

Journal of Environmental Studies

Vol. 47, No. 2, Summer 2021

Journal Homepage: 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

Parisa Dodangeh¹, Hamid Ebadi^{1,2}, Abbas Kiani^{3*}

1 Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics Engineering, K.N.Toosi University of Technology, Tehran, Iran

2 Member of the Scientific Center of Spatial Information Technology, K.N.Toosi University of Technology, Tehran, Iran

3 Faculty of Civil Engineering, Babol 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

Document Type Research Paper

Received April 3, 2021

Accepted July 14, 2021

Journal of Environmental Studies

182

Vol. 47, No. 1, Summer 2021

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 floodaffected 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

Deep Learning Network for Flood Extent ...

Dodangeh Parisa., et al

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 3×3 and 5×5 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 3×3 and 5×5 and the highest time was related to DCNN network with dimensions of 5×5 . 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^ا، حمید عبادی^{۲۹۱}، عباس کیانی^۳

۱ گروه فتو گرامتری و سنجش از دور، دانشکده مهندسی نقشهبرداری، دانشگاه خواجهنصیرالدین طوسی، تهران، ایران ۲ عضو قطب علمی فناوری اطلاعات مکانی، دانشگاه صنعتی خواجهنصیرالدین طوسی، تهران، ایران ۳ گروه نقشه برداری، دانشکده عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران

تاریخ وصول مقاله: ۱۲/۱/۱٤

تاریخ پذیرش مقاله:۲۳٪۷۰۰۱٤

چکیدہ

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. ازجمله 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 پنچره 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 ۳۷ و نقشههای کاربری پس از سیل به ترتیب زمانشان، دقتهای کاربری و ۹۷ را کسب نمودند. نتایج حاکی از عملکرد مناسب رویکرد پیشنهادی در مواجه با چالش سرعت و دقت بوده که پیادهسازی آن بر روی تصاویر مختلف سیلاب بیانگر عمومیت داشتن فرآیند میباشد.

كليدواژه

يادگيرى عميق، شبكه عصبى كانولوشنى، تلفيق تصاوير، نقشه سيلاب، مديريت بحران سيل.

سر آغاز

سیل یک خطر طبیعی است که هرساله باعث مرگ بسیاری میشود و به دلیل اثرات تغییر اقلیم، تعداد رخداد آن در سراسر جهان در حال افزایش است (Rossi, 2020)؛ بنابراین ارزیابی خسارت فجایع طبیعی ماننـد سیلاب، اطلاعـات مهمـی را بـرای حمـایت از

تصمیم گیری و توسعه سیاستها درزمینهی مدیریت مخاطرات طبیعی و برنامهریزیهای لازم مطابق با تغییرات اقلیم فراهم میکند (Merz et al., 2010). با پیشرفت فناوری ماهوارهای در دهههای اخیر، سنجش ازدور به طور گستردهای برای استخراج اطلاعات مربوط به سطح زمین

محط شاسي ۱۸۶ دورهٔ ٤٧ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰

با دقت بالا استفاده می شود. بااین حال، برای ارزیابی تأثیرات ناشی از سیل، تصاویر مکانی و زمانی با وضوح بالا قبل و بعد از وقوع رویداد موردنیاز است تا وضعیت قبلی را با Jiménez-Jiménez et کند (al., 2020). مار ویداد مقایسه کند (al., 2020). مار ویداد مقایسه کند (al., 2020). استفاده می شود؛ بنابراین ترکیب داده های سنجش از دوری از سنجنده های مختلف راهی به منظور افزایش توانایی سنجش از دور برای نظارت بر سطح زمین است (Mohammadizadeh et al., 2018).

در دهه اخیر تحقیقاتی مرتبط با روشهای تلفیق داده درزمینهی سیل انجامشده است. برای مثال Zhang و همكاران (۲۰۱۴)، جهت تلفيق تصاوير ماديس و لندست و تهیه تصویر با قدرت تفکیک مکانی زمانی نسبتاً خوب در راستای پایش سیلاب شهری اقدام به آزمایش دو الگوریتم STARFM و ESTARFM نمودند. آنها اظهار داشتند که اگرچه هر دو الگوریتم از دقت بالایی درزمینهی پیشبینی مقادير سطح روزانه تصاوير برخوردارند وليكن Zhang et) در این زمینه بهتر عمل کرده است ESTARFM al., 2014). در ادامه، Du و همکاران (۲۰۱۶)، ابتدا به كمك روش هاى مختلف فيوژن، باند مادونقرمز كوتاه ماهوارهی سنتینل ۲، با قدرت تفکیک مکانی بیست متر را به ده متر تبدیل کرده و پسازآن توسط شاخص MNDWI که با استفاده از باندهای سبز و فروسرخ کوتاه محاسبه میگردد، اقدام به شناسایی پهنههای آبی در منطقه نمودند (Du et al., 2016). در سال ۲۰۱۹ پژوهشی با عنوان "فيوژن تصوير Landsat-MODIS و تجزيهوتحليل تصوير 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 می گیرد، این دادهها برای پیادهسازی انتخاب شدهاند. ولیکن

به دلیل رزولوشن مکانی پایین تصاویر، در این مقاله اقدام به انجام فيوژن با تصاوير لندست شده است. بدين ترتيب 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 درنهایت نقشه سیل توسط تصویر قطعهبندی شده با طبقهبندی کننده ماشین بردار پشتیبان^۳ تهیه شد. ارزیابی نتايج حاصل نيز با نقشه سيل بهعنوان داده واقعيت زميني صورت گرفته است. درنهایت نتایج بیانگر توانایی بالای اين الگوريتم تلفيق تصاوير بوده است (Dao et al., 2019). در کاربردهای دیگر نیز تحقیقاتی جدید درزمینهی 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 ازنظر مکانی و زمانی با مقیاس لندست و مادیس که به ترتیب ۳۰ متر و ۲۵۰ متر هستند، ارائه نمودند. روش تلفیق مورداستفاده در پژوهش ذکرشده، الگوريتم ESTARFM بوده كه پس از انجام ارزيابيهاي لازم كارايي آن ثابت گرديده 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 از یک مدل رگرسیون خطی بین دادههای LAI بازیابی شده از تصاویر فیوژن جهت بررسي رشد محصول استفاده نمودند (Zhou et al., 2020). بررسیها نشان از کاربرد این الگوریتم در زمینههای مختلفی که نیاز به بررسیهای فشرده ازنظر 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 متمركز بودهاند غالباً از محدوديت قدرت تفكيك زماني برخوردار هستند زيرا با توجه به توضيحات داده شده، اگرچه این تصاویر قدرت تفکیک مکانی مناسب دارند

