



University of Tehran Press

ECO HYDROLOGY

Home Page: <https://ije.ut.ac.ir>

Online ISSN: 2423-6101

Using the deep learning approach to increase the efficiency of the alluvial aquifer vulnerability index (Case study: Coastal aquifer: Babol-Amol)

Hadis Karami¹ | Bahram Malekmohammadi^{2*} | Saman Javadi³

1. PhD student, Department of Environmental Engineering, Kish International Campus, Tehran University, Kish
2. Associate professor, Department of Environmental Planning and Management, University of Tehran, Email: malekb@ut.ac.ir
3. Associate Professor, Department of Water Engineering, College of Abouraihan, University of Tehran

ARTICLE INFO

Article type:
Research Article

Article History:
Received April 08, 2024
Revised May 17, 2024
Accepted June 17, 2024

Keywords:
*Optimization,
calibration,
correlation,
deep learning,
machine learning*

ABSTRACT

This research aims to evaluate the vulnerability of aquifers by comparing two approaches of deep learning and machine learning in index calibration. Therefore, by analyzing the inherent vulnerability of the Amol-Babol aquifer with the DRASTIC index, the sensitive areas of the aquifer were identified. The results of the vulnerability index showed that the northwestern part of the aquifer is more sensitive than other areas. Examining the correlation value between nitrate concentration as an effective index with the DRASTIC vulnerability index indicates a value of 24%, which indicated the need for recalibration. Therefore, with two CNN-Harris Hawks and LSTM-MPA methods as deep learning approaches, weighting and index ranks were carried out as decision variables with the aim of maximizing the correlation of nitrate concentration and vulnerability index. The results showed that the CNN-HHO method with a correlation of 0.62 is superior to the LSTM-MPA method with a correlation of 0.59. Vulnerability zones in the assessment conditions showed that the western and northeastern parts have higher vulnerability. On the other hand, the recalibrated weights and ranks indicate an increase in all weights and ranks in recalibration conditions compared to the initial conditions, which was determined after analyzing the optimization approaches.

Cite this article: Karami, H., Malekmohammadi, B. & Javadi, S. (2024). Using the deep learning approach to increase the efficiency of the alluvial aquifer vulnerability index (Case study: Coastal aquifer: Babol-Amol). *ECO HYDROLOGY*. 11 (2), 235-256. Doi: doi.org/10.22059/IJE.2024.373124.1801



© Hadis Karami, Bahram Malekmohammadi, Saman Javadi
DOI: <http://10.22059/IJE.2024.373124.1801>

Publisher: University of Tehran Press.



استفاده از رویکرد یادگیری عمیق در افزایش کارایی شاخص آسیب‌پذیری آبخوان آبرفتی (منطقه مورد مطالعه: آبخوان ساحلی آمل-بابل)

حدیث کرمی^۱ | بهرام ملک‌محمدی^{۲*} | سامان جوادی^۳

۱. دانشجوی دکتری، رشته مهندسی محیط‌زیست پردیس بین‌المللی کیش دانشگاه تهران، کیش
۲. دانشیار، دانشکده محیط‌زیست، دانشگاه تهران، تهران؛ رایانامه: malekb@ut.ac.ir
۳. دانشیار، گروه مهندسی آب، دانشکده فناوری کشاورزی ابوریحان، دانشگاه تهران، تهران

