی بر پیچ بوده و در دو ابعاد مختلف  $3 \times 3$  و  $5 \times 5$  آزمایش گردیده است. علاوه بر آن با بسیاری از رویکردهای مرسوم نظیر ماشین بردار پشتیبان و همچنین DCNN مقایسه شده و برتری آن توسط پژوهشگران اعلام گشته است.

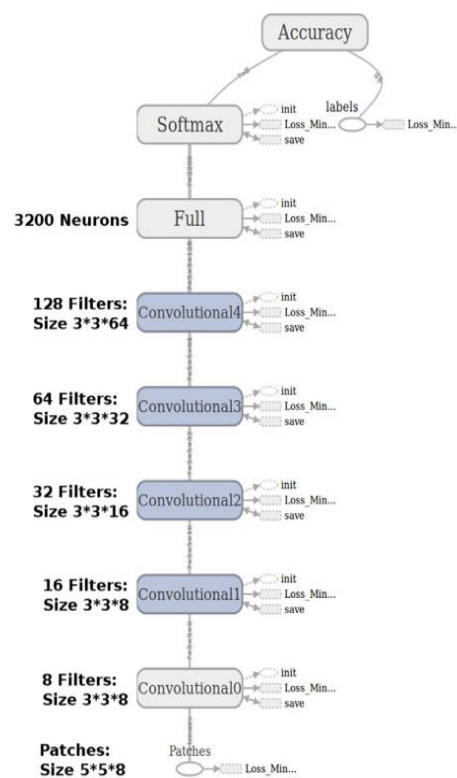
### شبکه عصبی کانولوشنی پیشنهادی

طبق تحقیقات صورت گرفته در سال‌های اخیر، شبکه‌های عصبی کانولوشنی با لایه‌های عمیق در برنامه‌های تشخیص عارضه به ساختارهای خوب تصویر وابسته می‌باشد که به دلیل کمبود چنین ساختارهای ریزی در

روش‌های مختلفی برای طبقه‌بندی و در ادامه آن شناسایی تغییرات بر اساس مقایسه داده‌های سنجنش‌ازدور دیجیتال چند طیفی در تحقیقات ارائه شده است (Singh, 1989)؛ بنابراین در این تحقیق از چندین الگوریتم مرسوم با دقت‌های بالا جهت بررسی دقیق‌تر و مقایسه جامع‌تر با معماری پیشنهادی استفاده شده که در ادامه به شرح آن‌ها پرداخته شده است.


### شبکه عصبی کانولوشنی DCNN<sup>۱۱</sup>

اولین مطالعه استفاده از شبکه عصبی کانولوشنی مبتنی بر پیچ‌های تصویری برای طبقه‌بندی پوشش زمین به کمک داده‌های با وضوح متوسط توسط Sharma و همکاران (Sharma et al., 2017) انجام شد. معماری این شبکه مطابق با شکل ۴ می‌باشد.



شکل ۴. معماری شبکه DCNN

این شبکه در پیچ سائز  $5 \times 5$  آزمایش گردیده و نتایج حاصل از آن با شبکه عصبی معمولی مبتنی بر پیکسل،



شکل ۵. معماری شبکه LCNN

ارتباط مکانی یک پیکسل با همسایگی آن، یک سیستم شبکه عصبی کانولوشنی مبتنی بر پیچ ارائه می‌گردد که برای داده‌های سنجش‌ازدوری با وضوح متوسط طراحی شده باشد. این سیستم با هدف ترکیب خصوصیات متمایز داده‌های با وضوح متوسط جهت بهبود شناسایی عوارض طراحی خواهد شد. علاوه بر آن مطابق با پژوهش موسوی و همکاران (Mousavi et al., 2019)، به دلیل امکان استفاده از تمامی نمونه‌های دارای برجسب، از اثر پدینگ آینه‌ای به‌عنوان پیش‌پردازش برای تصاویر استفاده گردیده است. معماری شبکه طراحی شده در شکل ۶ نمایش داده شده است.

تصاویر متوسط مقیاس، امکان اخذ نتایج بسیار دقیق در محصول نهایی وجود نخواهد داشت. هدف این پژوهش طراحی شبکه عصبی عمیق سبک با حداقل تعداد لایه و فرا پارامتر ضمن اخذ بیشترین دقت و افزایش سرعت آموزش همراه با انجام آزمایش‌هایی بر روی اندازه پیچ‌های ورودی، جهت تهیه نقشه مناطق خسارت‌دیده با استفاده از تصاویر ماهواره‌ای با وضوح متوسط به دست آورد، می‌باشد. لازم به ذکر است که دقت کم روش‌های طبقه‌بندی مبتنی بر پیکسل موجود برای داده‌های با قدرت تفکیک متوسط یک عامل محدودکننده اساسی در کاربردهای حساسی نظیر مدیریت بحران سیل است. لذا در این پژوهش با توجه به



شکل ۶. ساختار شبکه پیشنهادی

شبکه از ادغام دو زیر شبکه یکسان تشکیل شده است که دلیل آن ترکیب ویژگی‌های مختلف به‌منظور بارز سازی آن‌ها بوده است. این زیر شبکه‌ها دارای دو لایه کانولوشن

این شبکه طوری طراحی شده است که تنها با داشتن چندلایه محدود و محاسبات سبک به ویژگی‌های سطح بالا از داده‌های متوسط مقیاس دست یابد. به‌صورت کلی این

می‌آید تا در مرحله‌ی برآورد سطح آب‌گرفتگی مناطق از آن‌ها استفاده گردد. این عمل به دلیل اهمیت برآورد دقیق مساحت آسیب در بخش‌های کشاورزی صورت گرفته است تا بتوان انواع زمین‌های زراعی را بهتر تفکیک کرده و مساحت آسیب‌دیده را برای هریک محاسبه نمود.

### فاز هفتم) ارزیابی دقت نقشه‌های طبقه‌بندی شده

به‌منظور ارزیابی نتایج، تصاویر تولید شده با داده‌ی واقعیت زمینی مربوطه مورد ارزیابی قرار می‌گیرند. برای ارزیابی، ماتریس ابهام را می‌توان با استفاده از داده‌های واقعیت زمینی تشکیل داد. سپس پارامترهای دقت کلی، ضریب کاپا، دقت تولیدکننده و کاربر محاسبه شده است.

### فاز هفتم) برآورد مساحت مناطق تحت تأثیر سیلاب

در نهایت جهت دستیابی به هدف اصلی تحقیق، اقدام به محاسبه مساحت آب‌گرفتگی در طول بازه زمانی رخداد سیل می‌گردد. لذا پس از تهیه نقشه کاربری‌های تحت تأثیر نیز می‌توان سطح آسیب وارده بر منطقه مورد مطالعه را محاسبه کرده و بدین ترتیب به برنامه‌ریزی و مدیریت پس از بحران سیل اقدام نمود.