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 مقیاس با تصاویر دارای قدرت تفکیک مکانی پایین از 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 نسبتا 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 می تواند در ارزیابی سریع خسارات بحران هایی نظیر سیل کمک شایانی نماید. در چند سال اخیر، یادگیری عمیق بهعنوان یکی از روش های موفق استخراج ویژگی خودکار و طبقهبندی تصاویر سنجشازدوری شناخته شده است. بهطوركلي روشهاي مختلفي درزمينهي كلاسهبندي تصاوير سنجشازدور موجود است که از میان آنها، روش شبکه عصبی کانولوشنی[†] در یادگیری عمیق یکی از پرکاربردترین رویکردها درزمینهی آشکارسازی تغییرات ناشی از سیل بوده است. بهعنوانمثال در پژوهشی در سال ۲۰۱۷، یک رویکرد مبتنی بر یادگیری عمیق برای نگاشت پهنههای آبی ارائهشده است. پژوهشگران، یک شبکه F-CNN 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 سنجشازدوری است. در این مدل، تعداد قابلتوجهی از پارامترهای آموزش کاهش مییابد و آنالیز در مقیاس های مختلف ممکن می شود (Isikdogan et Gebrehiwot .(al., 2017 و همکاران (۲۰۱۹)، به بررسی يتانسيل رويكردهاي شبكه عصبي كانولوشني براي استخراج

استخراج محدودههای سیلزده بر پایه ادغام تصاویر ... _____

147

پریسا دودانگه و همکا*ر*ان

مناطق سیلزده از تصاویر پهپاد پرداختند. در این تحقیق از یک شبکه VGG-based استفاده شده است. مدل تنظیم دقیق شده⁶ 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 درنهایت جهت ارزیابی، نتایج قطعهبندی تصویر بهدست آمده از FCN-16 با نتایج بهدست آمده از FCN-32 و FCN-8 و SVM مقایسه گردید و ثابت شد که FCN-8 بهترين 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 آموزشدیده بود. در چنین رویکردی لایههای اولیه شبکه معمولاً ویژگیهای بسیار کلی را میآموزند، درحالی که ویژگی های عمیق تر در لایه های بعدی شبکه آموخته میشود. آنها نتایج کار خود را با مناطق شناسایی شده توسط شاخص های آب مقایسه نمودند که نشانگر بهبود دقت در رویکرد پیشنهادی بود (Jain et al.,) 2020). Hashemi-beni و همكاران (۲۰۲۱) نيز تحقيقي در زمينهي مديريت بحران سيل به كمك الگوريتمهاي 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 می تواند در صورت وجود مجموعه داده کوچک، شبکه را بهبود دهد. اگرچه FCN نتايج اميدواركنندهاي براي شناسايي مناطق تحت تأثير سيل ارائه می دهد، اما قادر به شناسایی میزان سیل در مناطق تحت يوشش سايه بهصورت متراكم نيست. به همين علت

محط شاسي 174 دورهٔ ٤٧ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰

رویکرد 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 بررسیشده 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^۷ با چالش روبهرو بوده است. شبکههای تنظیم دقیق اگرچه ارائهدهندهی دقتهای تقریباً مناسبی بودهاند ولیکن به دلیل آموزش آنها با دادههای غیر سنجشازدوری که ازنظر ویژگیهای طیفی، متفاوت از دادههای سنجشازدوری هستند، از دقتهای بالا برخوردار نمی باشند. از طرفی شبکههای با آموزش از ابتدا نیز جهت جلوگیری از مسائلی همچون بیش برازش^ نیازمند نمونههای آموزشی زیاد میباشند و چون در سنجشازدور در تهیه دادههای مرتبط با مسئله موردمطالعه محدوديت وجود دارد، اين قضيه 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 تولیدشده از سیلاب را نسبت به تحقيقات گذشته بهبود داده است. اهميت تهيه سري زماني نیز به جهت ایجاد امکان بررسیهای دقیقتر درروند وارد شدن خسارات به منطقهی متأثر میباشد. از اهداف دیگر این تحقیق، طراحی یک معماری عصبی کانولوشنی جدید با آموزش از ابتدا بهطوریکه در عین داشتن تعداد لایههای محدود و حداقل نیاز به تعداد نمونههای آموزشی بتواند ویژگیهای عمیق را با سرعتبالا استخراج نماید و در کنار آن دچار بیش برازش نشود، میباشد. از چالش های دیگر استفاده از تصاویر با قدرت تفکیک مکانی بالای ۱۰ متر در شبکههای عصبی کانولوشنی با لایههای عمیق، کمبود

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 ارائهشده از ویژگیهای طیفی-مکانی بهصورت 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 ممسایگی آزمایش شده و نتایج آن با نتایج حاصل از روش های مرسوم دیگر، مقایسه گردیده است. این تحلیلهای قیاسی بهمنظور اجرای ارزیابیهای نسبی صورت گرفته و به تحقیق حاضر عمومیت میبخشند.

مواد و رو ش بررسی منطقه مورد مطالعه

منطقه موردمطالعه 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 بارش،ها در کشور آغاز گردیده و با ادامه و تشديد روند آن در استان خوزستان، سيلاب از اوايل فروردین شروعشده و تا اواسط آن روند صعودی داشته است که در این بازه زمانی شهرهایی نظیر اهواز، حمیدیه و ... را به همراه بخش وسيعي از مناطق كشاورزي تحت تأثير 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 کیلومترمربع شده است. در شکل ۱، نمای کلی از منطقه موردمطالعه قابلمشاهده است. لازم به ذکر است که ترکیب باندی کاذب مورداستفاده در شکل ۱ به ترتیب باندهای مادونقرمز کوتاه، مادونقرمز نزدیک و قرمز سنجنده لندست ۸ با نامهای NIR ،SWIR1 و Red هستند.

