

## Research Paper



## Prediction of underground water potential in the Khorramabad plain based on convolutional neural networks



Sayyad Asghari Saraskanroud<sup>1</sup>, Maryam Riahinia<sup>2</sup>



This paper is an open access and licenced under the CC BY NC licence.



DOI:10.22034/hyd.2023.56400.1691

**Reference to this article:** Sayyad Asghari Saraskanroud, Maryam Riahinia. (2024). Prediction of underground water potential in the Khorramabad plain based on convolutional neural networks. *Hydrogeomorphology*, 11(38): 1-18.

### Keywords

Zoning, Neural Network, Underground Water, Khorramabad Plain

Receive Date: 2023/05/01

Accept Date: 2023/09/17

Available: 2024/04/18

### ABSTRACT

Today, due to population increase, industrial development, excessive exploitation, droughts, exploitation of underground water has multiplied. Therefore, identifying areas with underground water as one of the important sources for providing drinking water, agriculture, and various industries is considered to be one of the important and necessary issues in water resources management. The purpose of this research is to investigate and zonate the areas with underground water in Khorram Abad plain located in Lorestan province using convolutional neural network method. For this purpose, maps of nine factors affecting underground water were first prepared in the ArcGist environment. In the convolution method, the number of samples was determined as the ratio between the training set and the test set was 70:30, and the convolution neural network framework was used as 2 convolution layers and 2 integration layers, 2 complete connections. layers and finally the sigmoid layer was used for classification from the 3-3 convolution kernel, the Relu function as the activation function and the cross entropy function as the loss function. The obtained maps were classified into 5 classes: very good, good, average, low and very low. Confusion matrix was also used to validate the results of the model. 30% of the real data was used for evaluation, which resulted in an overall accuracy of 92%, that is, the model was able to correctly identify 92% of the data as underground water and 93% as the absence of underground water. The analysis of the groundwater potential map of the convolutional neural network model shows that about 57% of the area is in low groundwater conditions and 43% of the area is in good groundwater conditions.

\* Corresponding Author: Sayyad Asghari Saraskanroud

E-mail: s.asghari@uma.ac.ir

1. Professor, Department of Physical Geography, Faculty of Social Science, University of Mohaghegh Ardabili, Ardabil, Iran.

2 MSc. of Remote Sensing and GIS, University of Mohaghegh Ardabili, Ardabil, Iran.

## Extended Abstract

### Introduction

Groundwater is the largest source of fresh water on Earth. Since surface water resources are limited in many regions of the country, the use of underground water has increased due to factors such as high availability, excellent quality, low development cost, and limited vulnerability. Therefore, the management of water resources is inevitable in water-scarce countries, including Iran. Iran is a dry and semi-arid land with very little rainfall so that its average annual rainfall is less than a third of the world's average annual rainfall. This country, about 65% of which is supplied from underground water, is facing difficult conditions in terms of water supply. In such a situation, the estimation of groundwater potential in an area will help people to have a general understanding of local water resources and can guide them when making decisions about site selection, urban planning, environmental protection, etc.

### Methodology

In this research, a new method is presented for the classification of targets in satellite images using convolutional neural network (CNN) deep learning and remote sensing approaches. Moreover, one of the latest machine learning methods is used to identify prone areas in the Khorramabad Plain for the first time.

### Results and Discussion

In this research, the number of samples was determined as a ratio between the training set and the test set of 70:30, and the CNN framework was used as 2 convolution layers, 2 integration layers, and 2 complete connection layers. Finally, the sigmoid layer was used for the classification of the 33 convolution kernel, the Relu function as the activation function, and the cross entropy function as the loss function. After calculating the accuracy of each step, BATCH\_SIZE was set to 100, Epochs to 400, and the learning rate to 0.0001. The input data were the actual groundwater data in the area and its equivalent data. Groundwater simulation data matched the groundwater remote sensing assessment results. It was also a process of labeling and creating a sample dataset, that is, the actual or equivalent groundwater distribution level was used to match the amount of areas with groundwater potential assessed by remote sensing. So far, data of 1000 wells have been used as the sample set data of this research area to train the CNN model of underground water distribution. After calculations, the accuracy of the model was finally found to be 92%; the closer to 1, the better it will be, and the model loss was reduced to 0.3113 (the closer to 0, the better it is). Thus, it is a better classification model for assessing groundwater potential water resources obtained in the Khorramabad plain.

### Conclusions

The training results of the model classified the region into five levels. After 400 training and testing cycles, the accuracy of the model was 92%, and the loss of the model was reduced to 0.3113. The analysis of the underground water potential map of the CNN model shows that about 22.27% and 31.47% of the area are in very low and low groundwater conditions, respectively. About 27% of the area is in average underground water conditions, and 19.25% of the area is in good and very good underground water conditions. In this research, the share of groundwater-prone areas in the CNN is 46.25% of the entire study area, most of which are in the south, east, and northwest of the region and a small part of the west and center. The evaluation of the results obtained from the above method using the confusion matrix shows that the overall accuracy of the neural network method is 92% and its overall accuracy is 93%.

## مقاله پژوهشی



## ارزیابی پتانسیل آب زیرزمینی در دشت خرم‌آباد براساس شبکه‌های عصبی کانولوشن



دکتر صیاد اصغری<sup>۱</sup>، مریم ریاحی نیا<sup>۲</sup>



این مقاله به صورت دسترسی باز و با لایسنس CC BY NC کرییتیو کامنز قابل استفاده است.



ارجاع به این مقاله: دکتر صیاد اصغری، مریم ریاحی نیا (۱۴۰۲). ارزیابی پتانسیل آب زیرزمینی در دشت خرم‌آباد براساس شبکه‌های عصبی کانولوشن. هیدروژئومورفولوژی، ۱۰ (۳۸): 18 – 1.

DOI:10.22034/hyd.2023.56400.1691



## کلیدواژه‌ها

پهنه‌بندی، شبکه عصبی، آب زیرزمینی، دشت خرم‌آباد

## چکیده

امروزه به دلیل افزایش جمعیت، توسعه صنعتی، بهره‌برداری بی‌رویه، خشکسالی‌ها بهره‌برداری از آب‌های زیرزمینی چندین برابر شده است. بنابراین تشخیص مناطق دارای آب زیرزمینی به‌عنوان یکی از منابع مهم برای تأمین آب آشامیدنی، کشاورزی، صنایع مختلف به‌خصوص از موارد مهم و ضروری در مدیریت منابع آب محسوب می‌شود. هدف از انجام این پژوهش، بررسی و پهنه‌بندی مناطق دارای آب زیرزمینی در دشت خرم‌آباد واقع در استان لرستان با استفاده از روش شبکه عصبی کانولوشن است. بدین منظور ابتدا از طریق بازدیدهای میدانی، نقشه‌های زمین‌شناسی و توپوگرافی و با مرور منابع قبلی و بررسی شرایط منطقه، نه عامل طبقات ارتفاعی، شیب، جهت شیب، فاصله از گسل، فاصله از رودخانه، بارش، لیتولوژی و کاربری‌اراضی، خاک به‌عنوان عوامل مؤثر بررسی و انتخاب شدند و نقشه آن‌ها در محیط ArcGIS تهیه شدند. در روش کانولوشن تعداد نمونه‌ها به‌عنوان نسبت بین مجموعه آموزشی و مجموعه آزمایشی ۳۰:۷۰ تعیین شد و چارچوب شبکه عصبی کانولوشن به‌عنوان ۲ لایه کانولوشن و ۲ لایه ادغام، ۲ اتصال کامل استفاده شد. لایه‌ها و در نهایت لایه sigmoid برای در طبقه‌بندی از هسته کانولوشن ۳، ۳، تابع Relu به‌عنوان تابع فعال‌سازی و تابع آنتروپی متقاطع به‌عنوان تابع زیان استفاده شد. نقشه‌های به‌دست آمده در ۵ کلاس طبقه‌بندی شد. هم‌چنین برای اعتبارسنجی نتایج مدل از ماتریس کانفیوزن استفاده شد. ۳۰ درصد از داده‌های واقعی برای ارزیابی استفاده شد که منجر به دقت کلی ۹۲ درصد شد، یعنی مدل توانسته ۹۲ درصد داده‌ها را آب زیرزمینی و ۹۳ درصد عدم آب زیرزمینی رو به‌درستی تشخیص دهد. تجزیه و تحلیل نقشه پتانسیل آب زیرزمینی مدل شبکه عصبی کانولوشن نشان می‌دهد که حدود ۵۷ درصد منطقه در شرایط کم آب زیرزمینی و ۴۳ درصد منطقه در شرایط خوب آب زیرزمینی قرار دارد.

تاریخ دریافت: ۱۴۰۲/۰۲/۱۱

تاریخ پذیرش: ۱۴۰۲/۰۶/۲۶

تاریخ انتشار: ۱۴۰۳/۰۱/۲۹

\* نویسنده مسئول: صیاد اصغری سراسکانرود

ایمانامه: S.asghari@uma.ac.ir

۱- استاد گروه جغرافیای طبیعی، دانشکده علوم اجتماعی، دانشگاه محقق اردبیلی، اردبیل، ایران.

۲- کارشناسی ارشد سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه محقق اردبیلی، اردبیل، ایران.