### نتایج و بحث

در این قسمت نتایج به‌دست آمده از فازهای مختلف تحقیق نمایش و به‌صورت مطلق و نسبی ارزیابی شدند.

### ارزیابی نتایج تلفیق تصاویر

به‌منظور صحت سنجی تصویری که در اثر اجرای الگوریتم‌های تلفیقی به دست می‌آید، نیاز به انجام ارزیابی‌های دقت می‌باشد. این ارزیابی می‌تواند به‌صورت مختلفی انجام گیرد که در این تحقیق دو مورد از مرسوم‌ترین و دقیق‌ترین آن‌ها اجرا شده است. لذا در این بخش ابتدا تصاویر تولیدی نمایش داده شده و سپس توسط ترسیم نمودارهای پراکنندگی و محاسبه خطای RMS ارزیابی دقت صورت می‌گیرد.


بوده که در طراحی آن‌ها، در لایه با عمق کمتر از ابعاد بزرگ‌تر و تعداد فیلتر کمتر و در لایه‌ی عمیق، ابعاد کوچک‌تر و تعداد فیلترهای بیشتر در نظر گرفته شده است. سپس بعد از هر لایه کانولوشن یک لایه Batch Normalization به‌کار رفته که دلیل آن کاهش تغییر توزیع و جلوگیری از محوشدگی گرادیان می‌باشد. این لایه موجب کاهش حساسیت شبکه به مقداردهی اولیه وزن‌ها نیز می‌گردد. در ادامه به‌منظور تسریع در آموزش شبکه از تابع فعال‌ساز ELU پس از هر لایه Batch Normalization استفاده گردیده است که موجب بهبود آموزش شبکه نیز می‌گردد. لازم به ذکر است که توابع RELU و LeakyRELU نیز آزمایش گردیده و عملکرد ضعیف‌تری نسبت به تابع فعال‌ساز استفاده شده داشتند. در این پژوهش از هیچ‌گونه لایه Dropout بهره گرفته نشده است زیرا طبق تحقیقات لایه Batch Normalization به‌تنهایی می‌تواند از بیش‌برازش جلوگیری نموده و نقش یک رگیولایزر را نیز ایفا کند. در کنار لایه Dropout، از لایه ادغام یا Max Pooling نیز جهت جلوگیری از حذف ویژگی‌ها استفاده نشده و بدین ترتیب شبکه امکان استفاده از تمامی ویژگی‌های استخراجی را خواهد داشت. در نهایت ویژگی‌ها توسط یک لایه تماماً متصل به‌صورت بردار درآمده و ویژگی‌های دو زیر شبکه با یکدیگر ترکیب و وارد لایه Dense با ۴ کلاس می‌گردند. لایه نهایی وظیفه وزن دهی خودکار به‌منظور تعیین درجه تعلق هر نمونه به کلاس مشخص را دارا می‌باشد. این شبکه در ۱۰ اپک و با اپتیمایزر Adamax، با نرخ آموزشی ۰/۰۰۱ آموزش دیده است.

### فاز ششم) تهیه نقشه‌های پوشش گیاهی

برای انجام مراحل بعدی یعنی تهیه نقشه مناطق تحت تأثیر سیلاب و به‌منظور تفکیک بهتر عوارض مرتبط با بخش‌های کشاورزی و پوشش گیاهی، نقشه‌های مربوطه توسط بهترین رویکرد آزمایش شده در تحقیق به دست

۷، تصاویر ادغام شده در تاریخ‌های ۱۹ و ۲۵ فروردین از نظر بصری نیز همانند تصویر سنتینل ۲ در قسمت ج دارای کیفیت مناسب می‌باشند. این موضوع همچنین به لحاظ نزدیکی تاریخ و مشابهت منطقه در دو تاریخ ۲۵ فروردین و ۱ اردیبهشت ملموس‌تر است.


تصاویر تلفیق شده در شکل ۷ قسمت الف و ب نمایش داده شده‌اند و به جهت مقایسه بصری بهتر تصویر سنتینل ۲ نیز در قسمت ج نمایش داده شده است. اگرچه به منظور اطمینان از توانایی روش به کار برده شده در تلفیق تصاویر از روش‌های مختلف ارزیابی استفاده شده ولیکن این موضوع باید به صورت بصری نیز قابل رؤیت باشد. مطابق با شکل



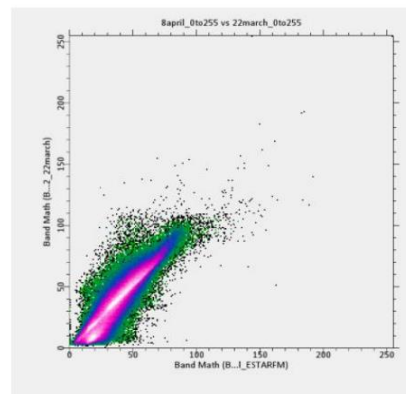
شکل ۷. تصاویر منطقه؛ (الف) تصویر ۱۹ فروردین (تلفیق شده)، (ب) تصویر ۲۵ فروردین (تلفیق شده)، (ج) تصویر ۱ اردیبهشت (سنتینل ۲).

می‌رود. مقدار یکی از متغیرها (متغیر کنترل) به عنوان مقدار محور افقی و مقدار متغیر دیگر (متغیر پاسخ) به عنوان مقدار محور عمودی در نظر گرفته می‌شود. نمودار پراکندگی برای تحلیل همبستگی دو متغیر نیز به کار می‌رود. نمودارهای هر تصویر تلفیق شده با تصویر سنتینل نزدیک‌تر به آن تاریخ تهیه گشته است.

در ادامه به منظور ارزیابی دقت و اثبات کارایی الگوریتم در ادغام تصاویر، نمودارهای پراکندگی به عنوان نمونه برای یک باند تصاویر ارائه شده است. نمودار پراکندگی نموداری است که از نمایش یک نقطه به ازای هر جفت متغیر در دستگاه مختصات دکارتی به دست می‌آید. این نمودار معمولاً برای نمایش نحوه پاسخ یک متغیر (متغیر پاسخ) به تغییرات متغیر دیگر (متغیر کنترل) به کار



ب



الف

شکل ۸. نمودار پراکندگی مقادیر تصاویر تلفیق شده؛ (الف) باند ۱ تصویر ۱۹ فروردین، (ب) باند ۱ تصویر ۲۵ فروردین.