دادههای مورداستفاده

دادههای مورد استفاده در این تحقیق دو سری تصاویر

استخراج محدودههای سیلزده بر پایه ادغام تصاویر ... بریسا دودانگه و همکاران

> 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

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



شکل ۱. موقعیت جغرافیایی منطقه موردمطالعه در زمان سیلاب

جدول ۱. تاریخ تصاویر مورداستفاده در تحقیق

وضعيت منطقه	تاریخ اخذ (شمسی)	تاریخ اخذ (میلادی)	نوع سکو	نام سنجنده
قبل از سیل	١٣٩٨/٠ ١/٠٢	T+ 19/+7/77	Sentinel-2B	y (
بعد از سیل	١٣٩٨/٠٢/٠١	7•19/•۴/71	Sentinel-2B	سىنيىل ١
قبل از سیل	١٣٩٨/٠ ١/٠٢	۲・۱۹/・۳/۲۲	MOD09GA	
بعد از سیل	١٣٩٨/٠١/١٩	۲۰۱۹/۰۴/۰۸	MOD09GA	.1
بعد از سیل	١٣٩٨/٠ ١/٢۵	7+19/+4/14	MOD09GA	ماديس
بعد از سیل	١٣٩٨/٠٢/٠١	7.19/.4/71	MOD09GA	

روش تحقيق

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 بهمنظور پیشربینی بازتابندگی سطحی روزانه

تصاویر اجرا گشته و در صورت مناسب بودن خطا و دقت تصاویر پیشبینی شده، سری زمانی از دوره سیلاب به دست می آید. در فاز سوم، نقشه های واقعیت زمینی توسط پژوه شگر به روش تفسیر تصاویر تهیه می شوند. در فاز چهارم، از این داده ها جهت انجام طبقه بندی های مختلف نظیر رویکرده ای یادگیری عمیق و یادگیری ماشین، نمونه های آموزشی تهیه گشته و اقدام به اجرای شبکه



شکل ۲. روند نمای کلی تحقیق

پیشنهادی در ابعاد مختلف ورودی شده و در قیاس با سایر روش ها، الگوریتم های نامبرده در شکل ۲ نیز اجرا می گردد. لازم به ذکر است که تعداد نمونه های آموزشی و اعتبارسنجی در شبکه های یادگیری عمیق بسیار محدود و وابستگی به کاربر نیز رعایت گردد. در فاز پنجم برای شناسایی مناطق تحت تأثیر سیل در بخش های کشاورزی و پوشش گیاهی اقدام به تهیه نقشه های مربوطه با بهترین رویکرد آزمون شده در فاز قبل گشته و درنهایت در فاز ششم اقدام به انجام ارزیابی های دقت توسط ماتریس ابهام و معیار مرتبط با آن می گردد. در فاز هفتم میزان مساحت کاربری های تحت تأثیر سیلاب برآورد می شود. در ادامه به

شرح جزییات فازهای نامبرده شده پرداخته خواهد شد.

فاز اول) پیش پردازش تصاویر

با توجه به آنکه در این پژوهش از دو سنجنده مختلف استفاده شده است، پیش پردازش ها متفاوت خواهد بود. از آنجایی که داده های سنتینل ۲ مورداستفاده از نوع سکوی 2B هستند بنابراین نیاز به تصحیحات اتمسفری کی دارند. در خصوص تصاویر مادیس، از آنجایی که از محصولات باز تابندگی سطحی استفاده شده است بنابراین تنها تصحیحات لازم تبدیل سیستم مختصات به UTM معادل با تصاویر سنتینل و کورجیسترسازی است. استخراج محدودههای سیلزده بر پایه ادغام تصاویر ... بریسا دودانگه و همکاران

فاز دوم) تلفيق تصاوير با الكوريتم ESTARFM

مدل ESTARFM با استفاده از روند بازتاب مشاهده شده در زمان و الگوریتم اختلاط خطی طیفی، الگوریتم اصلی STARFM را بهبود میبخشد تا پیش بینی 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 بهدست آمدهاند؛ بنابراین در این تحقیق به جهت تولید دو تصویر پیش بینی در مقیاس سنتینل ۲، از ۴ تصویر مادیس و ۲ تصویر سنتینل ۲ بهره گرفته شده است. تصاویر مادیس پیش بینی، در دو تاریخ ۱۹ و ۲۵ فروردین و تصاویر زمان ۱ و ۲ الگوریتم، ۲ فروردین و ۱ اردیبه شت برای هر دو سری سنجنده در نظر گرفته شده است. بدین ترتیب سری زمانی از منطقه در ۴ تاریخ

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 طبقه بندی شده باید با داده ی 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 نقشه ها در ۴ کلاس شامل آب، پوشش گیاهی، زمین بایر و مناطق ساخته شده از روی همان سری زمانی تولید شده در مرحله قبل تولید می شوند. نقشه های واقعیت زمینی تهیه شده در شکل ۳ نمایش داده شده است.



شکل ۳. نقشههای واقعیت زمینی تهیهشده 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 سنجشازدوری استفاده میکنند، دقت بالاتری برای طبقهبندی کسب نمود. این موضوع با توجه به کمبود حجم زیادی از تصاویر سنجشازدوری و نیاز مبرم به سختافزارهای قوی همواره از چالشهای یادگیری عمیق بهحساب آمده است. در این تحقیق برای آموزش و

اعتبارسنجی شبکه طراحی شده از تعداد بسیار کمی نمونه های آموزشی ^۹ و اعتبار سنجی ^۱ استفاده و درعین حال از بیش برازش نیز جلوگیری شده است. مجموع تعداد نمونه های آموزشی برای هر تصویر تقریباً ۲۵/۰ درصد کل پیکسل های تصویر و تعداد نمونه های اعتبار سنجی نیز ۲/۰ درصد بوده است. این نمونه ها برای آموزش هر سه معماری یادگیری عمیق پیاده سازی شده به صورت یکسان استفاده شده اند.