## مقدمه

آب‌های زیرزمینی ۴ درصد از مجموعه آب‌هایی را که فعالانه در سیکل هیدرولوژی دخالت دارند، شامل می‌شوند (علیزاده، ۱۳۸۸: ۲۴). این منابع بعد از یخچال‌ها و پهنه‌های یخی، بزرگترین ذخیره آب شیرین به حساب می‌آیند (صداقت، ۱۳۸۷: ۷). کشور ایران با شرایط اقلیمی خشک و نیمه‌خشک و میانگین بارش سالانه حدود ۲۵۰ میلی‌متر یکی از کم‌آب‌ترین کشورهای جهان محسوب می‌شود (مسعودیان و کاویانی، ۱۳۸۶: ۸۲) و با مشخصات هیدرولوژیکی مانند حجم نزولات جوی ۴۱۳، تبخیر و تعرق ۲۹۶ و حجم آب قابل دسترس ۱۱۷ میلیارد مترمکعب، سرانه آب تجدید شونده جهانی ۱۹۰۰ مترمکعب، مصرف ۳/۴ میلیارد مترمکعب که حدود ۶۵ درصد آن از آب‌های زیرزمینی تأمین می‌گردد، با شرایط سخت در زمینه تأمین آب رو به‌روست (سازمان مدیریت و برنامه‌ریزی، ۱۳۸۳). این شرایط اقلیمی به‌گونه‌ای است که حتی در پرباران‌ترین دشت‌های آن نیاز به آب زیرزمینی احساس می‌شود و هرساله بر تعداد چاه‌های عمیق و نیمه‌عمیق در آن‌ها افزوده می‌شود. این مساله موجب افت سطح آب زیرزمینی در بسیاری از دشت‌های کشور گردیده است. بنابراین، بررسی وضعیت منابع آب زیرزمینی و تعیین عوامل اثرگذار بر آن‌ها از اهمیت شایانی برخوردار است (خلفی و اسدیان، ۱۳۸۹: ۴). درچنین شرایطی برآورد پتانسیل آب زیرزمینی در یک منطقه به مردم کمک خواهد کرد که درک عمومی از منابع آب محلی داشته باشند و می‌تواند هنگام تصمیم‌گیری در مورد انتخاب سایت، برنامه‌ریزی شهری، حفاظت از محیط زیست و غیره، آن‌ها را راهنمایی کند (دنگ و همکاران<sup>۱</sup>، ۲۰۱۶: ۴). مرور مطالعات صورت گرفته در زمینه پتانسیل‌یابی منابع آب زیرزمینی نشان می‌دهد که این موضوع در سال‌های اخیر همواره مورد توجه پژوهشگران بوده است. فلاح و همکاران (۲۰۱۷: ۸۹) پتانسیل آب زیرزمینی در محدوده مطالعاتی خرم‌آباد لرستان را با روش شاخص آماری بررسی کردند و در نهایت برای تعیین صحت نقشه نهایی از منحنی ROC استفاده کردند. دقت نقشه نهایی ۸۲ درصد شد و در نتیجه این مدل را مناسب منطقه معرفی کردند. عرب امیری (۲۰۱۷: ۲۵) پتانسیل آب زیرزمینی حوضه نجف‌آباد را با استفاده از مدل‌های شواهد قطعی، شاخص آنتروپی، مدل ترکیبی این دو روش بررسی کردند و اعتبارسنجی نتایج را با استفاده از مساحت AUC و شاخص سطح سلول هسته‌ای انجام دادند. نوحانی و همکاران (۲۰۱۸: ۱۱۹) پتانسیل آب زیرزمینی دشت الشتر را با روش نسبت فراوانی انجام دادند که این مدل برای منطقه دارای صحت ۸۵ درصد و مناسب منطقه بود. علاوه بر این شفیع و همکاران (۲۰۱۹: ۲۹۱) با استفاده از نه متغیر مؤثر، پتانسیل آب زیرزمینی را با استفاده از روش آنتروپی شانون در نورآباد ممسنی بررسی و با استفاده از منحنی راک این مدل را برای این منطقه مناسب ارزیابی کردند. در ادامه یونسی و همکاران (۲۰۲۰: ۳۶) پتانسیل‌یابی منابع آب‌های زیرزمینی را در محدوده نجف‌آباد اصفهان با استفاده از مدل شاخص آماری و وزن شواهد مورد بررسی قرار دادند و از ۱۰ متغیر مؤثر برای رسیدن به نقشه نهایی استفاده کردند. در این مطالعه دقت مدل شاخص آماری بالاتر بود و در نتیجه مناسب منطقه بود. کایو ژو و همکاران<sup>۲</sup> (۲۰۲۳: ۱) ما از داده‌های ماهواره‌ای بازتابی جاذبه و آزمایش آب و هوا (GRACE) و همچنین مجموعه داده‌های HydroSHEDS برای تعیین کمیت تغییرات GWS در چین از سال ۲۰۰۳ تا ۲۰۲۰ در مقیاس‌های چندگانه استفاده کردیم. دریافتیم که GWS با نرخ -۲۰۰۹ میلی‌متر بر ثانیه در چین کاهش می‌یابد. سه منطقه داغ با کاهش چشمگیر GWS، واقع در شمال غربی، جنوب‌غربی و شمال چین، ۵۲.۵٪ از کل کاهش GWS در چین را به‌خود اختصاص دادند و کاهش GWS در این مناطق عمدتاً ناشی از فعالیت‌های انسانی بود. کایهمایونی و همکاران (۲۰۲۳: ۲): مآثرات تغییر اقلیم بر سطح آب زیرزمینی آبخوان مهم دهگلان در شمال غرب ایران را بررسی کردیم. تکنیک‌های محاسباتی نرم همراه با پیش‌بینی‌های اقلیمی در سه مرحله روش‌شناختی برای تخمین افت سطح آب زیرزمینی تا سال ۲۰۴۵ مورد استفاده قرار گرفتند. ابتدا MODFLOW بعد رگرسیون بردار پشتیبان (SVR) و مدل‌های یادگیری ماشینی SVR حداقل مربعات (LSSVR) برای پیش‌بینی سطوح آب‌های زیرزمینی برای دوره ۲۰ ساله آینده (۲۰۲۶-۲۰۴۵) استفاده شد. سناریوی محاسباتی شامل سطح آب زیرزمینی ماه قبل، برداشت ماهانه آبخوان و بارش ماهانه بالاترین عملکرد را در پیش‌بینی سطح آب زیرزمینی با ریشه میانگین مربعات خطا (RMSE)، میانگین درصد مطلق خطا (MAPE) و راندمان نش ساتکلیف

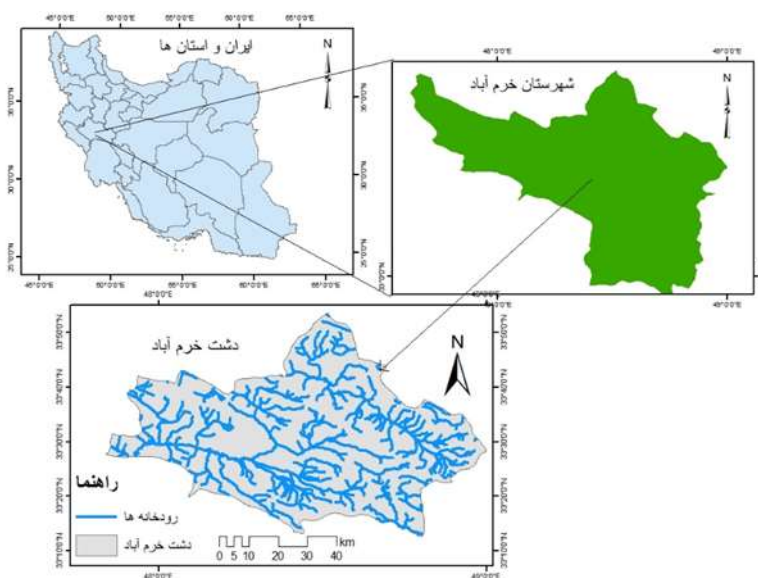
1 -Dang

2 - kaiyo zhao

(NSE) برابر با به ترتیب ۰.۳۰۵ متر، ۰.۰۱۴ متر و ۰.۹۹۸ متر می‌باشد. نتایج نشان داد که مدل MODFLOW-LSSVR سطح آب زیرزمینی را با دقت بیشتری نسبت به MODFLOW-SVR و MODFLOW-SVR-WOA پیش‌بینی می‌کند. مرور مطالعات صورت گرفته در زمینه پتانسیل‌یابی منابع آب زیرزمینی نشان می‌دهد که این موضوع در سال‌های اخیر همواره مورد توجه پژوهش‌گران بوده است. به همین منظور در مطالعه حاضر به پتانسیل‌یابی منابع آب زیرزمینی با استفاده از متغیرهای مؤثر (ارتفاع، شیب، جهت‌شیب، خاک، کاربری‌اراضی، لیتولوژی، فاصله از گسل، فاصله از آبراهه، بارش) و بهره‌گیری از ArcGIS و اجرای مدل شبکه عصبی کانولوشن در دشت خرم‌آباد پرداخته شد. تعیین نقشه پتانسیل منابع آب زیرزمینی در این محدوده تاکنون با بهره‌گیری از روش شبکه عصبی کانولوشن که از جمله مدل‌های یادگیری ماشینی است، تهیه نشده است.