نتیجه گرفت که با توجه به نمودارهای رسم شده این الگوریتم طبق تحقیقات پیشین که بر روی تصاویر لندست و مادیس صورت گرفته بودند، دارای عملکرد مناسب بوده و این موضوع در کاربرد نقشه مناطق تحت تأثیر سیل و با ادغام تصاویر جدیدی نظیر سنتینل ۲ و مادیس نیز صادق می‌باشد. در ادامه به جهت اطمینان بیشتر از کارایی این رویکرد، خطای RMS هریک از تصاویر محاسبه و در جدول ۲ نمایش داده شده است.

تراکم پیکسل‌های تصویر در نمودارهای پراکنندگی نشان می‌دهد که همبستگی زیادی بین تصاویر سنتینل ۲ و تصاویر تلفیق شده وجود دارد. اگرچه در برخی موارد خطاهایی نظیر بیش برآورد<sup>۱۳</sup> و ناچیز شماری<sup>۱۴</sup> نیز وجود دارد که ناشی از (۱) متفاوت بودن تاریخ تصاویر مرجع و پیش‌بینی و به تبع آن تغییر شرایط جوی و (۲) استفاده از دو جفت تصویر با تاریخ‌های مختلف و سنجنده‌های متفاوت برای پیش‌بینی مقادیر هر تصویر می‌باشد، ولیکن به دلیل مقادیر محدود آن، قابل چشم‌پوشی است. نهایتاً می‌توان

جدول ۲. برآورد میزان RMSE تصاویر تلفیق شده در هر باند

باند ۶	باند ۵	باند ۴	باند ۳	باند ۲	باند ۱	شماره باند تصویر
۰/۰۰۲۶	۰/۰۰۲۲	۰/۰۰۲۲	۰/۰۰۱۹	۰/۰۰۱۳	۰/۰۰۱۵	۱۹ فروردین
۰/۰۰۱۸	۰/۰۰۱	۰/۰۰۱۳	۰/۰۰۱۳	۰/۰۰۰۹	۰/۰۰۱۱	۲۵ فروردین

اردیبهشت (تصویر مرجع) نسبت به شباهت تصویر ۱۹ فروردین با تصویر مرجع دانست.

مطابق با خطای RMS برآورد شده برای باندها مختلف هر تصویر که مقدار ناچیزی بوده است، می‌توان نتیجه‌گیری‌های نمودار پراکنندگی را تأیید کرد که این موضوع بیانگر اثبات کارایی الگوریتم در تلفیق تصاویر در زمان‌های مختلف می‌باشد. همان‌گونه که در شکل‌ها نیز دیده می‌شد، بیشترین اختلافات در باندهای حساس به آب NIR و SWIR بوده است که ریشه در تغییرات محیط خصوصاً در کاربری‌های آب و پوشش گیاهی دارد. همچنین دلیل بیشتر بودن خطای تصویر ۱۹ فروردین نسبت به ۲۵ فروردین را می‌توان شباهت بیشتر و اختلاف‌زمانی کمتر تصویر ۲۵ فروردین به تصویر ۱

### ارزیابی نتایج شبکه پیشنهادی در ابعاد مختلف

از چشم‌اندازهای بیان شده در این تحقیق، ارزیابی رویکرد پیشنهادی در ابعاد مختلف بوده تا در تصاویر و شرایط محیطی مختلف، بهترین پیچ سایز ورودی شناسایی گردد. همچنین بدین صورت می‌توان یک حالت بهینه از ابعاد ورودی را نیز معرفی نمود. لذا در این قسمت اقدام به انجام ارزیابی‌های کمی با پارامترهای مهمی نظیر دقت کلی و ضریب کاپا در جدول ۳ شده است.

جدول ۳. دقت کلی (درصد) شبکه پیشنهادی در پیچ سایزهای مختلف

۱۱×۱۱	۹×۹	۷×۷	۵×۵	۳×۳	ابعاد پیچ تاریخ تصویر
۷۱/۵۵	۷۱/۶۱	۷۲/۷۸	۷۱/۸۲	۷۱/۱۹	۲ فروردین
۷۵/۰۳	۷۴/۱۵	۷۳/۷۱	۷۳/۳۰	۷۲/۶۴	۱۹ فروردین
۷۷/۳۹	۷۷/۶۰	۷۶/۵۰	۷۵/۹۱	۷۴/۳۰	۲۵ فروردین
۷۸/۸۸	۷۹/۱۷	۷۸/۶۷	۷۷/۴۲	۷۵/۸۱	۱ اردیبهشت

پیش از سیل، کمتر و ابعاد آن نسبت به سایر تصاویر که بخش وسیعی را در برمی‌گیرد، کوچکتر بوده است و به همین دلیل نیاز به انتخاب تعداد پیکسل همسایگی کوچکتر برای آموزش خواهد داشت. در سایر تصاویر که مربوط به تاریخ سیلاب هستند، پیچ سائزهای ۹ و ۱۱ دقت بالایی دارند و اختلاف آن‌ها ناچیز می‌باشد؛ بنابراین می‌توان تعمیم‌پذیری این پیچ سائز را در دوران سیلاب نیز اثبات نمود. در جدول ۴، معیار ضریب کاپای هر تصویر در ابعاد گوناگون ارائه و بررسی شده است. نتایج حاصل شده از جدول ۴ نیز مشابه با جدول ۳ بوده و تکمیل‌کننده این بخش از ارزیابی می‌باشد.

نتایج جدول ۳ به صورت کلی نمایش‌دهنده دقت مناسب این روش در شناسایی عوارض می‌باشد. همان‌گونه که مشاهده می‌شود در تصویر قبل از سیل بهترین ابعاد ورودی مربوط به بعد ۷×۷ می‌باشد و در سایر تصاویر مربوط به دوران سیلاب، پیچ سائزهای ۹ و ۱۱ از دقت‌های بالاتری برخوردار بوده‌اند. این امر در درجه اول نشانگر کاهش خطاها در ابعاد بالاتر همسایگی نسبت به پیچ سائزهای ۳ و ۵ و در درجه دوم بهبود استخراج ویژگی در اطراف پیکسل مرکزی که منجر به بهبود آموزش شبکه می‌شود، است. همچنین دلیل اختلاف در دقت پیچ سائز تصویر قبل سیل با تصاویر پس از سیل را می‌توان شرایط محیطی تصویر عنوان نمود زیرا مساحت کاربری نظیر آب

جدول ۴. ضریب کاپا (درصد) شبکه پیشنهادی در پیچ سائزهای مختلف

ابعاد پیچ	۳×۳	۵×۵	۷×۷	۹×۹	۱۱×۱۱	تاریخ تصویر
۲ فروردین	۵۱/۴۴	۵۲/۳۴	۵۳/۳۵	۵۱/۱۰	۵۲/۷۹	
۱۹ فروردین	۵۷/۷۱	۵۹/۰۶	۵۹/۴۵	۶۰/۳۸	۶۱/۷۹	
۲۵ فروردین	۶۱/۹۹	۶۴/۹۳	۶۵/۹۸	۶۷/۱۸	۶۷/۲۰	
۱ اردیبهشت	۶۴/۰۵	۶۷/۲۶	۶۹/۱۳	۶۹/۷۱	۶۹/۴۳	

و هرکدام به صورت جداگانه بررسی گردیده‌اند. در جدول ۵، معیارهای دقت کلی و ضریب کاپای بهترین پیچ سائز رویکرد پیشنهادی با رویکرد ماشین بردار پشتیبان بر مبنای پیکسل و شیء ارائه و مقایسه شده است.