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

محط ثناسي 194 دورهٔ ٤٢ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰

2017). روش های مختلفی برای طبقهبندی و در ادامه آن شناسایی تغییرات بر اساس مقایسه داده های سنجش ازدور دیجیتال چند طیفی در تحقیقات ارائه شده است (,Singh (1989)؛ بنابراین در این تحقیق از چندین الگوریتم مرسوم با دقت های بالا جهت بررسی دقیق تر و مقایسه جامع تر با معماری پیشنهادی استفاده شده که در ادامه به شرح آن ها پرداخته شده است.

شبکه عصبی کانولوشنی DCNN^{۱۱}

اولین مطالعه استفاده از شبکه عصبی کانولوشنی مبتنی بر پچهای 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 می باشد.



شکل ۴. معماری شبکه DCNN

این شبکه در پچ سایز ۵×۵ آزمایش گردیده و نتایج حاصل از آن با شبکه عصبی معمولی مبتنی بر پیکسل،

CNN مبتنی بر پیکسل و ماشین بردار پشتیبان مقایسه شده است. نتایج طبقهبندی نشان می دهد که سیستم پیشنهادی به پیشرفتهای قابل توجهی 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. بااین حال، به دلیل ساختار پیچیده عمیق، این شبکه برای جلوگیری از بیش برازش و محاسبات سنگین، به نمونههای آموزشی زیادی نیاز داشت.

شبکه عصبی کانولوشنی LCNN^{۱۲}

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 بهدقت بالا Song et ، بهدقت دستیابی بهدقت بالا با ورودی طیفی تصاویر لندست ۸ پیشنهاد دادند (Song et Song et ، ورودی طیفی تصاویر لندست ۸ آموزشی، توانست بدون بیش برازش، بهدقت بالایی دست آموزشی، توانست بدون بیش برازش، بهدقت بالایی دست موزشی با در می معماری هزینه محاسباتی کمی دارد، زیرا در مقایسه با CNN های معمولی که برای کارهای طبقهبندی تصویر با وضوح بالا یا فرا طیفی استفاده می شوند، از نظر طراحی بسیار سادهتر است. شکل معماری این الگوریتم مطابق شکل ۵ می باشد.

این شبکه نیز مبتنی بر پچ بوده و در دو ابعاد مختلف ۳×۳ و ۵×۵ 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.

شبكه عصبى كانولوشني پيشنهادي

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



ارتباط مکانی یک پیکسل با همسایگی آن، یک سیستم شبکه عصبی کانولوشنی مبتنی بر پچ ارائه میگردد که برای دادههای سنجشازدوری با وضوح متوسط طراحیشده 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 برچسب، 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 پچ های 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 مديريت بحران سيل است. لذا در اين پژوهش با توجه به



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

محط شاسي 198 دورهٔ ٤٧ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰

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 BatchNormalization بەكار رفتە كە دليل آن كاھش تغيير توزيع و جلوگيري از محوشدگي گراديان ميباشد. اين لايه موجب کاهش حساسیت شبکه به مقداردهی اولیه وزنها نیز میگردد. در ادامه بهمنظور تسریع در آموزش شبکه از تابع فعالساز ELU پس از هر لايه ELU 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 استفادهشده داشتند. در این پژوهش از هیچگونه لایه Dropout بهره گرفته نشده است زیرا طبق تحقیقات لایه BatchNormalization بهتنهایی میتواند از بیش برازش جلوگیری نموده و نقش یک رگیولایزر را نیز ايفا كند. در كنار لايه Dropout، از لايه ادغام يا MaxPooling نیز جهت جلوگیری از حذف ویژگیها استفادهنشده و بدین ترتیب شبکه امکان استفاده از تمامی ویژگیهای استخراجی را خواهد داشت. درنهایت 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 خودكار بهمنظور تعيين درجه تعلق هر نمونه به كلاس مشخص را دارا میباشد. این شبکه در ۱۰ ایک 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 آزمایششده در تحقیق به دست

می آید تا در مرحلهی بر آورد سطح آب گرفتگی مناطق از آنها استفاده گردد. این عمل به دلیل اهمیت بر آورد 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) بر آورد مساحت مناطق تحت تأثير سيلاب

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 موردمطالعه را محاسبه کرده و بدین ترتیب به برنامهریزی و مدیریت پس از بحران سیل اقدام نمود.

نتايج و بحث

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

ارزيابي نتايج تلفيق تصاوير

به منظور صحت سنجی تصویری که در اثر اجرای الگوریتم های تلفیقی به دست می آید، نیاز به انجام ارزیابی های دقت می باشد. این ارزیابی می تواند به صورت مختلفی انجام گیرد که در این تحقیق دو مورد از مرسوم ترین و دقیق ترین آن ها اجراشده است. لذا در این بخش ابتدا تصاویر تولیدی نمایش داده شده و سپس توسط ترسیم نمودارهای پراکندگی و محاسبه خطای RMS ارزیابی دقت صورت می گیرد. استخراج محدودههای سیلزده بر پایه ادغام تصاویر ... بریسا دودانگه و همکاران

> تصاویر تلفیقشده در شکل ۷ قسمت الف و ب نمایش داده شده اند 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 کاربرده شده در تلفیق تصاویر از روش های مختلف ارزیابی استفاده شده ولیکن این موضوع باید به صورت بصری نیز قابل رؤیت باشد. مطابق با شکل

۷، تصاویر ادغام شده در تاریخهای ۱۹ و ۲۵ فروردین ازنظر 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 ملموس تر است.