### منطقه مورد مطالعه

شهر خرم‌آباد به‌عنوان مرکز استان لرستان و نیز از بزرگترین شهرستان استان هم به لحاظ جمعیت و هم مساحت می‌باشد که دارای موقعیت ۲۰ و ۴۸ درجه الی ۲۳ و ۴۸ درجه طول شرقی و ۲۷ و ۳۳ الی ۳۳ و ۳۳ درجه عرض شمالی است. این شهر از شمال به شهرستان نورآباد، از جنوب به شهرستان پلدختر، از غرب به شهرستان کوهدشت و از شرق به شهرستان بروجرود منتهی می‌گردد (طالبی، ۱۳۹۴: ۱). وسعت منطقه ۲۵۱۳ کیلومتر مربع و ارتفاع متوسط ۱۲۶۰ متر از سطح دریا می‌باشد. رود خرم‌آباد بخش شمالی حوضه آبریز و رودخانه کاکاشرف جنوب و جنوب‌شرقی آن را زهکشی می‌نماید (طهماسیان و همکاران، ۱۳۹۶: ۵). بارزترین ویژگی این حوضه از نظر طبیعی کوهستانی بودن و ساخت جوان ناهمواری‌های آن است. حوزه آبریز رودخانه خرم‌آباد یکی از زیرحوضه‌های رودخانه کرخه است این حوضه در بخش میانی کوه‌های زاگرس واقع شده است. با توجه به شرایط کوهستانی دشت خرم‌آباد آب و هوای آن تحت تأثیر اقلیم کوهستانی قرار دارد. اقلیم سرد کوهستانی در مناطق مرتفع و اقلیم معتدل کوهستانی در دره‌ها و مناطق میان‌کوهی شرایط خاص و ویژه‌ای را به این منطقه بخشیده است. از ویژگی‌های خاص منطقه تغییر عناصر اقلیمی برحسب ارتفاع است، این تغییرات در شدت عمل عوامل شکل‌زایی حائز اهمیت هستند. افزایش و کاهش ارتفاع، دما و بارش منطقه رو تغییر می‌دهد به نحوی که به ازای هر ۱۰۰ متر تغییر در ارتفاع در حوضه ۸/۲ درجه دما و ۳۳/۴ میلی‌متر بارندگی تغییر می‌کند (علیاری، ۱۳۷۶: ۳). شهرستان خرم‌آباد از نظر زمین‌شناسی مربوط به سنوزوئیک جزء دوره کواترنری می‌باشد و جزء زاگرس چین خورده محسوب می‌گردد. این منطقه از لحاظ تکتونیک وضعیت متعادلی دارد به طوری که رسوبات با لایه‌بندی یکنواخت و به ترتیب سنی بر روی یکدیگر قرار گرفته‌اند و پدیده تکتونیک خاصی به جز وجود چین‌خوردگی‌های متعدد و گسل‌های درون‌سازی در این منطقه مشاهده نمی‌شود (خلجی و همکاران، ۱۳۹۲: ۱).



شکل ۱: منطقه مورد مطالعه

Figure 1: The study area



## مواد و روش

در این تحقیق نقشه‌های زمین‌شناسی در مقیاس ۱:۱۰۰۰۰۰:۱ سازمان زمین‌شناسی، نقشه‌های توپوگرافی در مقیاس ۱:۵۰۰۰۰ سازمان جغرافیایی استان، تصاویر ماهواره‌ای لندست ۸ سال ۱۳۹۸، داده‌های اقلیمی بارش منطقه مورد مطالعه (۱۳۸۵ تا ۱۳۹۷) از سازمان هواشناسی استان لرستان مورد بررسی قرار گرفته است. DEM با فاصله ۱۲.۵ متری از ماهواره ALOS PALSAR ۲۰۱۸ استفاده شد. از نرم افزار ArcGIS برای ایجاد پایگاه داده، تحلیل فضایی و در نهایت مدل پیاده‌سازی و از نرم‌افزارهای ENVI برای اصلاحات هندسی و رادیومتری تصاویر ماهواره‌ای و پردازش آن‌ها استفاده شد. برای طراحی مدل شبکه عصبی عمیق از نرم افزار MATLAB 2019 استفاده شد. در این تحقیق ۹ عامل ارتفاع، شیب، جهت‌شیب، کاربری اراضی، سنگ‌شناسی، خاک، فاصله از گسل، فاصله از رودخانه، بارندگی برای مطالعه و پهنه‌بندی مناطق مستعد منابع آب زیرزمینی برای مدل شبکه عصبی کانولوشن مورد بررسی قرار گرفت. سپس نقشه این عوامل با استفاده از نرم‌افزار ArcGIS تهیه و در مدل مورد استفاده قرار گرفت. به‌منظور رویکرد این مطالعه، ابتدا سوابق علمی موجود بررسی می‌شود تا تمامی معیارهای مؤثر بر مناطق با پتانسیل منابع آب زیرزمینی مشخص شود. سپس اطلاعات موجود شامل نقشه‌ها و تصاویر ماهواره‌های مورد نیاز جمع‌آوری و پس از تهیه نقشه‌ها، اصلاحات لازم بر روی نقشه‌ها و تصاویر ماهواره‌ها انجام شد.

## تشریح مدل شبکه عصبی کانولوشن

شبکه عصبی کانولوشنال (CNN) در سال‌های اخیر،<sup>۱</sup> DL به‌طور گسترده‌ای در کاربردهای داده‌کاوی و سنجش از دور استفاده شده است. در مدل‌های DL، ویژگی‌ها را می‌توان به‌طور خودکار برای کارهای طبقه‌بندی بدون الگوریتم‌های ساخت ویژگی با ادغام رمزگذارهای خودکار استخراج کرد CNN های دو بعدی به‌طور گسترده در مطالعات سنجش از دور برای استخراج ویژگی‌های فضایی از تصاویر با وضوح بالا برای تشخیص اشیا و تقسیم‌بندی تصویر استفاده شده‌اند. این مطالعات چندین لایه کانولوشن را برای استخراج ویژگی‌های فضایی و طیفی از تصاویر سنجش از دور تشکیل دادند (مازیا و همکاران<sup>۲</sup>، ۲۰۲۰: ۴). محبوب‌ترین نوع شبکه عصبی عمیق در مناطق یادگیری عمیق، یعنی شبکه عصبی کانولوشن (CNN) که در کاربردهای واقعی مختلف به‌موفقیت زیادی دست می‌یابد (بواسفیاو همکاران<sup>۳</sup>، ۲۰۲۱: ۲۳). CNN از چندین لایه به‌هم پیوسته تشکیل شده است و نمایش ویژگی سلسله‌مراتبی را از داده‌های پیکسل خام می‌آموزد. ویژگی‌ها را در سطوح مختلف بازنمایی‌ها کشف می‌کند. پایین‌ترین سطح با ویژگی‌های اولیه پیکسل‌ها (مثلاً ویژگی‌های طیفی) نشان داده می‌شود و سطح بالاتر شامل تبدیل از نمایش پیکسل خام به نمایش‌های انتزاعی‌تر به تدریج است که نسبت به تغییرات هندسی کوچک (مثلاً لبه‌ها و گوشه‌ها) تغییر نمی‌کند و تبدیل بیشتر می‌شود. آن‌ها را به تدریج تغییر دهید تا آن‌ها را نسبت به تغییرات کنتراست و وارونگی کنتراست ثابت کنند (مثلاً قطعات شی) در پایان، متداول‌ترین الگوهای مربوط به مقوله‌های انتزاعی‌تر مرتبط با کل اشیا شناسایی می‌شوند (الشهی و همکاران<sup>۴</sup>، ۲۰۱۷: ۱۴۰). این روش تصاویر را از میان مجموعه‌هایی از چندین لایه، از جمله نوروها یا هسته‌های کوچک (کانولوشنال) عبور می‌دهد. هر نورو به‌بخش کوچکی از تصویر نگاه می‌کند و آن را خروجی می‌دهد. این خروجی شامل یک کلاس یا پتانسیل برای بهترین توصیف کلاس است. یک نمای کلی از معماری شبکه عصبی کانولوشنال در شکل ۲ نشان داده شده است که از سه لایه تشکیل شده است: ۱. پیچیدگی: در این لایه، هسته‌ها (وزن‌ها) به آرامی از روی تصویر عبور می‌کنند و خواص مختلفی را استخراج می‌کنند. معماری مورد استفاده در این تحقیق از سه لایه کانولوشن تشکیل شده است. لایه ۲: این لایه را با هم ادغام

<sup>۱</sup> - Deep learning

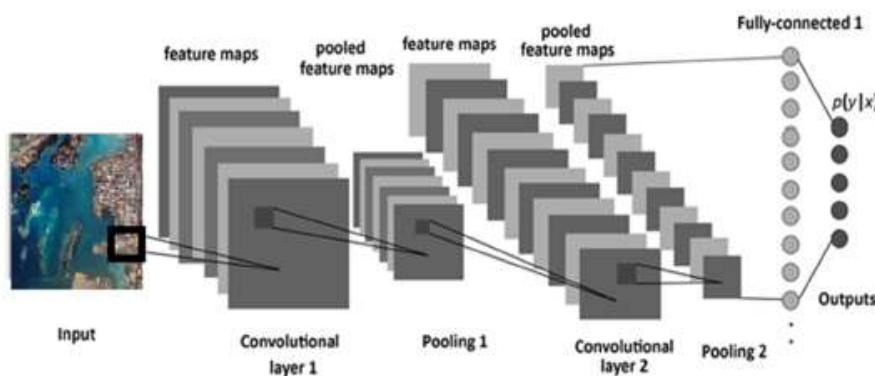
<sup>۲</sup> - Mazia et al

<sup>۳</sup> - Bouaafia et al

<sup>۴</sup> - Alshehhi et al

کنید تا تعداد پارامترها کاهش یابد تا هزینه‌ها کاهش یابد و از پدیده اضافه برآزش جلوگیری شود و حجم داده‌ها در میدان کاهش یابد. 3. لایه کاملاً متصل: این لایه لایه‌های ورودی را به یک لایه یک بعدی تبدیل می‌کند (دوتا و همکاران<sup>۱</sup>، ۲۰۱۷: ۲).

در مرحله اول تصویر ورودی به شبکه تغذیه می‌شود و در این مرحله ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و نهایتاً اعمال عملیات کانولوشن در هر لایه می‌باشد سپس خروجی شبکه محاسبه می‌شود. در این جا به منظور تنظیم پارامترهای شبکه و یا به عبارت دیگر همان آموزش شبکه، از نتیجه خروجی جهت محاسبه میزان خطای شبکه استفاده می‌شود. به این منظور خروجی شبکه را با استفاده از یک تابع خطا با پاسخ صحیح مقایسه کرده و این طور میزان خطا محاسبه می‌گردد. در مرحله بعدی براساس میزان خطای محاسبه شده مرحله پس انتشار آغاز می‌گردد. در این مرحله گرادیانت هر پارامتر با توجه به فائده زنجیره محاسبه شده و تمامی پارامترها با توجه به تأثیری که بر خطای ایجاد شده در شبکه دارند تغییر پیدا می‌کنند. بعد از بروزآوری پارامترها مرحله بعدی پیش‌رونده آغاز می‌گردد. بعد از تکرار تعداد مناسبی از این مراحل آموزش شبکه پایان می‌یابد.