### ارزیابی نسبی شبکه پیشنهادی با رویکردهای یادگیری ماشین

به منظور انجام ارزیابی‌های بهتر و مقایسه‌های شفاف‌تر نتایج رویکرد پیشنهادی با سایر روش‌ها، جداولی تهیه شده

جدول ۵. ارزیابی نسبی شبکه پیشنهادی با رویکردهای یادگیری ماشین

ضریب کاپا (درصد)			دقت کلی (درصد)			معیار ارزیابی
Pixel_based SVM	Object_based SVM	شبکه پیشنهادی	Pixel_based SVM	Object_based SVM	شبکه پیشنهادی	روش
۴۴/۷۴	۴۶/۳۵	۵۳/۳۵	۶۷/۴۸	۶۷/۷۹	۷۲/۷۸	۲ فروردین
۵۲/۳۴	۵۵/۵۱	۶۱/۷۹	۶۸/۹۱	۶۹/۸۵	۷۵/۰۳	۱۹ فروردین
۵۲/۹۲	۶۱/۰۶	۶۷/۱۸	۶۷/۸۵	۷۳/۱۵	۷۷/۶۰	۲۵ فروردین
۵۷/۵۲	۶۴/۹۶	۶۹/۷۱	۷۱/۱۰	۷۵/۶۰	۷۹/۱۷	۱ اردیبهشت



## ارزیابی نسبی شبکه پیشنهادی با رویکردهای یادگیری عمیق

در جدول ۶، ارزیابی نسبی میان رویکرد پیشنهادی با شبکه‌های عصبی کانولوشنی نظیر LCNN و DCNN صورت گرفته است. این دو شبکه یادگیری عمیق در تحقیق حاضر، در دو بعد  $3 \times 3$  و  $5 \times 5$  آزمایش گردیده‌اند زیرا در پژوهش مربوط به LCNN، نویسندگان نیز آزمایش‌های خود را بر روی این دو پیچ سایز انجام دادند و در پژوهش مربوط به DCNN، آزمایشات بر روی پیچ سایز ۵ صورت گرفته است.

جدول ۶. ارزیابی نسبی شبکه پیشنهادی با رویکردهای یادگیری عمیق مقایسه‌ای

کاپا (درصد)					دقت کلی (درصد)					معیار
DCNN 5x5	DCNN 3x3	LCNN 5x5	LCNN 3x3	پیشنهادی شبکه	DCNN 5x5	DCNN 3x3	LCNN 5x5	LCNN 3x3	پیشنهادی شبکه	روش تاریخ تصویر
۵۱/۷۸	۴۸/۹۹	۴۹/۸۷	۵۰/۱۱	۵۳/۳۵	۷۱/۴۱	۶۹/۳۷	۷۰/۰۹	۷۰/۷۵	۷۲/۷۸	۲ فروردین
۵۷/۹۳	۵۸/۲۷	۵۶/۰۷	۵۷/۰۶	۶۱/۷۹	۷۲/۱۵	۷۲/۲۳	۷۰/۶۴	۷۱/۷۳	۷۵/۰۳	۱۹ فروردین
۶۱/۰۰	۶۰/۰۴	۵۵/۴۸	۶۰/۵۵	۶۷/۱۸	۷۲/۵۲	۷۲/۱۰	۶۹/۲۱	۷۲/۳۸	۷۷/۶۰	۲۵ فروردین
۶۶/۵۳	۶۳/۳۶	۶۴/۳۳	۶۵/۹۵	۶۹/۷۱	۷۶/۸۱	۷۴/۳۵	۷۵/۰۴	۷۶/۷۱	۷۹/۱۷	۱ اردیبهشت

کلی و ضریب کاپا انجام گرفت و از مقایسه سه جدول ۳، ۵ و ۶ نتیجه شد که رویکرد پیشنهادی در ابعاد بالاتر از ۵ از تمامی رویکردهای مقایسه‌ای در تمامی ابعاد دقت بالاتری داشته است که کارایی این شبکه طراحی شده را در حالت‌های مختلف به اثبات می‌رساند. حال یکی از مهم‌ترین نکات در عملکرد الگوریتم‌های مختلف، زمان اجرای آن‌ها می‌باشد که این مسئله در زمینه‌های نظیر مدیریت بحران از اهمیت بسیار بالای برخوردار است؛ بنابراین شبکه طراحی شده باید علاوه بر اخذ دقت‌های بالا در سریع‌ترین زمان ممکن پاسخگویی نیاز پژوهشگران باشد. در این بخش اقدام به ارزیابی زمانی تمامی رویکردهای اجرا شده در جدول ۷ گشته است.

مطابق با جدول فوق، ابتدا رویکرد پیشنهادی در تمامی تصاویر دارای دقت بالا بوده و پس‌از آن رویکرد SVM مبتنی بر شی دقت بهتری را نسبت به SVM مبتنی بر پیکسل اخذ نموده است که در اینجا نه تنها برتری شبکه عصبی پیشنهادی نمایش داده شده بلکه برتری روش‌های مبتنی بر پیچ و قطعه در مقایسه با پیکسل مبنای اثبات گردیده است. در بخش بعدی به ارزیابی شبکه پیشنهادی در بهترین حالت با شبکه‌های عصبی کانولوشنی نامبرده شده در بخش روش‌ها پرداخته خواهد شد.

همان‌گونه که مشاهده می‌شود، رویکرد پیشنهادی از دقت‌های بسیار بالاتری نسبت به رویکردهای یادگیری عمیق بررسی شده در این تحقیق برخوردار است. این اختلاف چشمگیر در معیارهای بررسی شده بین رویکرد پیشنهادی با سایر رویکردها در تمامی تصاویر که دارای شرایط مختلفی هستند، نشانگر عمومیت شبکه در کسب دقت‌های بالا می‌باشد. همچنین طبق پژوهش Song و همکارانش (Song et al. 2019)، شبکه LCNN در پیچ سایز ۳ دقت بالاتری را در تمامی موارد نسبت به پیچ سایز ۵ کسب نموده است.