اطلاعات مقاله	چکیده
<p>نوع مقاله: پژوهشی</p> <p>تاریخ‌های مقاله: تاریخ دریافت: ۱۴۰۳/۰۱/۲۰ تاریخ بازنگری: ۱۴۰۳/۰۲/۲۸ تاریخ پذیرش: ۱۴۰۳/۰۳/۲۸</p> <p>کلیدواژه‌ها: بهینه‌سازی، واسنجی، همبستگی، یادگیری عمیق، یادگیری ماشین.</p>	<p>این تحقیق با هدف ارزیابی آسیب‌پذیری آبخوان‌ها با مقایسه دو رویکرد یادگیری عمیق و یادگیری ماشین در واسنجی شاخص انجام شده است. بر این اساس، با تحلیل آسیب‌پذیری ذاتی آبخوان آمل-بابل با شاخص DRASTIC پهنه‌های حساس آبخوان مشخص شد. نتایج شاخص آسیب‌پذیری نشان داد که بخش شمال غربی آبخوان نسبت به سایر مناطق دارای حساسیت بیشتری است. بررسی مقدار همبستگی بین غلظت نترات به‌عنوان یک شاخص تأثیرگذار با شاخص آسیب‌پذیری DRASTIC حاکی از مقدار ۲۴ درصد است که این مقدار نیازسنجی به واسنجی را نشان داد. بر این اساس، با دو روش CNN-Harris Hawks و LSTM-MPA به‌عنوان رویکردهای یادگیری عمیق، واسنجی وزن و رتبه‌های شاخص به‌عنوان متغیر تصمیم با هدف حداکثرسازی همبستگی غلظت نترات و شاخص آسیب‌پذیری انجام شد. نتایج نشان داد که روش CNN-HH با همبستگی ۰/۶۲ نسبت به روش LSTM-MPA با همبستگی ۰/۵۹ دارای برتری است. پهنه‌های آسیب‌پذیری در شرایط واسنجی نشان داد که بخش غربی و شمال شرقی دارای آسیب‌پذیری بیشتری است. از طرفی، وزن و رتبه‌های واسنجی شده حاکی از افزایش تمام وزن و رتبه‌ها در شرایط واسنجی نسبت به شرایط اولیه بوده که این موضوع پس از تحلیل رویکردهای بهینه‌سازی مشخص شد.</p>

استناد: کرمی، حدیث، ملک‌محمدی، بهرام، جوادی، سامان. (۱۴۰۳). استفاده از رویکرد یادگیری عمیق در افزایش کارایی شاخص آسیب‌پذیری آبخوان آبرفتی (منطقه مورد مطالعه: آبخوان ساحلی آمل-بابل). *اِقَد هیدرولوژی*، ۱۱(۲)، ۲۵۶-۲۳۵.

DOI: <http://doi.org/10.22059/IJE.2024.373124.1801>

© حدیث کرمی، بهرام ملک‌محمدی، سامان جوادی. ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <http://doi.org/10.22059/IJE.2024.373124.1801>