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

در ادامه بهمنظور ارزیابی دقت و اثبات کارایی الگوریتم ESTARFM در ادغام تصاویر، نمودارهای پراکندگی بهعنوان نمونه برای یک باند تصاویر ارائهشده 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

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



شکل ٨. نمودار پراکندگی مقادیر تصاویر تلفیق شده؛ الف) باند ١ تصویر ١٩ فروردین، ب) باند ١ تصویر ۲۵ فروردین.

محط ثناسي 199 دورهٔ ٤٧ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰

تراکم پیکسلهای تصویر در نمودارهای پراکندگی نشان میدهد که همبستگی زیادی بین تصاویر سنتینل ۲ و تصاویر تلفیقشده وجود دارد. اگرچه در برخی موارد خطاهایی نظیر بیش برآورد^{۳۳} و ناچیز شماری^{۱۴} نیز وجود دارد که ناشی از ۱) متفاوت بودن تاریخ تصاویر مرجع و پیشبینی و بهتبع 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

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 دادهشده است.

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
•/••78	•/••44	•/••77	٠/٠٠١٩	۰/۰۰۱۳	•/••1۵	۱۹ فروردین
۰/۰۰۱۸	•/•• ١	•/••1٣	•/••1٣	٠/٠٠٠٩	•/••١١	۲۵ فروردی <i>ن</i>

مطابق با خطای RMS برآورد شده برای باندها مختلف هر تصویر که مقدار ناچیزی بوده است، میتوان نتیجهگیریهای نمودار پراکندگی را تائید 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

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

ارزیابی نتایج شبکه پیشنهادی در ابعاد مختلف

از چشماندازهای بیانشده در این تحقیق، ارزیابی رویکرد پیشنهادی در ابعاد مختلف بوده تا در تصاویر و شرایط محیطی مختلف، بهترین پچ سایز ورودی شناسایی گردد. همچنین بدینصورت 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.

11×11	٩×٩	٧×٧	۵×۵	۳×۳	ابعاد پچ تاريخ تصوير				
V1/20	۷۱/۶۱	VY/YA	۷۱/۸۲	۷۱/۱۹	۲ فروردین				
۷۵/۰۳	V۴/۱۵	۷۳/۷۱	۷۳/۳۰	V7/94	۱۹ فروردین				
٧٧/٣٩	۲۲/۶۰	٧۶/۵۰	۷۵/۹۱	<u>۷۴/۳۰</u>	۲۵ فروردین				
V///	۲ ٩/۱۷	YN/8V	۷۷/۴۲	۷۵/۸۱	۱ اردیبهشت				

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

نتایج جدول ۳ بهصورت 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، پچ سایزهای ۹ و ۱۱ از دقتهای بالاتری برخوردار بودهاند. این امر در درجه اول نشانگر کاهش خطاها در ابعاد بالاتر همسایگی نسبت به پچ سایزهای 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 پچ سایز تصویر قبل سیل با تصاویر پس از سیل را میتوان شرایط محیطی تصویر عنوان نمود زیرا مساحت کاربری نظیر آب

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، پچ سایزهای ۹ و ۱۱ دقت بالایی دارند و اختلاف آنها ناچیز میباشد؛ بنابراین میتوان تعمیمپذیری این پچ سایز را در دوران سیلاب نیز اثبات نمود. در جدول ۴، معیار ضریب کاپای هر تصویر در ابعاد گوناگون ارائه و بررسیشده است. نتایج حاصل شده از جدول ۴ نیز مشابه با جدول ۳ بوده و تکمیل کننده این

استخراج محدودههای سیلزده بر پایه ادغام تصاویر ...

یریسا دودانگه و همکا*ز*ان

197

جدول ۴. ضریب کاپا (درصد) شبکه پیشنهادی در پچ سایزهای مختلف

11×11	૧×૧	٧×٧	۵×۵	۳×۳	ابعاد پچ تاريخ تصوير
۵۲/۷۹	۵۱/۱۰	۵۳/۳۵	57/74	51/44	۲ فروردین
۶١/٧٩	80/38	۵٩/۴۵	۵٩/۰۶	۵۷/۷۱	۱۹ فروردین
۶۷/۲۰	۶۷/۱۸	۶۵/۹۸	SF/98	૬૧/૧૧	۲۵ فروردین
९९/४७	۶ ٩/۷۱	۶٩/١٣	97/79	۶۴/۰۵	۱ اردیبهشت

ارزیابی نسبی شبکه پیشنهادی با رویکردهای یادگیری ماشین

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

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

	ضریب کاپا (درصد)			معيار ارزيابي		
Pixel_based SVM	Object_based SVM	شبکه پیشنهادی	Pixel_based SVM	Object_based SVM	شبک <i>ه</i> پیشنهادی	روش تاريخ تصوير
44/14	48/80	۵۳/۳۵	۶۷/۴۸	<i>۶</i> ٧/٧٩	VY/VA	۲ فروردین
۵۲/۳۴	۵۵/۵۱	۶١/٧٩	۶۸/۹۱	۶٩/٨۵	۷۵/۰۳	۱۹ فروردین
۵۲/۹۲	۶١/٠۶	۶۷/۱۸	۶۷/۸۵	۲۳/۱۵	۷۷/۶۰	۲۵ فروردین
۵۷/۵۲	१९/९۶	<i>୨</i> ୧/۲۱	۷۱/۱۰	۲۵/۶۰	۲۹/۱۲	۱ اردیبهشت

جدول ۵. ارزیابی نسبی شبکه پیشنهادی با رویکردهای یادگیری ماشین

محط ثناسي 197 دورهٔ ٤٧ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰

عصبی پیشنهادی نمایش دادهشده بلکه برتری روشهای

مبتنی بر پچ و قطعه در مقایسه با پیکسل مبنا نیز اثبات

گردیده است. در بخش بعدی به ارزیابی شبکه پیشنهادی

در بهترین حالت با شبکههای عصبی کانولوشنی نامبرده

شده در بخش روش ها پرداخته خواهد شد.