## ارزیابی زمانی رویکردهای اجرایی

تا بدین مرحله ارزیابی‌های دقت توسط دو پارامتر دقت

نیاز دارد.

### ارزیابی نسبی بهینه‌ترین حالات هر رویکرد

در این قسمت، ارزیابی به کمک معیار دقت‌های تولیدکننده و کاربر برای هر کلاس در نقشه‌های تولیدی با بالاترین دقت در هر رویکرد انجام گرفته است؛ یعنی برای مثال در هر تاریخ، بین SVM پیکسل مبنا و شیء مبنا، بین LCNN با ابعاد  $3 \times 3$  و  $5 \times 5$  و بین DCNN با ابعاد  $3 \times 3$  و  $5 \times 5$  یکی دارای دقت بیشتر بوده و آن وارد ارزیابی این مرحله گردیده است. این عمل به جهت بررسی‌های راحت‌تر و عدم ایجاد پیچیدگی به دلیل زیاد بودن تعداد نتایج انجام گرفته است. نتایج این بخش در جدول ۸ قابل مشاهده می‌باشد.

طبق توضیحات ارائه شده در بخش‌های قبل، هدف نهایی این تحقیق، تولید نقشه مناطق مختلف تحت تأثیر سیل با دقت و سرعت مناسب به صورت سری زمانی بوده است؛ بنابراین در این راستا دقت هر یک از کلاس‌های تعیین شده و تناسب آن‌ها با یکدیگر امر ضروری بوده و در ارزیابی کمی میزان آسیب وارده به کاربری‌های مختلف منطقه نیمه‌شهری خصوصاً کاربری‌های شهر و پوشش گیاهی تأثیر به سزایی دارد. برای مثال در جدول ۸، در تصویر قبل از سیل، در رویکردهای مقایسه‌ای کاربری شهر دارای دقت بسیار پایین و در نتیجه آن خطای بالایی می‌باشد که این موضوع روند محاسبات را دچار مشکل اساسی می‌کند. این در حالی است که در رویکرد پیشنهادی نه تنها دقت کلاس شهر بالا بوده بلکه سایر کلاس‌ها نیز دارای دقت مناسبی برای شناسایی می‌باشند. در تمامی تصاویر بررسی شده می‌توان به تناسب دقت کلاس‌ها خصوصاً دقت کاربر در مناطقی ساخته شده اشاره نمود. در رویکرد پیشنهادی ضمن حفظ دقت در کلاسی مانند آب، دقت سایر کلاس‌ها نیز از تناسب خوبی برخوردار بوده است که گام نهایی را ممکن‌تر می‌سازد.

جدول ۷. ارزیابی زمانی

تعداد اپک	زمان هر اپک (ثانیه)	نام شبکه
۱۰	۲	شبکه پیشنهادی $3 \times 3$
۱۰	۲	شبکه پیشنهادی $5 \times 5$
۱۰	۶	شبکه پیشنهادی $7 \times 7$
۱۰	۱۰	شبکه پیشنهادی $9 \times 9$
۱۰	۲۱	شبکه پیشنهادی $11 \times 11$
۱۰	۱۱	LCNN $3 \times 3$
۱۰	۱۱	LCNN $5 \times 5$
۳۰	۱۸	DCNN $3 \times 3$
۳۰	۹۳	DCNN $5 \times 5$

به صورت کلی رویکرد SVM چه مبتنی بر شی و چه مبتنی بر پیکسل نیازمند زمان بیشتری نسبت به سایر رویکردها جهت استخراج خروجی است. لذا از ارائه زمان دقیق آن‌ها در جدول فوق خودداری گشته است. شبکه DCNN طبق مقاله مرجع در ۳۰ اپک و شبکه LCNN در ۱۰ اپک اجرا گردیده‌اند. شبکه طراحی شده نیز در ۱۰ اپک بهترین نتایج را از نظر زمانی و دقت دارد. بر اساس یک دیدگاه جامع در تحقیق حاضر در تمامی تصاویر پیچ‌سایزهای بالاتر از ۵ دقت‌های بهتری نسبت به دو شبکه LCNN و DCNN در پیچ‌سایز ۳ و ۵ داشته‌اند. از نظر زمانی، شبکه DCNN با توجه به داشتن تعداد اپک بالا، دارای محاسبات سنگینی بوده که کارا نمی‌باشد اما در مقایسه با شبکه LCNN پیچ‌سایز ۱۱ رویکرد پیشنهادی کمی زمان بیشتری می‌برد. لکن طبق بررسی‌های انجام شده دقت پیچ‌سایز ۹ و ۱۱ در تمامی موارد بسیار مشابه بوده و اختلاف قابل‌اغماضی دارند. بدین ترتیب در صورتی که تنها دقت مدنظر باشد شبکه پیشنهادی با پیچ‌سایز ۱۱ توصیه شده و در صورتی که زمان مدنظر قرار گیرد، پیچ‌سایز ۵ و ۷ توصیه می‌گردد. ولیکن در صورتی که هر دو پارامتر مورد توجه باشد، شبکه پیشنهادی با ابعاد ۹ دارای بهترین نتیجه می‌باشد که زمانی کمتر از هر دو شبکه LCNN و DCNN