۱. مقدمه

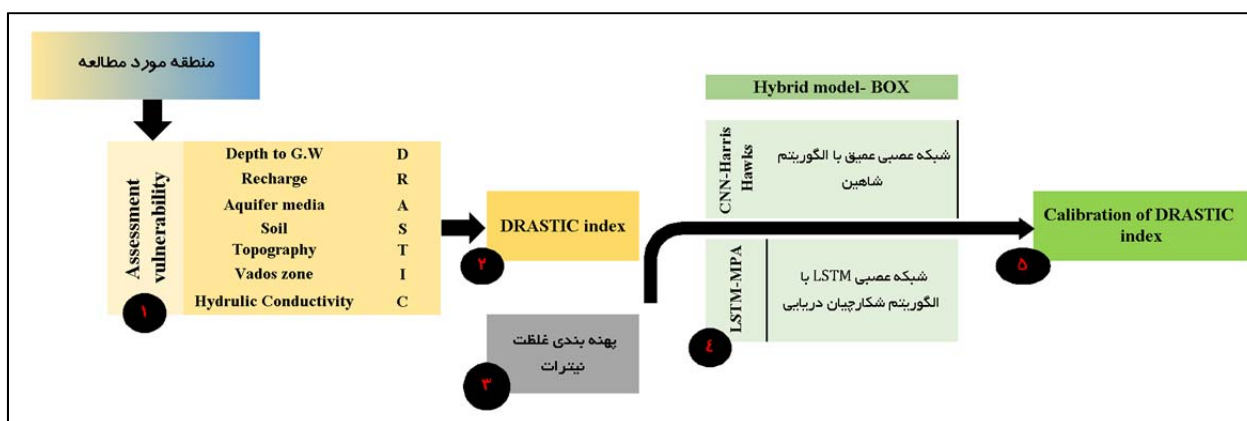
استفاده از رویکردهای مختلف برای واسنجی شاخص‌های آسیب‌پذیری در یک دهه اخیر، رشد شایانی داشته است. رابرت^۱ در سال ۲۰۰۱ با معرفی غلظت نیترات و نیتريت در آب زیرمینی به‌عنوان پارامتر مؤثر در شناسایی و بومی‌سازی شاخص دراستیک به‌عنوان اولین پیشگامان این حوزه است [۱]. بررسی مطالعات متعدد انجام‌شده در حوزه واسنجی آسیب‌پذیری نشان داده که اگرچه از پارامترها و شاخص‌های کیفی برای این موضوع استفاده شده است، دقت استفاده از غلظت نیترات به‌عنوان پارامتر مؤثر همواره دارای برتری بوده است [۲-۱۰]. از طرفی نیز توسعه روش‌های آماری و کامپیوتری سبب شده تا از آن‌ها به‌عنوان ابزار واسنجی استفاده شود. استفاده از روش‌هایی نظیر تحلیل آماری غلظت نیترات [۱۱]، ویلکاکسون [۸]، تحلیل سلسله‌مراتبی [۱۲]، داده‌محور [۱۳]، مدل‌های عددی [۱۴]، هوش مصنوعی [۱۵]، یادگیری ماشین [۱۶] و... در سال‌های مختلف مورد استفاده قرار گرفته‌اند. در سال‌های اخیر، رویکردهای مدیریت حجم زیاد داده و علاقه به استفاده از لایه‌های پنهان برای تشخیص الگوهای مختلف سبب شده است تا روش‌های یادگیری عمیق رشد و توسعه یابد. این روش‌ها مبتنی بر متن‌کاوی، تشخیص داده‌ها و تصاویر، طبقه‌بندی و بازیابی مفاهیم گسترش یافته است [۲۸]. پس از توسعه و استفاده از روش‌های یادگیری ماشین، باتوجه به پیچیدگی بسیاری از مسائل، روش‌های یادگیری عمیق معرفی و به کار گرفته شد [۱۷]. روش‌های یادگیری عمیق به مدل‌های محاسباتی که از لایه‌های پردازشی چندگانه تشکیل شده‌اند، اجازه می‌دهد تا نمایش داده‌ها را با سطوح مختلف مورد آنالیز قرار دهد [۱۸]. هر دوی این روش‌ها برای به دست آوردن الگوریتم‌هایی برای پردازش داده‌ها و تصمیم‌گیری در مورد آن‌هاست و توسعه روش‌های یادگیری عمیق مبتنی بر سطح پیچیدگی و عمق به کارگیری الگوریتم‌ها تعریف می‌شود. در روش یادگیری ماشین، الگوریتم‌های ساده‌تر و با سطح پیچیدگی کمتر مورد استفاده قرار می‌گیرد؛ این الگوریتم‌ها با استفاده از آموزش داده‌شده قابلیت مناسبی را برای پردازش داده‌های جدید دارند. اما در روش‌های یادگیری عمیق، شبکه‌های عصبی پیچیده و با سطح لایه‌های زیاد با بهره‌گیری از الگوریتم‌های پیچیده‌تری تدوین می‌شود. این شبکه‌ها با استفاده از داده‌های آموزشی، به‌صورت خودکار مرحله آموزش را فرا گرفته و باعث می‌شود که مدل‌های پیچیده‌تری را برای پردازش داده‌های پیچیده‌تر فراهم سازد. روش‌های یادگیری عمیق شامل شبکه‌های عصبی پرسپترون چندلایه (MP^2)، شبکه‌های عصبی پیچشی (CNN^3)، شبکه‌های عصبی بازگشتی (RNN^4) و شبکه‌های عصبی مولد (GNN^5) تاکنون معرفی شده‌اند. هر یک از این شبکه‌ها برای استخراج ویژگی‌های مختلف از داده‌ها و برای حل مسائل مختلف، مورد استفاده قرار می‌گیرد. این مطالعه با به‌کارگیری رویکرد یادگیری عمیق به‌منظور واسنجی وزن و رتبه‌های شاخص آسیب‌پذیری دراستیک مورد استفاده قرار گرفته است. باتوجه به مطالعات مختلف در زمینه ارزیابی آسیب‌پذیری آبخوان و روش‌های واسنجی، تاکنون در یک آبخوان ساحلی با رویکرد مقایسه‌ای این نوع واسنجی انجام نشده است. هدف اصلی این مطالعه استفاده از روش‌های جدید یادگیری عمیق برای افزایش کارایی شاخص آسیب‌پذیری است.