مطابق با جدول فوق، ابتدا رویکرد پیشنهادی در تمامی ارزیابی نسبی شبکه پیشنهادی با رویکردهای تصاویر دارای دقت بالا بوده و پسازآن رویکرد SVM یادگیری عمیق مبتنی بر شی دقت بهتری را نسبت به SVM مبتنی بر در جدول ^۶، ارزیابی نسبی میان رویکرد پیشنهادی با DCNN و LCNN عصبی کانولوشنی نظیر LCNN و

شبکههای عصبی کانولوشنی نظیر LCNN و DCNN و DCNN صورت گرفته است. این دو شبکه یادگیری عمیق در تحقیق حاضر، در دو بعد ۳×۳ و ۵×۵ آزمایش گردیدهاند زیرا در پژوهش مربوط به LCNN، نویسندگان نیز آزمایشهای خود را بر روی این دو پچ سایز انجام دادند و در پژوهش مربوط به DCNN، آزمایشات بر روی پچ سایز ۵ صورت گرفته است.

کاپا (درصد)					دقت کلی (درصد)				معيار	
DCNN 5×5	DCNN 3×3	LCNN 5×5	LCNN 3×3	شبکه پیشنهادی	DCNN 5×5	DCNN 3×3	LCNN 5×5	LCNN 3×3	شبکه پیشنهادی	روش تاريخ تصوير
۵۱/۷۸	41/99	۴٩/٨٧	۵۰/۱۱	۵۳/۳۵	٧١/۴١	F9/WV	٧٠/٠٩	٧٠/٧۵	VY/VA	۲ فروردین
۵۷/۹۳	۵۸/۲۷	۵۶/۰۷	۵۷/۰۶	<i></i> ୨۱/γ۹	VT/10	VT/TT	V1/84	V1/VT	۷۵/۰۳	۱۹ فروردین
۶١/۰۰	۶۰/۰۴	۵۵/۴۸	۶۰/۵۵	۶Y/۱۸	VT/27	٧٢/١٠	89/71	۷۲/۳۸	۷۷/۶۰	۲۵ فروردین
88/23	88/88	84/88	<i>୨</i> ۵/۹۵	۶۹/Y۱	٧۶/٨١	V۴/۳۵	۷۵/۰۴	Y8/Y1	V9/1V	۱ اردیبهشت

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

همانگونه که مشاهده می شود، 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 شرایط مختلفی هستند، نشانگر عمومیت شبکه در کسب دقتهای بالا می باشد. همچنین طبق پژوهش Song و همکارانش (Song et al. 2019)، شبکه NRN در پچ سایز ۳ دقت بالاتری را در تمامی موارد نسبت به پچ سایز ۵ کسب نموده است.

ارزیابی زمانی رویکردهای اجرایی

تا بدین مرحله ارزیابی های دقت توسط دو پارامتر دقت

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 می رساند. حال یکی از مهم ترین نکات در عملکرد الگوریتم های مختلف، زمان اجرای آنها می باشد که این مسئله در زمینه های نظیر مدیریت بحران از اهمیت بسیار بالای بر خوردار است؛ بنابراین شبکه طراحی شده باید علاوه بر اخذ دقتهای بالا در سریع ترین زمان ممکن پاسخگوی نیاز پژوه شگران باشد. در این بخش اقدام به ارزیابی زمانی تمامی رویکردهای اجراشده در جدول ۷ گشته است.

جدول ۲. ارزیابی زمانی								
تعداد اپک	زمان هر اپک	نام شبکه						
	(ثانیه)							
١٠	٢	شبکه پیشنهادی ۳×۳						
١٠	۲	شبکه پیشنهادی ۵×۵						
١٠	۶	شبکه پیشنهادی ۷×۷						
١٠	١٠	شبکه پیشنهادی ۹×۹						
١٠	71	شبکه پیشنهادی ۱۱×۱۱						
١٠))	LCNN 3×3						
١٠	11	LCNN 5×5						
٣.	۱۸	DCNN 3×3						
٣.	٩٣	DCNN 5×5						

بهصورت 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 ایک و شبکه LCNN در ۱۰ ایک اجرا گردیدهاند. شبکه طراحی شده نیز در ۱۰ ایک بهترین نتایج را ازنظر زمانی و دقت دارد. بر اساس یک دیدگاه جامع در تحقیق حاضر در تمامی تصاویر پچ سایزهای بالاتر از ۵ دقتهای بهتری نسبت به دو شبکه LCNN و DCNN در پچ سایز ۳ و ۵ داشتهاند. ازنظر زمانی، شبکه DCNN با توجه به داشتن تعداد ایک بالا، دارای محاسبات سنگینی بوده که کارا نمیباشد اما در مقایسه با شبکه LCNN پچ سایز ۱۱ رویکرد پیشنهادی کمی زمان بیشتری میبرد. لکن طبق بررسیهای انجام شده دقت یچ سایز ۹ و ۱۱ در تمامی موارد بسیار مشابه بوده و اختلاف قابل|غماضي دارند. بدين ترتيب درصورتيكه تنها دقت مدنظر باشد شبکه پیشنهادی با پچ سایز ۱۱ توصیه شده و درصورتی که زمان مدنظر قرار گیرد، پچ سایز ۵ و ۷ توصيه میگردد. وليکن در صورتی که هر دو پارامتر مورد توجه باشد، شبکه پیشنهادی با ابعاد ۹ دارای بهترین نتیجه می باشد که زمانی کمتر از هر دو شبکه LCNN و LCNN

استخراج محدودههای سیلزده بر پایه ادغام تصاویر ...

199

پریسا دودانگه و همکا*ز*ان

نیاز دار**د**.

ارزیابی نسبی بهینه ترین 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 انجامگرفته است؛ یعنی برای مثال در هر تاریخ، بین SVM پیکسل مبنا و شیء مبنا، بین LCNN با ابعاد ۳×۳ و ۵×۵ و بین DCNN با ابعاد ۳×۳ و ۵×۵ یکی دارای دقت بیشتر بوده و آن وارد ارزیابی این مرحله گردیده است. این عمل به جهت بررسیهای راحت تر و عدم ایجاد پیچیدگی به دلیل زیاد بودن تعداد نتایج انجامگرفته است. نتایج این بخش در جدول ۸ قابل مشاهده می باشد.