شکل ۲: نمای کلی معماری شبکه عصبی عمیق

Figure 2: Overview of deep neural network architecture

#### پارامترهای عمومی مدل

اگر چند لایه کانولوشن انباشته شود، ویژگی‌های استخراجی با افزایش عمق بیشتر فشرده می‌شوند. لایه‌های اول، ویژگی‌هایی مانند لبه‌ها را تقویت می‌کنند و در لایه‌های بعدی به صورت موضوع اصلی، بخش یا شیء جمع می‌شوند.

مفاهیم زیردر چارچوب شبکه عصبی کانولوشن حائز اهمیت می‌باشند:

مقداردهی اولیه: این مفهوم برای رسیدن به همگرایی اهمیت دارد. ما در این جا از مقداردهی اولیه خاویر استفاده می‌کنیم. بدین وسیله نمونه‌های فعال‌سازی و گرادیان در سطوح کانتور شده حفظ می‌شود، در غیراین صورت ممکن است گرادیان‌های منتشر شده به عقب، از بین رفته یا منفجر شوند (معصومی و همکاران، ۱۳۹۶: ۳).

تابع فعال‌سازی: این تابع مسئولیت تبدیل غیرخطی داده‌ها را برعهده دارد. واحدهای خطی یکسو کننده (ReLU) به صورت زیر تعریف می‌شود:

$$f(x) = \max(0, x) \quad (1)$$

این واحدها برای دستیابی به نتایج بهتر نسبت به توابع مماس هذلولی یا هلالی قدیمی‌تر و تسریع آموزش مشخص شدند اما اعمال یک ثابت 0 می‌تواند به گردش گرادیان و تطبیق متوالی وزن‌ها آسیب وارد کند. این محدودیت‌ها را می‌توان به کمک متغیری به نام واحد

<sup>1</sup> - Dota et al

خطی یکسوکنده (LReLU) که با شیب منحنی کوچکی در بخش منفی تابع شروع می شود برطرف کرد (معصومی و همکاران، ۱۳۹۶: ۴). این تابع به صورت زیر تعریف می شود:

$$f(x) = \max(0; x) + \min(0; x) \quad (2)$$

در این تابع پارامتر  $\Phi$  نامتراکمی می باشد. در لایه تمام بسته آخر از حداکثر نرمی استفاده می کنیم.

ادغام: ویژگی های اطراف نقشه های ویژگی را از نظر فضایی ترکیب می کند. این ترکیب ویژگی های زائد احتمالی نظیر جزئیات کم اهمیت، نمایش آن را برای تغییرات جزئی تصویر فشرده تر و ثابت تر کرده و بار محاسباتی مرحله های بعدی را نیز کاهش می دهد. برای پیوند ویژگی ها معمولاً از ادغام ماکزیمم یا میانگین استفاده می کنند (بیرانوند و همکاران، ۱۳۹۹: ۴۹).

تنظیم: برای کاهش تطابق اضافی مورد استفاده قرار می گیرد. ما در لایه های تمام بسته از روش کنارگذاری استفاده می کنیم. این روش در هر مرحله آموزش با احتمال گره ها را از شبکه مورد نظر برداشته و بدین شیوه تمام گره های لایه های تمام بسته را مجبور می کند تا نمایش بهتری از داده ها یاد بگیرند و با این کار از تطابق گره ها با یکدیگر جلوگیری می کند. در حین انجام آزمایش از تمام گره ها استفاده می شود. از آنجایی که آموزش هر شبکه با بخشی از داده های آموزشی صورت می گیرد، کنارگذاری را می توان مجموعه های از شبکه های متفاوت و نوعی جاناندازی تلقی کرد (معصومی و همکاران، ۱۳۹۶: ۴).

تابع اتلاف: تابعی است که طی فرآیند آموزش باید به کمترین حد خود برسد. در اینجا از آنتروپی متقاطع رسته های استفاده کرده ایم،

$$H = - \sum_{\text{Evovels}} \sum_{\text{KEclasses}} c_j \log(c_j^k | 3) \quad (3)$$

در این معادله  $c$  نشان دهنده پیشبینی های احتمالی (پس از سافتمکس) و  $\hat{c}$  نیز هدف مورد نظر است.

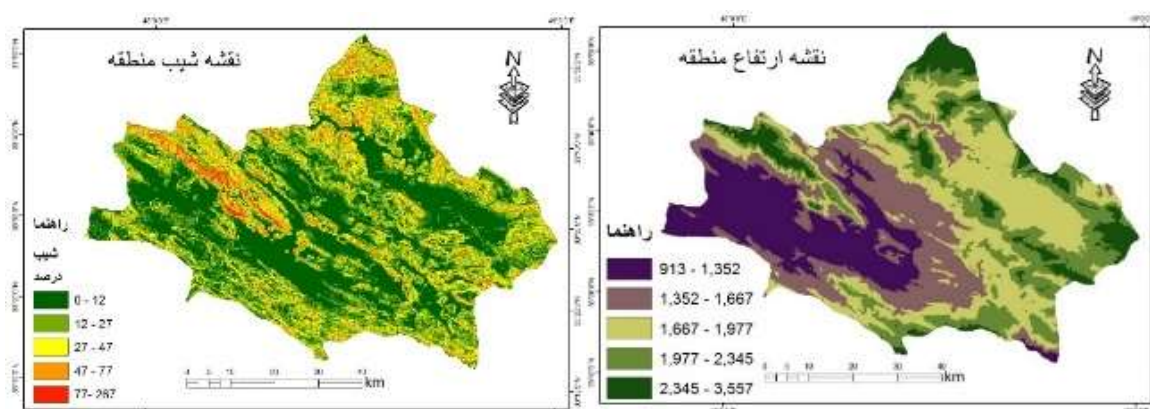
آموزش: برای آموزش شبکه عصبی کانولوشن، تابع اتلاف با وجود غیرخطی بودن باید به کمترین حد خود برسد. در اینجا از گرادیان نزولی تصادفی به عنوان الگوریتم بهینه سازی استفاده می کنیم. این الگوریتم متناسب با مقدار منفی گرادیان در جهت کمینه های محلی اقدام می کند، ولی با این همه در نواحی دارای انحنای کم ممکن است پس از  $\epsilon$  ثابت حفظ می شود، ولی سرعت یادگیری  $v$  عمل نماید. بنابراین، برای تسریع الگوریتم در آن نواحی از گشتاور شتابدار نستروف کمک می گیریم. در این گشتاور هر دوره به صورت خطی کاهش یافته است. کنارگذاری کامل کلیه نمونه های آموزشی را یک دوره تلقی می کنیم (معصومی و همکاران، ۱۳۹۶: ۶).

ارزیابی: دقت و اعتبار نتایج مطالعات اعتبارسنجی طبقه بندی کننده اغلب به عنوان ماتریس های سردرگمی ارائه می شود. یک ماتریس سردرگمی برای طبقه بندی  $k$  کلاس یک جدول احتمالی  $k \times k$  است که سلول های  $(i, j)$  ( $i = 1, \dots, k, j = 1, \dots, k$ ) فرکانس مشاهدات را با کلاس واقعی  $C_i$  و کلاس استنباط شده ارائه می کنند.  $C_j$  یک ماتریس سردرگمی باینری یک مورد خاص است زمانی که فقط دو کلاس وجود دارد:  $C$  (کلاس مثبت) و نه  $C$  (کلاس منفی). یک ماتریس سردرگمی  $k \times k$  همیشه می تواند به عنوان مجموعه ای از  $k$  ماتریس های سردرگمی باینری یکی برای هر کلاس  $C_i$  نمایش داده شود. در یک ماتریس سردرگمی باینری، مشاهداتی که به درستی در کلاس مثبت طبقه بندی شده اند، مثبت های واقعی و مشاهداتی که به درستی در کلاس منفی طبقه بندی شده اند، منفی های واقعی نامیده می شوند. نمونه هایی از کلاس مثبت که به طور کاذب به عنوان منفی طبقه بندی می شوند، منفی های کاذب و نمونه هایی از کلاس منفی که به طور



کاذب به عنوان مثبت طبقه‌بندی می‌شوند، مثبت کاذب نامیده می‌شوند. تعداد مشاهدات مثبت درست، مثبت کاذب، منفی درست و منفی کاذب توسط TP، FP، FN و TN ذکر شده است (سالا و همکاران، ۲۰۱۸: ۴).