۲. مواد و روش‌ها

۲.۱. روش پژوهش

باتوجه به هدف این پژوهش در ۵ گام برای دستیابی به آن، متدولوژی این پژوهش تدوین شد. پس از بررسی منطقه مورد مطالعه در گام اول، شاخص آسیب‌پذیری دراستیک با تلفیق ۷ لایه مورد نظر در محیط GIS محاسبه می‌شود [۱۹]. پس از محاسبه شاخص آسیب‌پذیری براساس حداکثرسازی همبستگی بین شاخص دراستیک و غلظت نیترات اندازه‌گیری‌شده توسط شرکت آب منطقه‌ای مازندران در آبخوان آمل-بابل با دو رویکرد یادگیری عمیق، واسنجی وزن و رتبه‌های شاخص آسیب‌پذیری محاسبه می‌شود و مورد آنالیز قرار می‌گیرد. در نهایت، رویکردی که بیشترین میزان دقت را در واسنجی شاخص آسیب‌پذیری از نظر شاخص‌های آماری دارد، برای تحلیل نقشه پهنه‌بندی آسیب‌پذیری آبخوان به کار برده می‌شود.

1. Rubert
2. Multilayer Perceptron
3. Convolutional Neural Networks
4. Recurrent Neural Networks
5. Generative Neural Networks



شکل ۱: مراحل انجام پژوهش



۲.۲. منطقه مورد مطالعه

وسعت کل محدوده مطالعاتی آمل-بابل ۱۶۷۶/۶۵ کیلومتر مربع است، که مساحت تفکیکی آن شامل کوه ۱۰۸۹/۸۲ کیلومتر مربع و دشت ۵۸۶/۸۳ کیلومتر مربع است. حداکثر ارتفاع در کوه ۳۶۸۵ متر و در دشت ۲۵ متر و حداقل ارتفاع در کوه ۳۸۵ متر و در دشت ۳۳- است. متوسط ارتفاع حوضه در کوه ۱۰۳۱ متر و در دشت ۳۲ متر است. این محدوده ساحلی دارای دو آبخوان آزاد و تحت فشار است که باتوجه به آماربرداری سراسری، حجمی بالغ بر ۵۵۰ میلیون متر مکعب از منابع آب زیرزمینی را مورد بهره‌برداری قرار می‌دهد. این حوضه دارای جهت شمالی- جنوبی و در عرض جغرافیایی ۲۵' ۵۲° تا ۵۵' ۵۲° و در طول جغرافیایی ۰۰' ۳۶° تا ۴۳' ۳۶° قرار گرفته است. آبخوان ساحلی بابل‌رود (آمل- بابل) باتوجه به پتانسیل بالای بهره‌برداری از پراهمیت‌ترین جلگه‌های استان مازندران است. این محدوده دارای بیش از ۷۰۰۰۰ حلقه چاه بوده که سالانه تخلیه بالغ بر ۵۵۰ MCM داشته و باتوجه به تغذیه مناسب از نظر نزولات آسمانی و جریانات سطحی، کسری MCM

۱/۴ را دارد. جهت جریان آب زیرزمینی مطابق جریانات سطحی و از جنوب به شمال بوده و بخش جنوبی این آبخوان جبهه‌های آب زیرزمینی یکی از عوامل تغذیه آبخوان است. در شکل ۲، موقعیت منطقه مورد پژوهش نمایش داده شده است.