جدول ۸. دقت‌های کاربر و تولید کننده تصاویر


دقت کاربر (درصد)				دقت تولید کننده (درصد)				معیار		تاریخ تصویر
پوشش گیاهی	ساخته شده مناطق	زمین بایر	پهنه‌های آبی	پوشش گیاهی	ساخته شده مناطق	زمین بایر	پهنه‌های آبی	کلاس	روش	
۷۳/۴۸	۶۱/۰۷	۷۴/۲۵	۶۷/۱۹	۸۱/۶۷	۵۱/۵۱	۶۵/۷۰	۶۶/۷۶	رویکرد پیشنهادی ۷×۷	۰۱/۰۲	
۷۹/۹۳	۳۸/۱۸	۶۲/۱۳	۵۹/۵۴	۶۴/۲۱	۳۹/۹۷	۷۶/۴۸	۶۵/۵۶	Object_based SVM		
۷۷/۹۳	۶۴/۳۶	۶۴/۰۱	۷۴/۹۱	۷۱/۰۳	۴۲/۱۵	۷۶/۰۹	۵۵/۹۳	LCNN 3×3		
۷۶/۰۲	۴۸/۵۲	۶۹/۹۷	۶۶/۷۱	۷۶/۷۳	۵۰/۶۶	۶۸/۸۳	۶۵/۰۲	DCNN 5×5		
۷۶/۹۰	۵۲/۹۵	۷۴/۴۵	۷۸/۷۴	۸۱/۴۴	۵۷/۱۷	۶۸/۰۶	۸۴/۴۰	رویکرد پیشنهادی ۱۱×۱۱	۰۱/۱۹	
۸۲/۳۳	۳۰/۰۵	۶۴/۸۲	۸۳/۵۵	۶۶/۹۵	۵۲/۵۷	۷۲/۱۲	۸۱/۳۰	Object_based SVM		
۷۲/۴۸	۳۵/۱۵	۸۱/۷۵	۷۹/۱۰	۸۵/۳۳	۵۵/۴۴	۵۴/۶۷	۷۸/۰۴	LCNN 3×3		
۷۷/۴۸	۴۶/۹۹	۷۱/۵۴	۷۰/۶۵	۷۴/۵۹	۵۰/۶۶	۶۷/۵۶	۸۵/۸۸	DCNN 3×3		
۷۳/۵۲	۵۹/۳۸	۷۲/۲۸	۹۵/۶۹	۷۹/۰۶	۵۴/۵۸	۷۷/۰۰	۸۰/۲۷	رویکرد پیشنهادی ۹×۹	۰۱/۲۵	
۷۱/۲۰	۴۱/۹۸	۶۵/۱۶	۹۶/۷۳	۷۱/۹۵	۳۳/۸۹	۷۸/۴۲	۷۷/۱۵	Object_based SVM		
۷۰/۳۶	۳۰/۹۶	۷۴/۹۱	۹۷/۰۹	۸۱/۳۸	۵۹/۹۸	۶۶/۷۵	۶۸/۷۵	LCNN 3×3		
۷۱/۳۰	۲۸/۲۳	۷۸/۵۷	۹۸/۰۲	۸۲/۷۴	۶۴/۶۴	۶۳/۹۸	۶۹/۵۰	DCNN 5×5		
۷۱/۱۶	۷۱/۹۱	۷۸/۴۱	۹۵/۹۶	۸۴/۳۹	۵۷/۱۸	۷۴/۰۸	۸۲/۳۴	رویکرد پیشنهادی ۹×۹	۰۲/۰۱	
۷۳/۸۵	۵۲/۹۱	۶۶/۱۲	۹۷/۴۲	۶۶/۴۳	۴۸/۱۶	۸۳/۰۲	۸۵/۱۷	Object_based SVM		
۶۶/۵۰	۶۰/۳۶	۸۱/۱۸	۸۷/۹۷	۸۹/۲۶	۵۰/۱۷	۶۵/۴۸	۷۷/۷۱	LCNN 3×3		
۶۹/۷۸	۴۸/۱۰	۷۷/۵۱	۹۸/۳۰	۸۲/۴۹	۵۷/۶۶	۷۲/۰۶	۷۸/۳۳	DCNN 5×5		

### محاسبه مساحت آب‌گرفتگی در مناطق مختلف

بوده است و پس‌از آن روند کاهش آب‌گرفتگی مشاهده می‌گردد، لذا جهت برآورد مساحت آسیب‌دیدگی منطقه از دو تصویر ۲۵ فروردین و ۲ اردیبهشت بهره گرفته شده است. شکل ۹ نمایشی از نقشه کاربری پوشش گیاهی را در تاریخ ۲۵ فروردین به همراه نقشه واقعیت زمینی آن ارائه می‌کند.

همان‌گونه که از مقایسه شکل‌های فوق می‌توان دریافت، با توجه به آنکه کلاس‌های نامبرده از شباهت بسیار بالایی نسبت به یکدیگر برخوردار هستند ولیکن رویکرد پیشنهادی قادر به تفکیک مناسب آن‌ها بوده است. همچنین جهت تأیید این موضوع، نتایج حاصل از ارزیابی دقت نقشه‌های طبقه‌بندی شکل ۹ در جدول ۹ ارائه شده که

در آخر در جهت نیل به هدف نهایی تحقیق، پس از تهیه نقشه‌های تغییرات اراضی، اقدام به برآورد سطح مناطق آسیب‌دیده در کاربری‌های شهری و پوشش گیاهی می‌گردد. پوشش گیاهی نیز پس از تهیه نقشه‌های کاربری اراضی اصلی به سه کلاس شامل اراضی کشت آبی، اراضی دیم و آیش و تالاب تفکیک می‌گردد و نقشه‌های آن تولید می‌شود. لذا در شکل ۹ اقدام به ارائه یک نمونه از نقشه‌های آسیب پوشش گیاهی منطقه توسط رویکرد پیشنهادی که کارایی آن در بخش پیشین بررسی گردید، شده است. همچنین به صورت کلی با توجه به آنکه اوج سیل گرفتگی منطقه در ۴ تصویر در تاریخ ۲۵ فروردین و ۲ اردیبهشت



شکل ۹. نقشه‌های پوشش گیاهی؛ الف) نقشه طبقه‌بندی ۲۵ فروردین، ب) نقشه واقعیت زمینی، ج) راهنمای نقشه.

در نهایت در جدول ۱۰ میزان آب‌گرفتنی در کاربری‌های مختلف منطقه مورد مطالعه در سطح پیکسل و در ۴ کاربری اصلی ارائه شده است.

بدین ترتیب از تاریخ ۲۵ فروردین تا ۱ اردیبهشت مساحت آب‌گرفتنی کاربری‌های مناطق ساخته شده و اراضی دیم و آیش کاهش ولیکن میزان آسیب به کاربری کشت آبی افزایش یافته است. با توجه به مقادیر چشمگیر سیلاب در منطقه، ضرورت برآورد آن با دقت و سرعت

در آن‌ها از دو معیار اصلی، دقت کلی و ضریب کاپا استفاده گردیده است.

جدول ۹. ارزیابی دقت نقشه‌های پوشش گیاهی

ضریب کاپا (درصد)	دقت کلی (درصد)	معیار / نقشه
۵۹/۰۰	۸۱/۳۷	۲ فروردین
۵۷/۰۰	۸۱/۹۱	۲۵ فروردین
۶۲/۰۰	۸۲/۸۰	۱ اردیبهشت