لایه‌های اطلاعاتی استفاده شده: نقشه ارتفاعی منطقه براساس مدل رقومی ارتفاعی با دقت ۱۲.۵ متر با استفاده از ماهواره ALOS PALSAR تهیه شد. ارتفاع یکی از عوامل اصلی در پتانسیل‌یابی منابع آب زیرزمینی بوده و تقریباً تمامی روش‌های پهنه‌بندی این عامل را به نحوی در نظر گرفته‌اند (شکل ۲). شیب: یکی دیگر از عوامل مؤثر در پتانسیل‌یابی منابع آب زیرزمینی است و از عوامل مؤثر در تبدیل بارش به رواناب است. بین شیب و سرعت رواناب یک منطقه رابطه مستقیمی برقرار است. این نقشه از مدل رقومی ارتفاع منطقه در ۵ طبقه در محیط نرم‌افزار ArcGIS تهیه شد (شکل ۳). جهت شیب نشان‌دهنده تأثیر متفاوت نورآفتاب، بادهای گرم و خشک و بارش در جهت‌های مختلف است (اصغری و بلواسی، ۱۳۹۷: ۱۶۵). نقشه جهت شیب منطقه با استفاده از مدل ارتفاعی رقومی در نه کلاس طبقه‌بندی شده است که شامل جهات اصلی، فرعی و مسطح می‌باشد (شکل ۴). خاک: نفوذ آب در خاک به عواملی مانند بافت و ساختمان خاک، پوشش گیاهی و شیب زمین بستگی دارد. بدیهی است که نوع بافت خاک تأثیر مهمی در افزایش یا کاهش میزان نفوذ آب دارد (فلاح و همکاران، ۱۳۹۶: ۹۲). نقشه خاک محدوده مطالعاتی با توجه به نقشه خاک ایران در ۴ کلاس تهیه شد (شکل ۵). فاصله از رودخانه: معمولاً با دور شدن از رودخانه قدرت نفوذپذیری کم می‌شود. نقشه فاصله از رودخانه براساس لایه رقومی شبکه آبراهه در دشت خرم‌آباد تهیه شد. این نقشه در نهایت به ۶ دسته طبقه‌بندی شد (شکل ۶). فاصله از گسل: گسل‌ها و شکستگی‌های موجود در یک منطقه در جهت تغذیه آب‌های زیرزمینی به عنوان نقاط مثبتی در نظر گرفته می‌شوند (فلاح و همکاران، ۱۳۹۶: ۹۲). نقشه فاصله از گسل براساس نقشه‌ی رقومی گسل‌های استان لرستان (اداره آبخیزداری استان لرستان، ۱۳۹۲) در مقیاس ۱:۲۵۰۰۰۰ تهیه شد. نقشه مذکور در ۵ کلاس طبقه‌بندی گردید (شکل ۷). بارش: در مناطقی که دارای بارندگی بیشتر هستند در صورتی که دیگر شرایط مساعد باشد فاکتور بارش می‌تواند عامل بسیار مهم در تغذیه آب‌های زیرزمینی باشد. داده‌های بارندگی سال ۱۳۸۵ تا ۱۳۹۷ مربوط به ایستگاه‌های باران سنجی منطقه مورد مطالعه از سازمان هواشناسی استان لرستان تهیه شد و میانگین بارش سالانه با استفاده از روش رگرسیون خطی در محیط Excel، ArcGIS برای حوضه مورد مطالعه به دست آمد (شکل ۸). کاربری اراضی: وجود پوشش گیاهی در هر منطقه سرعت جریان‌های سطحی را کاهش می‌دهد و سبب نفوذ بیشتر آب به داخل خاک می‌گردد (صابری و همکاران، ۱۳۹۱: ۱۲). نقشه کاربری اراضی با استفاده از تصویر ماهواره‌ای لندست ۸ تهیه شد (شکل ۹). سنگ‌شناسی: سنگ‌شناسی و مطالعات آب‌های زیرزمینی در ارتباط مستقیمی با جنس و نفوذپذیری سنگ بستر آن منطقه می‌باشد (تاجی، ۱۳۹۸: ۵۲). نقشه سنگ‌شناسی محدوده مطالعاتی خرم‌آباد با استفاده از نقشه‌های سازمان زمین‌شناسی کشور در مقیاس ۱:۱۰۰۰۰۰ تهیه گردیده و در ۶ گروه طبقه‌بندی گردید (شکل ۱۰) و (جدول ۱).



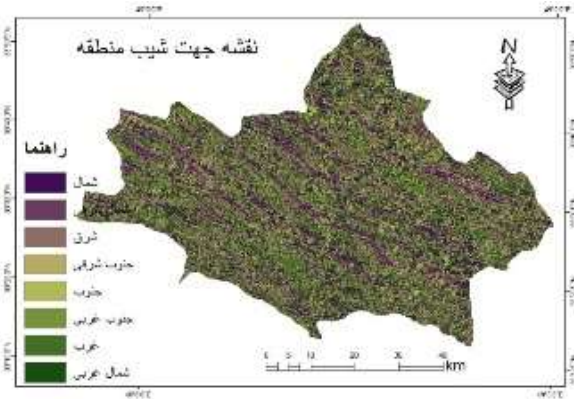
شکل ۴: نقشه شیب منطقه مورد مطالعه  
Figure 4: Slope map of the studied area

شکل ۳: نقشه ارتفاع منطقه مورد مطالعه  
Figure 3: Elevation map of the studied area



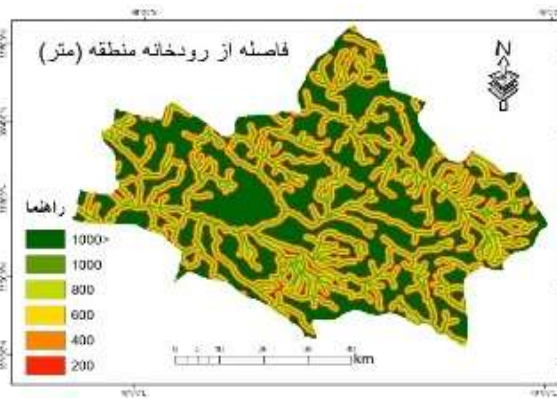
شکل ۶: نقشه خاک منطقه مورد مطالعه

Figure 6: Soil map of the study area



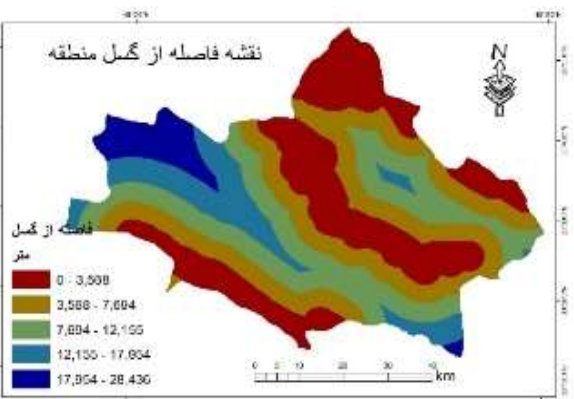
شکل ۵: نقشه جهت شیب منطقه مورد مطالعه

Figure 5: Slope direction map of the studied area



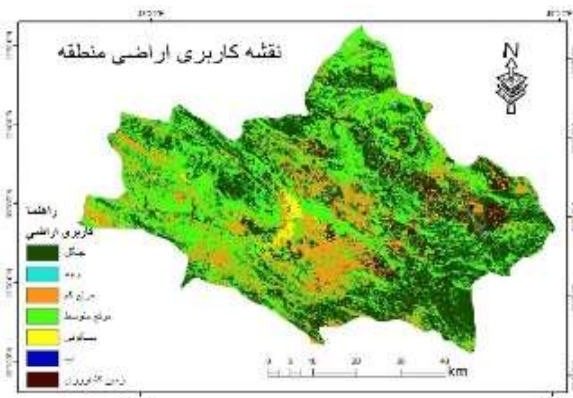
شکل ۸: نقشه فاصله از رودخانه منطقه مورد مطالعه

Figure 8: Map of the distance from the river in the study area



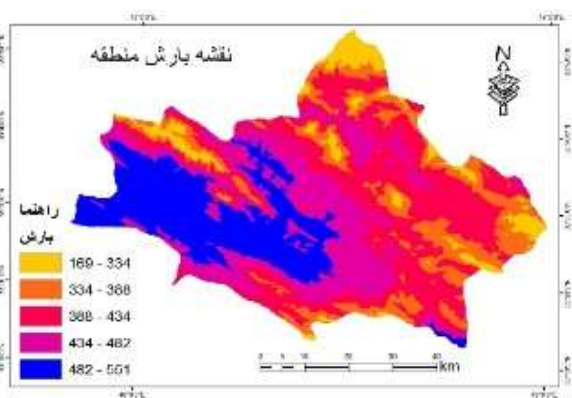
شکل ۷: نقشه فاصله از گسل منطقه مورد مطالعه

Figure 7: Map of the distance from the fault of the study area



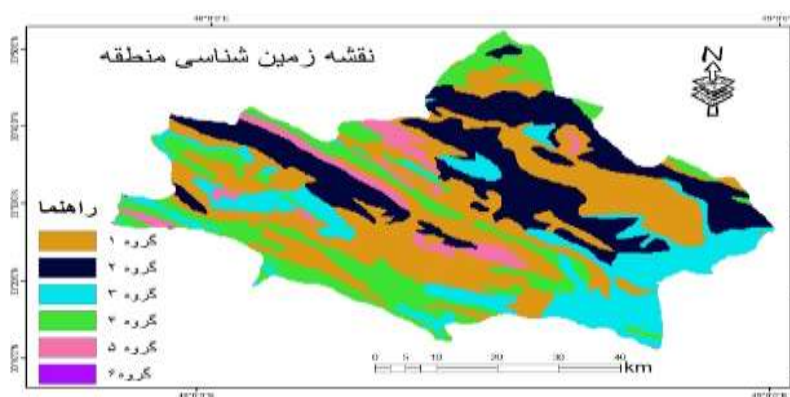
شکل ۱۰: نقشه کاربری اراضی منطقه مورد مطالعه

Figure 10: Land use map of the study area



شکل ۹: نقشه بارش منطقه مورد مطالعه

Figure 9: Precipitation map of the study area



شکل ۱۱: نقشه زمین شناسی منطقه مورد مطالعه

Figure 11: Geological map of the studied area

جدول ۱: اطلاعات مربوط به طبقات سازندهای حوضه مورد مطالعه

Table 1: Information about the strata of the studied basin formations

نوع سازند	
گروه ۱	ذخایر تراسی و مخروط افکنه‌ی کوهپایه‌ای قدیمی مرتفع و جدید کم ارتفاع
گروه ۲	بنگستان تفکیک نشده (آهک و شیل و...)، آهک اربیتولین دار توده‌ای ضخیم لایه خاکستری، آهک مرجانی، مارنی، آهک دولومیتی، دولومیت قهوه‌ای رنگ
گروه ۳	سازند کشکان (کنگلومرای قرمز، ماسه سنگ، سیلیتون)، سازند بختیاری (کنگلومرای توده‌ای سیمانی بادگرسانی شدید)، کنگلومرای بختیاری، مارن
گروه ۴	سازند آقاجاری (ماسه سنگ آهک دار قهوه‌ای مایل به خاکستری)، گروه فارس (گچساران، میشان)، سازند امیران، سنگ‌های تفکیک نشده سازندهای شهبازی و آسمانی، سازند تله زنگ، برش رادیولاریت، آهک متعفن الیتی توده‌ای ضخیم لایه خاکستری
گروه ۵	سازند گورپی (مارن خاکستری مایل به آبی و شیل حاوی آهک آرژیلی)، سنگ‌های تفکیک نشده آئوسن، سازند گچساران، مارن، ماسه سنگ، آهک، سازند آسماری
گروه ۶	سازند نمکی هرمز