۳.۲. شاخص آسیب‌پذیری

مفهوم آسیب‌پذیری در ۴ دهه اخیر در بیان پتانسیل‌سنجی آبخوان‌ها برای بهره‌برداری پایدار از نقطه‌نظر آلاینده‌ها و مباحث کیفی مطرح شده است. این مفهوم با ارائه شاخص آسیب‌پذیری در آبخوان آبرفتی در سال ۱۹۸۷ توسط آلر تعریف شد [۲۰]. نحوه بررسی و ارائه این شاخص از آن، باتوجه به پیوستگی و جامعیت دیدگاه به‌گونه‌ای بود که تا امروز در جایگاه یکی از مهم‌ترین شاخص‌ها در این موضوع به‌صورت کاربرد مورد تحقیق قرار گرفته است. این شاخص از ۷ پارامتر عمق آب زیرزمینی، تغذیه خالص آبخوان، نوع خاک، نوع آبخوان، محیط غیراشباع، شیب زمین و هدایت هیدرولیکی تشکیل شده است. عمق آب زیرزمینی براساس درون‌یابی داده‌های عمق ثبت‌شده در هر چاه مشاهده‌ای در منطقه محاسبه می‌گردد که می‌تواند مبتنی بر روش‌های قطعی یا زمین‌آماری باشد که با استفاده از روش اعتبارسنجی متقابل و تحلیل مکانی به یک پهنه مناسب برای این پارامتر دست یافت. باتوجه به ناهمگنی نتایج پهنه‌بندی در نهایت با روش کارشناسی، پهنه‌بندی عمق آب زیرزمینی انجام



شکل ۲: موقعیت آبخوان بابل-آمل در شمال ایران

گرفت. میزان تغذیه براساس میزان نفوذ، بارش و رواناب منطقه مورد تحلیل و زون‌های تغذیه محاسبه و تعیین می‌شود. این زون‌ها مبتنی بر جریان‌های طبیعی در سطح آبخوان تعریف و براساس استاندارد این شاخص رتبه‌دهی می‌شود. مقادیر اختصاص داده شده براساس بیلان منابع آب زیرزمینی منطقه، ارزیابی و صحت‌سنجی شده است. میزان نفوذ از بارش در هر منطقه، با مقدار آب برگشتی از مصارف و میزان نفوذ از جریان‌های سطحی برابر با مقدار تغذیه به آبخوان می‌شود. با استفاده از لوگ‌های حفاری در منطقه، سه پارامتر محیط آبخوان، خاک و محیط اشباع تحلیل، پهنه‌بندی و رتبه‌بندی می‌شود. معمولاً عمق دومتری از سطح زمین به‌عنوان خاک به‌عنوان لایه ابتدایی و مهم در ورود آلودگی و پس از آن محیط غیراشباع آبخوان تا سطح ایستابی و کل ضخامت آبرفت برای هر لوگ حفاری به‌عنوان لایه جنس آبخوان مورد آنالیز و رتبه‌دهی می‌شود. نتایج این بخش باتوجه به تحلیل سه بعدی آبخوان از نظر ساختار و جنس ارزیابی گردید. باتوجه به اهمیت این آبخوان، تعداد ۴۶ حلقه لوگ حفاری در این منطقه جمع‌آوری و مورد تحلیل قرار گرفت. تنوع مکانی این لوگ‌ها باتوجه به پراکنش مناسب، نتایج مناسبی را ایجاد کرده است. پهنه‌بندی انجام شده از تلفیق روش‌های زمین‌آماری و ریاضی با اعمال نظرات کارشناسی بهره گرفته است. با استفاده از نقشه مدل رقومی ارتفاعی (DEM) و استفاده از ابزارهای GIS، شیب منطقه تعیین و رتبه‌بندی می‌شود. با استفاده از تحلیل نتایج آزمایش پمپاژ و محاسبه قابلیت انتقال در آبخوان و با تقسیم این مقدار بر ضخامت آبخوان مقدار هدایت هیدرولیکی تعیین می‌شود. وزن و رتبه‌دهی پارامترهای شاخص آسیب‌پذیری دراستیک به صورت جدول (۱) تعیین می‌شود.