جدول ۱۰. مساحت آب‌گرفتنی در کاربری‌های مختلف

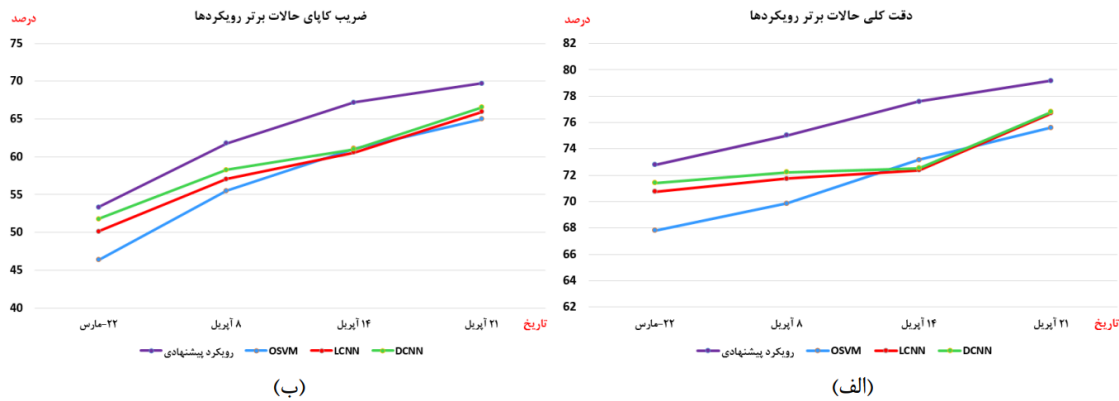
مساحت آب‌گرفتنی (هکتار)	تعداد پیکسل				تصویر / کاربری
	۲۵ فروردین	۱ اردیبهشت	۲۵ فروردین	۲ فروردین	
۶۶۱۷	۷,۳۶۲	۷۱۱,۱۰۲	۶۹۲,۴۷۵	۸۷۶,۵۱۷	مناطق ساخته شده
۲۶,۷۱۶	۴۱,۶۵۱	۲,۱۰۰,۰۵۲	۱,۷۲۶,۶۸۳	۲,۷۶۷,۹۶۳	اراضی دیم و آیش
۵۲,۴۰۸	۳۸,۳۲۲	۳,۶۱۶,۷۲۳	۳,۹۶۸,۸۸۰	۴,۹۲۶,۹۲۳	کشت آبی
۵,۱۷۳	۴,۰۹۶	۱۰۰,۸۳۳	۱۲۷,۷۵۹	۲۳۰,۱۴۹	تالاب

ادامه، نمودارهایی به جهت بررسی دقیق‌تر روش‌های پیاده‌سازی شده ارائه گردیده است. مطابق با توضیحات داده شده، شبکه عصبی پیشنهادی از اختلاف چشمگیری در دقت نسبت به سایر رویکردها برخوردار بوده است. علاوه بر آن در بررسی کلاس‌های استخراج شده، در رویکرد پیشنهادی، کاربری مناطق ساخته شده از شناسایی بسیار بالایی در مقایسه با الگوریتم‌های


مناسب در سری زمانی‌های مختلف نمایان می‌گردد. تحقیق حاضر در تلاش برای بهبود یکی از مهم‌ترین مسائل در مدیریت بحران کشور یعنی ارزیابی خسارات ناشی از پدیده ناگهانی سیل پیاده‌سازی شده است. لذا ارائه روشی با سرعت مناسب نسبت به روش‌های موجود و همچنین افزایش دقت نقشه‌های نهایی با توجه به چالش‌برانگیز بودن آن از اهداف این تحقیق بوده است. در

شبکه عصبی پیشنهادی، با افزایش ابعاد در تصاویر پس از سیل، خطای شناسایی کاهش یافته که بهینه‌ترین حالت آن با توجه به دقت و زمان اجرا، پیچ سایز ۹ معرفی شده است.

دیگر بهره‌مند بوده و تناسب دیگر کاربری‌ها به خصوص کاربری پهناهای آبی حفظ گردیده است. همچنین طبق بررسی‌های صورت گرفته در مورد ابعاد مختلف ورودی در



شکل ۹. ارزیابی مقایسه‌ای حالات برتر هر رویکرد



شکل ۱۰. ارزیابی کمی سطح آب‌گرفتنی در مناطق مختلف

### نتیجه‌گیری

ارزیابی خسارات ناشی از بحران سیل از مهم‌ترین مسائل در مدیریت بحران به شمار می‌آید. یکی از چالش‌های مرسوم در مدیریت بحران سیل، ابری بودن منطقه تحت تأثیر و در نتیجه ایجاد خلل در تصاویر اپتیکی می‌باشد. یکی از راه‌حل‌های موجود در مواجهه با این مسئله استفاده از داده‌های چند منبعی و تکنیک‌های تلفیق تصاویر می‌باشد. در این تحقیق از الگوریتم ادغام تصاویر ESTARFM که مناسب تلفیق تصاویر در مناطق ناهمگن

مطابق با بررسی‌های انجام‌گرفته، بیشترین میزان آب‌گرفتنی در منطقه مورد مطالعه در هفته چهارم فروردین بوده و پس از آن منطقه با روند کاهشی مواجه بوده است. لذا تعیین سطح آسیب در تاریخ‌های ۲۵ فروردین و ۱ اردیبهشت انجام گرفت است. طبق نمودار ۱۱ و ارزیابی‌های صورت گرفته در بخش قبل، آب‌گرفتنی از تاریخ ۲۵ فروردین تا ۱ اردیبهشت در مناطق ساخته‌شده و اراضی دیم و آیش کاهش و در مناطق کشت آبی و تالاب با افزایش روبه‌رو بوده است.

نقشه با سرعت بالا، رویکرد پیشنهادی پاسخ مناسبی را ارائه نموده است. در صورتی که در اجرای تحقیق، زمان و دقت به طور متناسب مدنظر باشد، شبکه طراحی شده در ابعاد ورودی  $9 \times 9$  پیشنهاد می‌گردد زیرا در این صورت هم برتری دقت و هم زمان در مقایسه با الگوریتم‌های مقایسه‌ای ایجاد می‌شود. به منظور برآورد مساحت آب‌گرفتگی منطقه نیز نقشه‌های پوشش گیاهی به صورت جداگانه با رویکرد پیشنهادی در ۳ کلاس شامل اراضی زراعت آبی، اراضی دیم و آیش و تالاب‌ها تهیه شده و در مجموع بررسی تغییرات در ۴ کلاس مناطق ساخته شده، اراضی دیم و آیش، اراضی زراعت آبی و تالاب‌ها انجام شده است. نتایج به صورت کلی بیانگر بهبود دقت و سرعت تهیه نقشه در مقابل سایر رویکردهای مقایسه‌ای می‌باشد که امکان اجرایی ساختن هدف تهیه نقشه مناطق تحت تأثیر سیلاب در کاربری‌های مهمی نظیر منطقه نیمه‌شهری را با سرعت بالا و بدون نیاز به نقشه‌های خاص و تنها با تصاویر سنجنش‌ازدوری فراهم می‌آورد.