پتانسیل یابی و تهیه نقشه منابع آب زیرزمینی در این تحقیق براساس چاه‌های آب در منطقه و معیارهای مؤثر در منابع آب زیرزمینی است. نحوه‌ی تهیه‌ی نقشه‌ی منابع آب زیرزمینی به صورت زیر است، ابتدا داده‌های چاه‌های آب در منطقه مورد مطالعه از اداره آب و فاضلاب استان لرستان، تهیه و برخی هم از طریق بازدیدهای میدانی با استفاده از GPS جمع‌آوری شدند. در ادامه معیارهای مؤثر بر منابع آب زیرزمینی در دشت خرم‌آباد از طریق بازدیدهای میدانی، نقشه‌های زمین‌شناسی و توپوگرافی و با مرور منابع قبلی و بررسی شرایط

منطقه انتخاب شدند که عبارت بودند از: طبقات ارتفاعی، شیب، جهت شیب، فاصله از گسل، فاصله از رودخانه، بارش، لیتولوژی و کاربری اراضی به عنوان عوامل مؤثر بر منابع آب زیرزمینی بررسی و انتخاب شدند.


لایه‌های اطلاعاتی استفاده شده: در این پژوهش از تصاویر ماهواره‌ای Landsat8 و سنسور OLI شامل ۹ باند طیفی با تفکیک مکانی ۳۰ متر استفاده شد. وضوح رادیومتریک تصاویر این ماهواره ۱۲ بیتی و دوره تکرار آن ۱۶ روز می باشد. توجه به خشکسالی‌های اخیر که منجر به استفاده بی‌رویه از منابع آب‌های زیرزمینی، مجموعه‌ای از تصاویر (۲۰ تصویر در ماه‌های مختلف) در این منطقه تهیه شد. این تصاویر با روش PanSharpening در محیط ENVI به وضوح فضایی ۱۵ متر تبدیل شدند.

داده‌های آموزشی: پس از انتخاب تصاویر، نمونه‌های آموزشی با استفاده از بازدید میدانی در منطقه جمع‌آوری شد. این داده‌ها به صورت Shapfile استخراج شد. به منظور تسهیل در پردازش داده‌ها به منظور تبدیل داده‌ها به فرم شطرنجی، ابتدا نمونه‌های جمع‌آوری شده در تصاویر شناسایی و مناطق مورد نظر به صورت چندضلعی برای هر نمونه آموزشی و یک تصویر صفر و یک برای هر کلاس استخراج شد. در این تحقیق از روش شبکه مربع منظم استفاده شد و کلیه نقشه‌ها با این نوع شبکه تقسیم شدند. پس از استانداردسازی و شبکه‌سازی لایه‌ها، برای وارد کردن اطلاعات این لایه‌ها در نرم‌افزار متلب و انجام تحلیل توسط مدل‌ها طراحی شد. برای شبکه‌سازی منطقه، ابعاد شبکه‌ها از ۳۰ متر به ۳۰۰ متر تغییر یافت. با توجه به ابعاد حوضه، مقدار ۱۰۰ متر مناسب در نظر گرفته شد. ساخت داده‌های مجموعه نمونه برچسب با اشاره به «نقشه توزیع منابع آب زیرزمینی در منطقه خرم‌آباد» و همراه با بررسی میدانی توزیع آب زیرزمینی در داخل این منطقه مورد مطالعه به عنوان داده‌های برچسب نمونه تعیین شد. تحقیقات میدانی در مطابق با شرایط واقعی چاه‌ها برچسب رتبه‌بندی مربوطه را تنظیم کنید. مناطقی که دارای آب زیرزمینی هستند برچسب ۱ و مناطقی فاقد آب زیرزمینی برچسب صفر داده شد. تمامی این نقشه‌ها و نمونه‌های برچسب را در فرآیند یادگیری عمیق آموزش، یادگیری و آزمایش ترکیب کردیم.

### معماری شبکه کانولوشن

ساختار و معماری شبکه طراحی شده در این پژوهش در شکل (۱۲) نشان داده شده است. همانطور که مشخص است شبکه طراحی شده از دو قسمت کلی تشکیل شده است. در بخش اول نمونه‌برداری پایین، در مجموع از ۶ لایه استفاده می‌شود که دارای دو لایه کانولوشن هستند و بخش دوم نمونه‌برداری دارای سه لایه کانولوشن است. لایه‌های کانولوشن از هسته‌های سه‌بعدی برای استخراج ویژگی استفاده می‌کنند. بنابراین شبکه قادر خواهد بود به‌طور همزمان ویژگی‌های مکانی و زمانی هر پیکسل تصویر را استخراج کرده و در تصمیم‌گیری نهایی از آن‌ها استفاده کند. ابعاد تمامی هسته‌های سه‌بعدی  $3 \times 3 \times 3$  است. تعداد فیلترهای استفاده شده در هر لایه با استفاده از روش آزمون و خطا در نظر گرفته می‌شود تا بالاترین دقت ممکن در داده‌های ارزیابی به دست آید. علاوه بر موارد فوق در لایه‌های چهارم و ششم قسمت اول از لایه A Max Pooling با ابعاد  $2 \times 2$  استفاده شده است که ورودی آن خروجی تابع فعال کننده Relu می‌باشد. این ابعاد به عنوان پرکاربردترین ابعاد لایه Max Pooling در مطالعات مختلف مورد استفاده قرار گرفته است. این لایه علاوه بر کاهش حجم محاسبات و حفظ ویژگی‌های اصلی استخراج شده، با کاهش تعداد اتصالات شبکه، منجر به تسهیل آموزش شبکه و کاهش تعداد پارامترهای شبکه قابل آموزش می‌شود. آموزش شبکه به صورت back-propagation انجام شد و برای بهینه‌سازی الگوریتم از الگوریتم sgd استفاده شد. در نهایت، نرخ یادگیری شبکه  $[1 \times 10^{-3}]$  در نظر گرفته شد. پس از تهیه داده‌ها و طراحی معماری شبکه، روش مورد نظر پیاده‌سازی شده و در نهایت خروجی شبکه به صورت تصویری تولید می‌شود که مناطق با پتانسیل یابی منابع آب زیرزمینی را نشان می‌دهد.



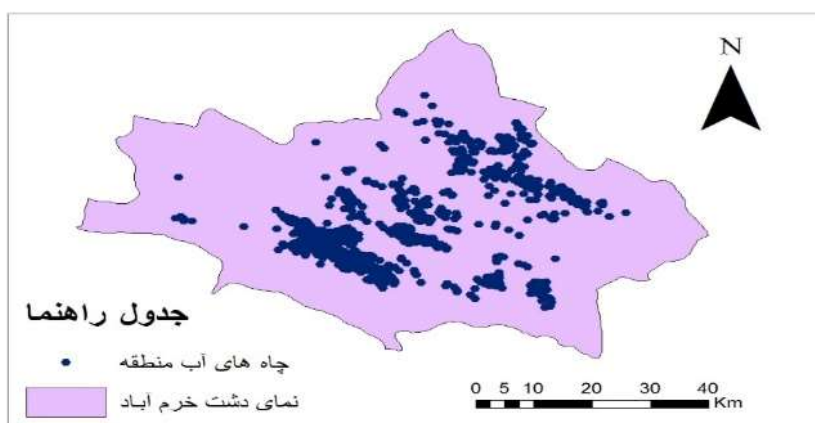


شکل ۱۲: معماری شبکه عصبی عمیق با ساختار نمونه برداری بالا و پایین

Figure 12: Deep neural network architecture with up and down sampling structure

### بحث و نتایج

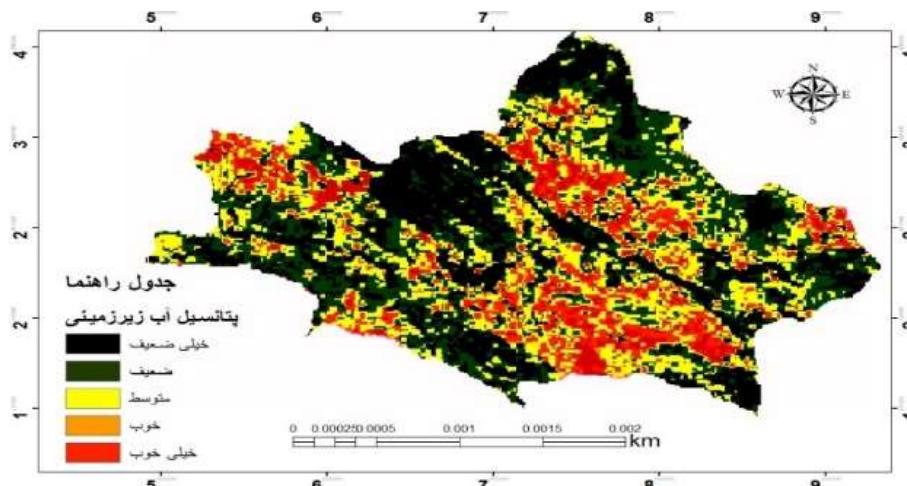
در این تحقیق تعداد نمونه‌ها به‌عنوان نسبت بین مجموعه آموزشی و مجموعه آزمایشی ۷۰:۳۰ تعیین شد و چارچوب شبکه عصبی کانولوشن به‌عنوان ۲ لایه کانولوشن و ۲ لایه ادغام، ۲ اتصال کامل استفاده شد. لایه‌ها و در نهایت لایه sigmoid برای در طبقه‌بندی از هسته کانولوشن ۳×۳، تابع Relu به‌عنوان تابع فعال‌سازی و تابع آنتروپی متقاطع به‌عنوان تابع زیان استفاده شد. دقت هر مرحله محاسبه شد و BATCH\_SIZE روی ۱۰۰، Epochs روی ۴۰۰ و نرخ یادگیری ۰.۰۰۰۱ تنظیم شد. داده‌های ورودی، داده‌های واقعی آب زیرزمینی در منطقه و داده‌های معادل آن بود. داده‌های شبیه‌سازی آب‌های زیرزمینی که با نتایج ارزیابی سنجش از دور آب‌های زیرزمینی مطابقت داشتند. این همچنین یک فرآیند برچسب‌گذاری و ایجاد یک مجموعه داده نمونه بود، یعنی استفاده از سطح توزیع آب زیرزمینی واقعی یا معادل برای مطابقت با مقدار مناطق با پتانسیل آب زیرزمینی ارزیابی شده توسط سنجش از دور تاکنون از ۱۰۰۰ داده‌های چاه‌ها به‌عنوان داده‌های مجموعه نمونه این منطقه تحقیقاتی برای آموزش مدل CNN توزیع آب زیرزمینی استفاده شده است، که نقشه مربوط به آن در شکل (۱۳) نشان داده شده است.