جدول ۱: وزن و رتبه‌های شاخص آسیب‌پذیری دراستیک

Depth G.W (m)		Recharge (mm)		Slope (%)		Hydraulic conductivity (m/day)		Aquifer media		Vados Zone		Soil	
Class	Rank	Class	Rank	Class	Rank	Class	Rank	Class	Rank	Class	Rank	Class	Rank
0.1-1.5	10	0-50.8	1	0-2	10	0.4-4.1	1	Volcanic rock	2	Confining layer	1	Gravel	10
1.5-4.6	9	50.8-101.6	3	2-6	9	4.1-12.3	2	Silt	3	Clay/Silt	3	Sand	9
4.6-9.1	7	101.6-177.8	6	6-12	5	12.3-28.7	4	Sandstone +shale	5	Shale	3	Pit	8
9.1-15.2	5	177.8-254	8	12-18	3	28.7-41	6	Sandstone	6	limestone	3	Sandy loam	7
15.2-22.8	3	>254	9	> 18	1	41-82	8	Conglomerate	8	Sandstone	6	Loam sandy	6
22.8-30.4	2					>82	10	Sand and Gravel	8	Sand and Gravel	8	Loam	5
> 30.4	1							Basalt	9	Basalt	9	Silt-clay	4
								Karst	10	Sand and clay	10	Clay loam	3
												Impact clay	2
												Non infiltration	1
5	Weight	4	Weight	1	Weight	3	Weight	3	Weight	5	Weight	2	Weight

پس از تهیه پارامترهای مورد نیاز برای ارزیابی آسیب‌پذیری به روش دراستیک، اقدام به تهیه نقشه آسیب‌پذیری شده است. هر یک از پارامترها در محیط GIS براساس یک پیکسل‌سایز یکسان تعیین و ارزش‌گذاری می‌شود. در نهایت با تلفیق این ۷ لایه براساس رابطه (۱) شاخص آسیب‌پذیری به دست می‌آید که در آن r ارزش کلاسه‌بندی شده هر پارامتر و w وزن هر یک از پارامترهاست.

$$\text{DRASTIC-Index} = D_r D_w + R_r R_w + A_r A_w + S_r S_w + T_r T_w + I_r I_w + C_r C_w \quad (1)$$

تقسیم‌بندی شاخص آسیب‌پذیری DRASTIC برای آبخوان به صورت جدول (۲) ارائه می‌شود.

جدول ۲: کلاس‌بندی آسیب‌پذیری براساس شاخص دراستیک

Class	DRASTIC Index
< 60	Ignore
60 - 119	Very low
119 - 139	Low
139 - 159	Medium
159 - 179	High
180 <	Very high

بررسی پارامترهای دربرگیرنده خصوصیات شاخص آسیب‌پذیری، مبتنی بر ذات یک آبخوان بوده و نقش عواملی نظیر کاربری اراضی و فعالیت‌های انسانی که مبتنی بر ذات آبخوان نیست، در آن مورد استفاده قرار نگرفته است. لذا برای ارزیابی شاخصی که مبتنی بر ذات آبخوان است، بایست پارامتری که بیانگر آلودگی ایجادشده یا پتانسیل آلودگی است استفاده شود. بر این اساس نیترا ت یکی از مهم‌ترین پارامترهای مورد آنالیز می‌تواند باشد. محاسبه این شاخص براساس میانگین وزنی مبتنی بر رتبه و وزن هر پارامتر مؤثر در شاخص آسیب‌پذیری محاسبه می‌شود و در نهایت مقدار نهایی شاخص بیانگر وضعیت آسیب‌پذیری است. وزن‌دهی و رتبه‌دهی پارامترهای این شاخص براساس استاندارد تعریف‌شده توسط آلر بوده که برای اولین بار در یکی از آبخوان‌های آبرفتی آمریکا مورد استفاده قرار گرفته است. بررسی مطالعات متعدد درخصوص استفاده از شاخص آسیب‌پذیری این نکته را حائز اهمیت می‌کند که این شاخص با تنوع ذات آبخوان در ۷ پارامتر تشکیل‌دهنده روبه‌رو بوده و عملاً نمی‌توان از وزن و رتبه‌های استاندارد در همه مناطق استفاده کرد. بررسی نتایج شاخص آسیب‌پذیری در مناطق خشک حاکی از کاهش اهمیت پارامترهایی نظیر عمق آب زیرزمینی و تغذیه بوده و در مناطق مرطوب این پارامترها از اهمیت بالاتری برخوردار است. همچنین تأثیر خصوصیات سازندگی آبخوان اعم از جنس آبرفت، جنس خاک و محیط غیراشباع در مناطق خشک باتوجه به خصوصیات خودپالایی و ضخامت معمولاً بیشتر در مناطق خشک از اهمیت و حساسیت بالاتری برخوردار است [۲۱-۲۶]. لذا اهمیت توجه به این موارد این نکته را حائز اهمیت می‌سازد که بایست رویکرد واسنجی در وزن و رتبه‌های شاخص آسیب‌پذیری اعم از هر نوع شاخص به‌منظور استفاده کاربردی به کار رود. روش‌های متعددی درخصوص واسنجی مطرح شده که امروز با توسعه فناوری و روش‌های مبتنی بر هوش مصنوعی رونق یافته است. علاوه بر سرعت و دقت، هزینه پایین در شبیه‌سازی این رویکردها باعث شده تا میزان کارایی این شاخص‌ها استفاده زیادی داشته باشد.