طبق توضيحات ارائهشده در بخشهاي قبل، هدف نهایی این تحقیق، تولید نقشه مناطق مختلف تحت تأثیر سیل با دقت و سرعت مناسب بهصورت سری زمانی بوده است؛ بنابراین در این راستا دقت هریک از کلاسهای تعیینشده 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 درنتیجه آن خطای بالایی می باشد که این موضوع روند محاسبات را دچار مشکل اساسی میکند. این در حالی است که در رویکرد پیشنهادی نهتنها دقت كلاس شهر بالا بوده بلكه ساير كلاسها نيز داراى دقت مناسبی برای شناسایی میباشند. در تمامی تصاویر بررسیشدہ میتوان بہتناسب دقت کلاس،ا خصوصاً دقت کاربر در مناطی ساختهشده اشاره نمود. در رویکرد ییشنهادی ضمن حفظ دقت در کلاسی مانند آب، دقت سایر کلاس ها نیز از تناسب خوبی برخوردار بوده است که گام نهایی را ممکنتر میسازد.

محط ثناس ۲., دورهٔ ٤٧ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰

	بر (درصد)	دقت کار		(.	ننده (درصد	ت توليد ک	ës -	معيار	
پوشش گياهى	مناطق ساختەشدە	زمين باير	پهندهای آبی	پوشش گیاهی	مناطق ساختەشدە	زمين باير	پهندهای آبی	كلاس روش	تاريخ تصوير
۷۳/۴۸	۶١/٠٧	V4/72	<i>۶</i> ٧/١٩	۸۱/۶۲	۵۱/۵۱	۶۵/۷۰	88/V8	رویکرد پیشنهادی ۷×۷	
V ঀ/ঀ۳	۳۸/۱۸	۶۲/۱۳	۵٩/۵۴	84/21	 ૿૾૾૾૾૾૾	V8/4N	82/28	Object_based SVM	., .
۷۷/۹۳	FF/TF	۶۴/۰۱	۷۴ /۹۱	۷۱/۰۳	47/10	४४/•९	۵۵/۹۳	LCNN 3×3	• \/• \
٧۶/٠٢	47/21	۶۹/۹V	88/VI	V8/V8	۵۰/۶۶	۶۸/۸۳	۶۵/۰۲	DCNN 5×5	
४४/९०	۵۲/۹۵	V4/40	٧٨/٧۴	۸۱/۴۴	۵۷/۱۷	۶۸/۰۶	٨۴/۴۰	رویکرد پیشنهادی ۱۱×۱۱	
۸۲/۳۳	۳۰/۰۵	۶۴/۸۲	۸۳/۵۵	<i>۶۶</i> /۹۵	۵۲/۵۷	VT/17	۸۱/۳۰	Object_based SVM	2/20
V7/4V	۳۵/۱۵	۸۱/۷۵	V٩/١٠	۸۵/۲۳	22/44	54/SV	۷۸/۰۴	LCNN 3×3	• 1/ 17
۷۷/۴۸	46/44	V1/24	۷۰/۶۵	V۴/۵۹	۵۰/۶۶	87/08	10/11	DCNN 3×3	
۷۳/۵۲	۵٩/۳۸	VT/TA	૧ ۵/۶۹	۷٩/۰۶	۵۴/۵۸	۷۷/۰۰	٨٠/٢٧	رویکرد پیشنهادی ۹×۹	
۷۱/۲۰	41/98	80/18	٩۶/٧٣	٧١/٩۵	۳۳/۸۹	۷۸/۴۲	۷۷/۱۵	Object_based SVM	. / .
۷۰/۳۶	۳۰/۹۶	۲۴/۹۱	९४/२९	۸۱/۳۸	<u> </u>	88/VD	۶۸/۷۵	LCNN 3×3	+ 1/10
٧١/٣٠	78/73	YA/2Y	٩٨/٠٢	٨٢/٧۴	F4/F4	۶ ٣/٩٨	۶٩/۵۰	DCNN 5×5	
۷۱/۱۶	۲ ۱/۹۱	۷۸/۴۱	૧ ۵/૧۶	٨۴/٣٩	۵۷/۱۸	٧۴/٠٨	۸۲/۲۴	رویکرد پیشنهادی ۹×۹	
٧٣/٨۵	۵۲/۹۱	<i>۶۶</i> /۱۲	٩٧/۴٢	88/4M	41/18	۸۳/۰۲	۸۵/۱۷	Object_based SVM	.
88/Dr	80/38	۸۱/۱۸	٨٧/٩٧	٨٩/٢۶	۵۰/۱۷	۶۵/۴۸	YY /Y1	LCNN 3×3	• \/• \
F9/VA	۴۸/۱۰	νν/۵١	٩٨/٣٠	٨٢/۴٩	21/25	۷۲/۰۶	۷۸/۳۳	DCNN 5×5	

جدول ۸. دقتهای کاربر و تولید کننده تصاویر

بوده است و پسازآن روند کاهش آبگرفتگی مشاهده میگردد، لذا جهت برآورد مساحت آسیبدیدگی منطقه از دو تصویر ۲۵ فروردین و ۲ اردیبهشت بهره گرفتهشده 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 می توان 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 تائید این موضوع، نتایج حاصل از ارزیابی دقت نقشههای طبقهبندی شکل ۹ در جدول ۹ ارائه شده که محاسبه مساحت آب گرفتگی در مناطق مختلف 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



شکل۹. نقشههای پوشش گیاهی؛ الف) نقشه طبقهبندی ۲۵ فروردین، ب) نقشه واقعیت زمینی، ج) راهنمای نقشه.

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

در نهایت در جدول ۱۰ میزان آبگرفتگی در کاربریهای مختلف منطقه موردمطالعه در سطح پیکسل و در ۴ کاربری اصلی ارائهشده است.