#### یادداشت‌ها

1. Spatial and Temporal Adaptive Reflectance Fusion Model
2. ESTARFM Spatial and Temporal Adaptive Reflectance Fusion Model
3. Support vector machine
4. Convolutional neural network
5. Fully convolutional neural network
6. Fine tune
7. From scratch
8. Overfitting
9. Training sample
10. Validation sample
11. Deep convolutional neural network
12. Light convolutional neural network
13. Over-estimation
14. Under-estimation

شناخته شده است، در دو زمان ۱۹ و ۲۵ فروردین استفاده گردیده و ارزیابی‌ها به کمک نمودارهای پراکنندگی و خطای کمترین مربعات صورت گرفته است. نتایج بیانگر کارایی روش در ادغام تصاویر سنتینل ۲ با وضوح نسبتاً بالا و تصاویر مادیس با وضوح پایین در کاربرد سیل بوده است. در زمینه‌ی شناسایی محدوده‌های سیل زده و در ادامه به دلیل ساختار ضعیف تصاویر با مقیاس بالای ۱۰ متر، امکان استخراج ویژگی‌های بهینه و عمیق با مشکل روبه‌روست. در تحقیق حاضر شبکه عصبی کانولوشنی مبتنی بر پیچ تصویری به صورت سلسله مراتبی با حداقل لایه و فرا پارامتر طراحی گردیده است که امکان آموزش از ابتدا با کمترین مقدار نمونه آموزشی و بدون بیش برازش را برای تصاویر با شرایط محیطی متفاوت فراهم می‌آورد. همچنین جهت یافتن بهینه‌ترین حالت، ابعاد ورودی‌های مختلف در تمامی تصاویر آزمایش گردیده است تا قیاسی از تأثیر همسایگی‌های متفاوت نیز انجام پذیرد. بدین ترتیب پیچ سایزهای ۳ تا ۱۱ آزمایش شدند که در تصویر قبل از سیل پیچ‌های ۵ و ۷ و در تصاویر بعد از سیل، پیچ‌های ۹ و ۱۱ بهترین‌ها بوده‌اند. دقت کلی نقشه‌های کاربری اراضی برای تصویر قبل از سیل،  $72/78$  و برای تصاویر بعد از سیل به ترتیب  $75/03$ ،  $77/60$  و  $79/17$  بوده که این نتایج با رویکردهایی نظیر SVM مبتنی بر شی و پیکسل، شبکه عصبی LCNN و DCNN با ابعاد  $3 \times 3$  و  $5 \times 5$  مطابق تحقیق مرجع، مقایسه شده و از بهبود دقت چشمگیری برخوردار بوده است. ارزیابی‌های زمانی نیز بین تمامی رویکردها صورت گرفته و کمترین زمان مربوط به رویکرد پیشنهادی با ابعاد پیچ  $3 \times 3$  و  $5 \times 5$  و بیشترین آن مربوط به شبکه DCNN با ابعاد  $5 \times 5$  بوده است. این در حالی است که با توجه به اهمیت زمان در مدیریت بحران و ضرورت تهیه

#### فهرست منابع

- Dao, P.D., Mong, N.T., & Chan, H.-P. (2019). Landsat-MODIS image fusion and object-based image analysis for observing flood inundation in a heterogeneous vegetated scene. *GIScience & Remote Sensing*, 56, 1148-1169

- Du, Y. Zhang, Y. Ling, F. Wang, Q. Li ,W. & Li, X. (2016). Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing*, 8, 354
- Gebrehiwot, A. Hashemi-Beni, L. Thompson, G. Kordjamshidi, P. & Langan, T.E. (2019). Deep convolutional neural network for flood extent mapping using unmanned aerial vehicles data. *Sensors*, 19, 1486
- Hashemi-Beni, L. & Gebrehiwot, A.A. (2021). Flood extent mapping: an integrated method using deep learning and region growing using UAV optical data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 2127-2135
- Isikdogan, F. Bovik, A.C. & Passalacqua, P. (2017). Surface water mapping by deep learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10, 4909-4918
- Jain, P. Schoen-Phelan, B. & Ross, R. (2020). Automatic flood detection in Sentinel-2 images using deep convolutional neural networks. In, *Proceedings of the 35th Annual ACM Symposium on Applied Computing* (pp. 617-623)
- Jiménez-Jiménez, S.I. Ojeda-Bustamante, W. Ontiveros-Capurata, R.E. & Marcial-Pablo, M.d.J. (2020). Rapid urban flood damage assessment using high resolution remote sensing data and an object-based approach . *Geomatics, Natural Hazards and Risk*, 11, 906-927
- Merz, B. Kreibich, H. Schwarze, R. & Thieken, A. (2010). Review article" Assessment of economic flood damage". *Natural Hazards and Earth System Sciences*, 10, 1697-1724
- Mohammadzadeh, P. Hamzeh, S. Kiavarz, M. & Darvishi Blorani, A. (2018). Derivation daily and high spatial resolution Land Surface Temperature using Fusion of Landsat and Modis Satellite Imagery. *Journal of Geospatial Information Technology*, 6, 77-99
- Mousavi, S.M. Ebadi, H. & Kiani ,A. (2019). Provide an Optimal Deep-network Method for Spectral-spatial Classifying of High Resolution Images. *Journal of Geomatics Science and Technology*, 9, 151-170
- Sharma, A. Liu, X. Yang, X. & Shi, D. (2017). A patch-based convolutional neural network for remote sensing image classification. *Neural Networks*, 95, 19-28
- Singh, A. (1989). Review article digital change detection techniques using remotely-sensed data. *International Journal of Remote Sensing*, 10, 989-1003
- Song, H. Kim, Y. & Kim, Y. (2019) .A patch-based light convolutional neural network for land-cover mapping using Landsat-8 images. *Remote Sensing*, 11, 114
- Tamimi, E. Ebadi, H. & Kiani, A. (2017). Evaluation of different metaheuristic optimization algorithms in feature selection and parameter determination in SVM classification. *Arabian Journal of Geosciences*, 10, 478
- Wang, B. Jia, K. Wei, X. Xia, M. Yao, Y. Zhang, X. Liu, D. & Tao, G. (2020). Generating spatiotemporally consistent fractional vegetation cover at different scales using spatiotemporal fusion and multiresolution tree methods. *ISPRS journal of photogrammetry and remote sensing*, 167, 214-229
- Zaffaroni, M. & Rossi, C. (2020). Water Segmentation with Deep Learning Models for Flood Detection and Monitoring. In, *Proceedings of the 17th ISCRAM Conference, Blacksburg, VA, USA* (pp. 24-27)
- Zhang, F. Zhu, X. & Liu, D. (2014). Blending MODIS and Landsat images for urban flood mapping. *International Journal of Remote Sensing*, 35, 3237-3253
- Zhou, X. Wang, P. Tansey, K. Zhang, S. Li, H. & Tian, H. (2020). Reconstruction of time series leaf area index for improving wheat yield estimates at field scales by fusion of Sentinel-2,3 and MODIS imagery. *Computers and Electronics in Agriculture*, 177, 105692