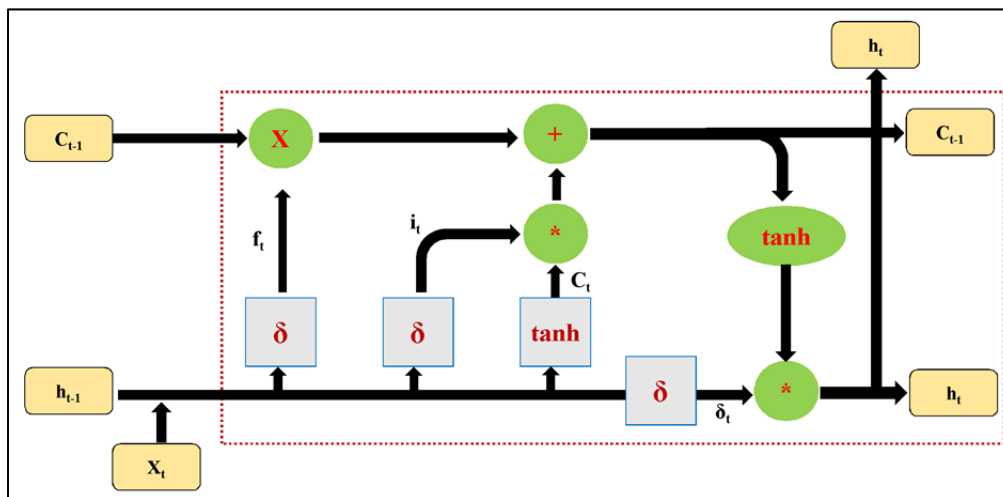
۲.۴. معرفی روش‌های یادگیری عمیق

روش‌های یادگیری عمیق به‌عنوان زیرمجموعه‌ای از روش‌های یادگیری ماشین مبتنی بر شبکه‌های عصبی مصنوعی تعریف می‌شود. واژه عمیق در این رویکرد به استفاده از چندین لایه در این نوع شبکه‌ها اشاره داشته که قابلیت استفاده نظارت‌شده، نیمه‌نظارت یا بدون نظارت را دارد [۹]. معماری‌های یادگیری عمیق مانند شبکه‌های عصبی عمیق، شبکه‌های باور عمیق، شبکه‌های عصبی مکرر، شبکه‌های عصبی کانولوشن و ترانسفورماتورها در زمینه‌هایی از جمله بینایی کامپیوتر، تشخیص گفتار، پردازش زبان طبیعی، ترجمه ماشینی، بیوانفورماتیک، طراحی دارو، تجزیه و تحلیل تصویر پزشکی استفاده شده است. شبکه‌های عصبی مصنوعی (ANN) از پردازش اطلاعات الهام گرفته شده و گره‌های ارتباطی را در سیستم‌های بیولوژیکی توزیع کردند. این شبکه‌ها تفاوت‌های مختلفی با مغزهای بیولوژیکی داشته و به‌طور خاص تمایل به رسیدن به حالت ایستا و نمادین داشته، درحالی که مغز بیولوژیکی بیشتر موجودات زنده پویا (پلاستیک) و آنالوگ است [۱۰]. بررسی‌ها نشان می‌دهد که به‌طور کلی سه نوع شبکه عصبی مصنوعی برای پردازش و تحلیل مورد استفاده قرار می‌گیرد: الف. شبکه‌های عصبی پیش‌خور (FF) که به‌عنوان ابتدایی‌ترین نوع شبکه به کار می‌روند. در این شبکه‌ها اطلاعات تنها در یک جهت از گره‌های ورودی به گره‌های خروجی جریان دارد. این شبکه‌ها برای کارهایی مانند طبقه‌بندی، رگرسیون و تشخیص الگو مورد استفاده قرار می‌گیرند؛ ب. شبکه‌های عصبی تکرارشونده (RNN) که دارای یک حلقه بازخورد هستند که به آن‌ها اجازه می‌دهد اطلاعات ورودی‌های قبلی را ذخیره کنند که آن‌ها را برای کارهایی مانند