شکل ۱۳: نقشه چاه‌های آب منطقه مورد مطالعه

Figure 13: Map of water wells in the study area

برای جلوگیری از هرگونه دخل و تصرف در نتایج شبکه عصبی، در این تحقیق برای آموزش و آزمایش شبکه به طور تصادفی و مساوی داده آب زیرزمینی آبدار و غیرآبدار انتخاب و از ۷۰ درصد این داده‌ها برای آموزش و ۳۰ درصد برای آزمایش استفاده شد که از اطلاعات ۱۰۰۰ نقاط چاه برای آموزش و آزمایش شبکه به کار برده شد. با بررسی پاسخ‌های خروجی شبکه عصبی در مرحله آزمایش، مشخص گردید که شبکه عصبی ایجاد شده دارای دقت ۹۲ درصدی است که هر چه به ۱ نزدیکتر باشد بهتر بودن مدل را نشان می‌دهد و تابع زیان به ۰.۳۱۱۳ کاهش یافت (که هر چه به صفر نزدیکتر باشد کم خطا بودن مدل را نشان می‌دهد)، بنابراین یک مدل طبقه‌بندی بهتر برای ارزیابی منابع آب زیرزمینی در دشت خرم‌آباد به دست آمد. در نهایت نقشه پتانسیل‌یابی منابع آب زیرزمینی براساس مدل شبکه کانولوشن به ۵ محدوده تقسیم‌بندی گردید (شکل ۱۴). از این میان سطح ارزیابی آب زیرزمینی در منطقه مورد مطالعه با ۵ رنگ به ۵ دسته تقسیم شد (رنگ‌های مربوط به آن سبز تیره، سبز روشن، زرد، نارنجی و قرمز به ترتیب مناطق با پتانسیل آب خیلی ضعیف، ضعیف، متوسط، خوب، خیلی خوب) می‌باشد. براساس پهنه‌بندی صورت گرفته در دشت خرم‌آباد با استفاده از شبکه کانولوشن درصد مساحت منطقه با پتانسیل متفاوت در کلاس‌های خیلی خوب، خوب، متوسط، ضعیف، خیلی ضعیف مشخص شد (جدول ۲)



شکل ۱۴: نقشه پتانسیل‌یابی منابع آب زیرزمینی در دشت خرم‌آباد با استفاده از شبکه کانولوشن

Figure 14: Map of the potential of underground water sources in Khorram Abad plain using Kakavolution network.

جدول ۲: درصد مساحت مناطق با پتانسیل متفاوت در روش شبکه عصبی کانولوشن


Table 2: Area percentage of areas with different potential in convolutional neural network method

زیاد	خیلی زیاد	متوسط	کم	خیلی کم	مساحت
۵/۸۰	۱۳/۴۵	۲۷	۳۱/۴۷	۲۲/۲۷	CNN

عملکرد این نقشه طبقه‌بندی با شاخص دقت کلی و دقت کلی در ماتریس سردرگمی ارزیابی شد. دقت کلی با محاسبه نسبت بین تعداد کل پیکسل‌های طبقه‌بندی شده صحیح و کل پیکسل‌های حقیقت زمین برای همه کلاس‌ها نشان داده می‌شود. عناصر مورب ماتریس نشان‌دهنده پیکسل‌هایی هستند که به درستی برای هر کلاس طبقه‌بندی شده‌اند. دقت کلاس فردی با تقسیم تعداد پیکسل‌های



طبقه‌بندی شده صحیح در هر دسته بر تعداد کل پیکسل‌های ردیف مربوطه به نام دقت کاربر و ستون‌هایی به نام دقت سازنده محاسبه شد. ۳۰ درصد از داده‌های واقعی برای ارزیابی استفاده شد که منجر به دقت کلی ۹۲ درصد شد، یعنی مدل توانسته ۹۲ درصد داده‌ها را آب زیرزمینی و ۹۳ درصد عدم آب زیرزمینی رو به درستی تشخیص دهد و صحت کلی آن ۹۳ درصد است. تمرکز اصلی این معیار صحت، بر روی درستی تشخیص‌های «بلی» توسط الگوریتم است. یعنی ۹۲ درصد داده‌ها واقعا آب زیرزمینی رو نشان می‌دهد. معیار پوشش (حساسیت) به دنبال یافتن پوشش بلی در میان داده‌هاست و حساسیت این مدل ۹۳ درصد است. همچنین ۶ درصد پیکسل‌ها عدم آب هستند که به اشتباه جز آب زیرزمینی در نظر گرفته شده‌اند (شکل ۱۵).



شکل ۱۵: ارزیابی نقشه پتانسیل آب زیرزمینی شبکه عصبی کانولوشن با ماتریس سردرگمی

Figure 15: Convolution neural network groundwater potential map evaluation with confusion matrix

## نتیجه‌گیری

در این تحقیق برای پتانسیل‌یابی منابع آب زیرزمینی منطقه مورد مطالعه ابتدا نقشه‌های متناسب با پارامترهای مؤثر در پتانسیل منابع آب که شامل لایه‌های شیب، جهت‌شیب، زمین‌شناسی (لیتولوژی)، کاربری‌اراضی، طبقات ارتفاعی، بارش، دما، فاصله از گسل، فاصله از رودخانه، سطح آب زیرزمینی می‌باشند تهیه شد. سپس به کمک روش شبکه عصبی کانولوشن و با استفاده از این لایه‌ها نقشه نهایی پتانسیل منابع آب استخراج شد. برای پهنه‌بندی منابع آب زیرزمینی با استفاده از شبکه عصبی مصنوعی ابتدا تعداد نمونه‌ها به‌عنوان نسبت بین مجموعه آموزشی و مجموعه آزمایشی ۳۰:۷۰ تعیین شد و چارچوب شبکه عصبی کانولوشن به‌عنوان ۲ لایه ادغام، ۲ اتصال کامل استفاده شد. لایه‌ها و در نهایت لایه sigmoid برای در طبقه‌بندی از هسته کانولوشن ۳×۳، تابع Relu به‌عنوان تابع فعال‌سازی و تابع آنروپی متقاطع به‌عنوان تابع زیان استفاده شد. در نهایت نقشه پتانسیل منابع آب زیرزمینی در منطقه تهیه شد و سطح ارزیابی آب زیرزمینی در منطقه مورد مطالعه با ۵ رنگ به ۵ دسته تقسیم شد (رنگ‌های مربوط به آن سبز تیره، سبز روشن، زرد، نارنجی و قرمز به ترتیب مناطق با پتانسیل آب خیلی ضعیف، ضعیف، متوسط، خوب، خیلی خوب) می‌باشد. تجزیه و تحلیل نقشه پتانسیل آب زیرزمینی مدل شبکه عصبی کانولوشن نشان می‌دهد که حدود ۲۲.۲۷ درصد منطقه در شرایط خیلی کم آب زیرزمینی و ۳۱.۴۷ درصد منطقه در شرایط کم آب زیرزمینی قرار دارد. حدود ۲۷ درصد منطقه در شرایط متوسط آب زیرزمینی و ۱۹.۲۵ درصد منطقه در شرایط خوب و خیلی خوب آب زیرزمینی قرار دارد. در این تحقیق سهم مناطق مستعد آب زیرزمینی در شبکه عصبی کانولوشن ۴۶.۲۵ درصد از کل منطقه مورد مطالعه است که بیشتر آن در جنوب و شرق و شمال‌غربی منطقه و بخش کمی از غرب و مرکز را شامل می‌شود. نتایج تحقیقات فلاح و همکاران (۱۳۹۶) که به پتانسیل‌یابی منابع آب زیرزمینی خرم‌آباد با روش شاخص آماری پرداخته بودند، نشان می‌دهد که