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

جدول ۹. ارزیابی دقت نقشههای پوشش گیاهی							
ضریب کاپا	دقت کلی	معيار					
(درصد)	(درصد)		نقشه				
۵٩/۰۰	۸۱/۳۷	۲ فروردین	,				
۵۷/۰۰	۸۱/۹۱	۲ فروردین	۵				
87/	٨٢/٨٠	ارديبهشت	١				

	_				
فتگی (هکتار)	مساحت أبگر	تعداد پيكسل			
۱ اردیبهشت	۲۵ فروردین	۱ اردیبهشت	۲۵ فروردین	۲ فروردین	تصویر کاربری
۶,۶۱۷	V,7757	٧١١,١٠٢	597,470	۸۷۶,۵۱۷	مناطق ساختەشدە
78,718	41,501	7,1,.07	1,778,887	7,797,998	اراضي ديم و آيش
۵۲,۴۰۸	۳۸,۳۲۲	٣,۶١۶,٧٢٣	٣,٩۶٨,٨٨٠	4,979,977	کشت آبی
۵,۱۷۳	4,.95	۱۰۰٫۸۳۳	١٢٧,٧۵٩	73.,149	تالاب

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 روش های موجود و همچنین افزایش دقت نقشههای نهایی با توجه به چالشبرانگیز بودن آن از اهداف این تحقیق بوده است. در

ادامه، نمودارهایی به جهت بررسی دقیقتر روشهای پیادهسازیشده 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 استخراجشده، در رویکرد پیشنهادی، کاربری مناطق ساخته شده از شناسایی بسیار بالایی در مقایسه با الگوریتمهای

محط ثناسي 4.4 دورهٔ ٤٢ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰

شبکه عصبی پیشنهادی، با افزایش ابعاد در تصاویر پس از سیل، خطای شناسایی کاهشیافته که بهینهترین حالت آن با توجه بهدقت و زمان اجرا، پچ سایز ۹ معرفی شده است. دیگر بهرهمند بوده و تناسب دیگر کاربریها بهخصوص کاربری پهنههای 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 آب گرفتگی در مناطق مختلف

نتيجه گيري

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 درنتیجه ایجاد خلل در تصاویر اپتیکی میباشد. یکی از راهحلهای موجود در مواجه با این مسئله استفاده از دادههای چند منبعی و تکنیکهای تلفیق تصاویر میباشد. در این تحقیق از الگوریتم ادغام تصاویر میباشد. در مناسب تلفیق تصاویر در مناطق ناهمگن مطابق با بررسیهای انجامگرفته، بیشترین میزان آبگرفتگی در منطقه موردمطالعه در هفته چهارم فروردین بوده و پسازآن 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، آبگرفتگی از تاریخ ۲۵ فروردین تا ۱ اردیبهشت در مناطق ساخته شده و اراضی دیم و آیش کاهش و در مناطق کشت آبی و تالاب با افزایش روبهرو بوده است. استخراج محدودههای سیلزده بر پایه ادغام تصاویر ...

۲.٣

پریسا دودانگه و همکا*ر*ان

نقشه با سرعتبالا، رویکرد پیشنهادی پاسخ مناسبی را ارائه نموده است. درصورتی که در اجرای تحقیق، زمان و دقت بهطور متناسب مدنظر باشد، شبکه طراحی شده در ابعاد ورودی ۹×۹ پیشنهاد می گردد زیرا در این صورت هم برتری دقت و هم زمان در مقایسه با الگوریتمهای مقایسهای ایجاد می شود. به منظور بر آورد مساحت آبگرفتگی منطقه نیز نقشههای یوشش گیاهی بهصورت جداگانه با رویکرد پیشنهادی در ۳ کلاس شامل اراضی زراعت آبی، اراضی دیم و آیش و تالابها تهیهشده و درمجموع بررسی تغییرات در ۴ کلاس مناطق ساختهشده، اراضی دیم و آیش، اراضی زراعت آبی و تالابها انجامشده است. نتایج بهصورت کلی بیانگر بهبود دقت و سرعت تهیه نقشه در مقابل سایر رویکردهای مقایسهای مى باشد كه امكان اجرايي ساختن هدف تهيه نقشه مناطق تحت تأثیر سیلاب در کاربریهای مهمی نظیر منطقه نیمهشهری را با سرعتبالا و بدون نیاز به نقشههای خاص و تنها با تصاویر سنجشازدوری فراهم می آورد.

یادداشت ها

- 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 ارزیابی ها به کمک نمودارهای پراکندگی و خطای كمترين مربعات صورت گرفته است. نتايج بيانگر كارايي روش در ادغام تصاویر سنتینل ۲ با وضوح نسبتاً بالا و تصاویر مادیس با وضوح پایین در کاربرد سیل بوده است. درزمینهی شناسایی محدودههای سیلزده و در ادامه به دلیل ساختار ضعيف تصاوير با مقياس بالاي ١٠ متر، امكان استخراج ویژگیهای بهینه و عمیق با مشکل روبهروست. در تحقیق حاضر شبکه عصبی کانولوشنی مبتنی بر پچ تصویری بهصورت سلسله مراتبی با حداقل لایه و فرا یارامتر 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 پچ سایزهای ۳ تا ۱۱ آزمایش شدند که در تصویر قبل از سیل یچهای ۵ و ۷ و در تصاویر بعد از سیل، یچهای ۹ و ۱۱ بهترینها بودهاند. دقت کلی نقشههای کاربری اراضی برای تصویر قبل از سیل، ۷۲/۷۸ و برای تصاویر بعد از سیل به ترتيب ۷۵/۰۳، ۷۷/۶۰ و ۷۹/۱۷ بوده که اين نتايج با رویکردهایی نظیر SVM مبتنی بر شی و پیکسل، شبکه عصبي LCNN و DCNN با ابعاد ٣×٣ و ٥×٥ مطابق تحقيق 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 یچ ۳×۳ و ۵×۵ و بیشترین آن مربوط به شبکه DCNN با ابعاد ۵×۵ 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

محیط شناسی دورهٔ ٤۷ ♦ شمارهٔ ۲ ♦ تابستان ۱٤۰۰ ۲-٤

- 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 SentineI-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
- Mohammadizadeh, 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