سهم مناطق با پتانسیل زیاد و خیلی زیاد ۴۶ درصد از سطح کل محدوده مطالعاتی خرم‌آباد می‌باشد که در نواحی شمال تا جنوب شرق و همچنین در نواحی مرکزی و غربی محدوده مطالعاتی دیده می‌شوند، در حالی که در این پژوهش سهم مناطق با پتانسیل خوب و خیلی خوب ۴۳ درصد از سطح کل محدوده مطالعاتی می‌باشد. نتایج مطالعات عشرت پورو رحیم نژاد (۱۳۹۵) که با تلفیق شاخص‌های طبیعی در فرآیند ارزیابی پتانسیل منابع آب زیرزمینی در استان لرستان نشان داد که هر یک از شاخص‌های طبیعی دارای وزن و اهمیت متفاوت با دیگری می‌باشند و ۲۵/۱ و ۱۶/۵۳ و ۲۲/۰۲ و ۳۶/۸۲ درصد از استان به ترتیب در مناطق با پتانسیل نامناسب و نسبتاً نامناسب و نسبتاً مناسب و مناسب قرار دارد که با بررسی نقشه‌ی حاصل بخش بزرگی از شهرستان خرم‌آباد در منطقه پتانسیل خوب قرار گرفته است. در این پژوهش ارزیابی نتایج به دست آمده از روش فوق با استفاده از ماتریس سردرگمی نشان می‌دهد که مدل توانسته ۹۲ درصد داده‌ها را آب زیرزمینی و ۹۳ درصد عدم آب زیرزمینی رو به درستی تشخیص دهد و ۹۲ درصد داده‌ها واقعا آب زیرزمینی رو نشان می‌دهد. بنابراین براساس نقشه تهیه شده با روش شبکه عصبی کانولوشن حدود ۵۷ درصد دشت دارای مناطق با پتانسیل ضعیف آب زیرزمینی هستند و از آن جا که این مناطق نشان‌دهنده‌ی عدم شرایط مناسب جهت تغذیه و ورودی آب به سفره‌های زیرزمینی است، در نتیجه استفاده و برداشت از این منابع توازن بین ورودی و خروجی سفره‌های آب زیرزمینی را برهم می‌زند و میزان برداشت بیشتر از میزان ورودی خواهد بود. بنابراین حفر چاه در این مناطق می‌تواند صدمات و پیامدهای ناشی از افت سطح آب سفره‌های زیرزمینی (از جمله: کاهش منابع آب زیرزمینی، کاهش آب‌دهی و تغییر محل و کف شکنی مکرر چاه‌های موجود، فرو نشست زمین و کاهش ظرفیت حجم مخزن طبیعی، افت کیفی منابع آب و شور شدن آن‌ها و آسیب‌ها و هزینه‌های فراوان بر سازندها می‌شود نهایتاً خشک شدن قنات) را داشته باشد. با توجه به اینکه در استان لرستان برداشت بی‌رویه منابع آب‌های زیرزمینی و وجود چاه‌های غیرمجاز وضعیت این منابع رو را بغرنج کرده و افت سریع‌تر سطح آبخوان‌ها را در برخی از دشت‌ها (کوه‌دشت و رومشگان) سبب شده است به گونه‌ای که این دشت‌ها جزء دشت‌های ممنوعه قرار گرفته‌اند و هر لحظه امکان فرونشست زمین در این دشت‌ها وجود دارد با توجه به این وضعیت بحرانی ۵ دشت دیگر لرستان منجمله خرم‌آباد در دستور کار ممنوعه شدن قرار گرفته‌اند که در صورت عدم همکاری مردم و مسئولین ممنوعه اعلام خواهند شد و این وضعیت بسیار نگران کننده است و نگرانی زمانی بیشتر به چشم می‌آید که اقتصاد مردم لرستان بر پایه کشاورزی و آن هم سنتی است چنانچه این روند (کاهش شدید ذخایر آب‌های زیرزمینی) ادامه پیدا کند مرگ اقتصاد لرستان را شاهد خواهیم بود. در نتیجه مدیریت و برنامه‌ریزی صحیح در کنترل منابع آب زیرزمینی در استان الزامی است. در نهایت پتانسیل بالای هر منطقه در گسترش و توسعه آینده آن نقش کلیدی ایفا خواهد کرد و با شناسایی این مناطق علاوه بر اینکه امکان ایجاد بهره‌برداری بهینه و مدیریت صحیح فراهم می‌شود می‌توان بسترهای مناسب برای تغذیه مصنوعی آن‌ها رو شناسایی کرد و با استفاده از راهکارها (آب باران، سیلاب‌ها) و ابزارهای گوناگون (احداث سدهای زیرزمینی، پخش آب، رودخانه و...) اقدام به شارژ آن‌ها کرد.

## منابع

- Aliyari, H. (1376). Geomorphology of Khorramabad river basin (north of Khorramabad) with emphasis on the problem of erosion. Master's thesis of the Department of Geography, Faculty of Earth Sciences.
- Alizadeh, A. (1389), Principles of applied hydrology, 31st edition, Imam Reza University Press, Mashhad.
- Alshehhi.R., Reddy Marpu. P., Woonan.W.L., Dalla Mura. M.(2017). Simultaneous extraction of roads and buildings in remote sensing imagery with convolutional neural networks.ISPRS Journal of Photogrammetry and Remote Sensing 130 (2017) 139–149.
- Amyar.A ., Modzelewski.R., Li.H., Ruan.S.(2020). Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation. Computers in Biology and Medicine 126, 104037.1-10.
- Asghari, f; Belvasi, I.(2017). Comparison of artificial neural network model with fuzzy logic model in landslide risk assessment (case study of Simre Chenar watershed), Quantitative Geomorphology Research, 7th year, No. 2, pp. 158-182.
- Bouaafia.S., Messaoud.S., Maraoui.A., Ammari.A.,C. Khriji.L., Machhout.M. (2021). Deep Pre-trained Models for Computer Vision Applications: Traffic sign recognition. 2021 18th International Multi-Conference on Systems, Signals & Devices (SSD'21).23\_28.
- Biranvand, N., Kikhaei, M., Mamani, R. (2021). Presenting a method in the field of revealing targets in satellite images using deep learning and with remote sensing and GIS approach. Geographical Quarterly of the Land, Scientific-Research, Year 18, Number 69, Spring 140. pp. 44-60
- Chen, W., Zhang, S., Li, R., Shahabi, H. (2018d). Performance evaluation of the GIS-based data mining techniques of bestfirst decision tree, random forest, and naïve Bayes tree for landslide susceptibility modeling. Science of The Total Environment 644, 1006–1018
- Deng, F. Deng, Z. Dan, L. Daqing, W. Duan, H. Xing, Z. (2016). Application of remote sensing and GIS analysis in groundwater potential estimation in west Liaoning Province, China. Journal of Engg Research ,4:(3), pp 1-17.
- Fallah, F., M. Daneshfar, S. Ghorbani Nejad (2016). Finding the potential of underground water resources in the study area of Khorram Abad using statistical index method. Journal of Water and Sustainable Development, 4(1): 89-98.
- G. Qi, H. Wang, M. Haner, C. Weng, S. Chen, Z. Zhu. (2019). Convolutional neural network based detection and judgement of environmental obstacle in vehicle operation, CAAI Trans. Intell. Technol. 4, 80–91
- Haji Azizi, M; Rahmani, M; Biglari, N (2013). finite element analysis of underground dams and important points in their design and implementation, case study: Abkhori underground dam in Semnan province, Journal of Modeling in Engineering, Year 12, No. 38, pp. 153-165.
- Jingxin.L., Mengchao.Z., Yuchen.L., Jinglei.C., Yutong.Z Zhong. Z.,Lihui.Z.(2021).COVID-19 lesion detection and segmentation–A deep learning method.Contents lists available at ScienceDirect Methods.1-8.
- Kazemi, M. Zamani Shorabi, A. (2016). Brain lesion tumor segmentation using convolutional neural network, Seyed Masoumi Forough | Kazemi Manouchehr Once Shurabi Abbas. National conference of 1420 vision and technological developments of electricity, computer and information technology, holding period: 1
- Lee, Saro. Song, K. Kim, Y. Park, I.(2012). Regional groundwater productivity potential mapping using a geographic information system (GIS) based artificial neural network model, Hydrogeology Journal, 8(20), pp1511–1527
- Manap, M. Nampak, H. Pradhan, B. Lee, S. Sulaiman, W. Ramli, M. (2012). Application of probabilistic-based frequency ratio model in groundwater potential mapping using remote sensing data and GIS. Arabian Journal of Geosciences, 7(2), pp 711-724.

- Mazzia, V., Khaliq, A., & Chiaberge, M.(2020). Improvement in land cover and crop classification based on temporal features learning from Sentinel-2 data using recurrent-convolutional neural network (R-CNN). *Applied Sciences*, 10(1), 238
- Nohani, A., A. Marufini, Kh. Khosravi.(2017). Evaluation of the abundance ratio method in determining the potential of underground water resources in Dasht al-Shatar, Lorestan province. *Iran Irrigation and Drainage Journal*, 1(12): 119-129.
- Sadaqat, M.(2017). *Land and Water Resources*, Payam Noor Publications
- Salla. R., Wilhelmiinab.H., Saric.K., Mikaelad.M., Pekkaa.M., Jaakko.M. (2018).Evaluation of the confusion matrix method in the validation of an automated system for measuringfeeding behaviour of cattle.*Behavioural Processes*.1-19.
- Seyed Masoumi, F., Kazemi, M., Zamani Shorabi, A.(2018). Brain lesion tumor segmentation using convolutional neural network, 1420 *Vision National Conference and Technological Advances in Electrical Engineering, Computer, Information Technology*, pp. 1-16
- Suganthi, S. Elango, L. Subramanian, S K. (2013). Ground- water potential zonation by Remote Sensing and GIS techniques and its relation to the Groundwater level in the part of Coastal the Arani and Koratalai River Basin. Southern India, *Earth Sci. Res. SJ*, 17(2), pp 87 – 95.
- Tahmasian, S., Z. Khani Temlia, c. Bahmanesh.( 2016). investigating the quality of underground water in Khorram Abad Plain. *Journal of Environmental and Water Engineering*, 3(4): 641-352.
- Talebi, L. (2014). Investigating flood risks in Khorramabad city. Master's thesis on urban hydrology and meteorology.
- Xu. H.,Yang. X., Wang.D., Hu.Y., Shi. Y., Cheng.Z., Liu.Z., Lu.Z., Shi.L., Liang.Z., Zhu.D.2022. Predicting groundwater potential assessment in water-deficient islands based on convolutional neural networks. *The Egyptian Journal of Remote Sensing and Space Sciences* 25 (2022) 1013–1023.
- Yamani, M; Alizadeh, Sh. (2013. potential exploration of underground water resources using AHP model (case study: Abadeh-Euclid Fars basin), *Hydrogeology Quarterly*, year 1, number 1, pp. 131-144.