پیش‌بینی توالی، مدل‌سازی زبان و تشخیص گفتار مناسب می‌کند؛ ج. شبکه‌های عصبی کانولوشنی (CNNs) که برای پردازش داده‌ها با توپولوژی شبکه‌ای مانند تصاویر و ویدئوها طراحی شده‌اند. در این شبکه‌ها از یک سری لایه‌های کانولوشن برای استخراج ویژگی‌ها از داده‌های ورودی استفاده می‌کنند و معمولاً برای تشخیص تصویر، تشخیص اشیا و تجزیه و تحلیل ویدئو استفاده می‌شوند.

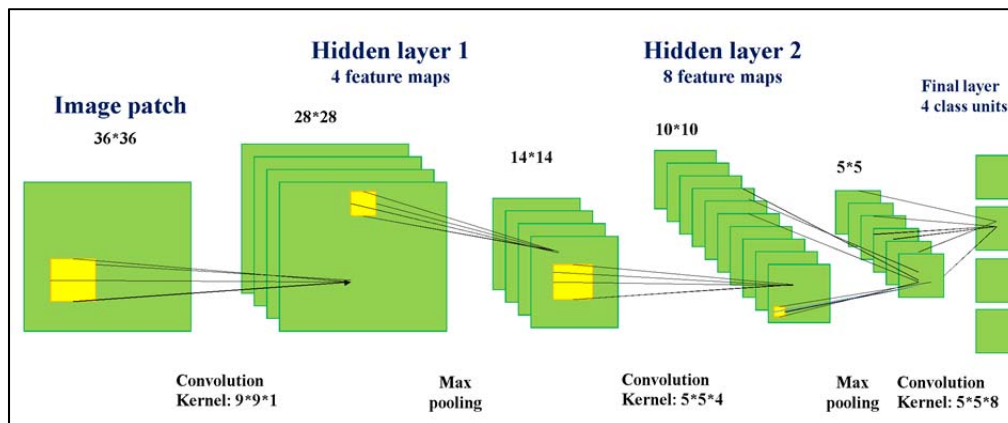
الف) شبکه عصبی پیش‌خور: این نوع شبکه، ابتدایی‌ترین نوع شبکه عصبی مصنوعی است که در آن اطلاعات تنها در یک جهت جریان دارد: از گره‌های ورودی به گره‌های خروجی تحت یک شبکه با مجموعه‌ای از نرون‌ها و بایاس‌ها. این شبکه‌ها برای کارهایی مانند طبقه‌بندی، رگرسیون و تشخیص الگو استفاده می‌شوند.

ب) شبکه عصبی تکرارشونده: این شبکه‌ها دارای یک حلقه بازخورد است که امکان ذخیره‌سازی اطلاعات ورودی‌های قبلی را فراهم می‌کند. در این شرایط این نوع شبکه برای کارهایی مانند پیش‌بینی توالی، مدل‌سازی زبان و تشخیص گفتار مناسب است. شبکه عصبی RNN نوعی شبکه عصبی است که حافظه داخلی داشته و این قابلیت را دارد که در ساختارش حلقه‌ای داشته باشد که از طریق آن در هر گام خروجی گام قبلی، به‌همراه ورودی جدید، به شبکه وارد گردد. این حلقه به شبکه کمک می‌کند تا اطلاعات قبلی را در کنار اطلاعات جدید داشته باشد و بتواند براساس این اطلاعات خروجی مد نظر را به دست آورد. این ویژگی شبکه این امکان را فراهم می‌سازد که با داده‌های ترتیبی^۱ مانند متن، صدا و... کار کند. در شکل ۳، ساختار شبکه LSTM به‌عنوان یک شبکه عصبی بازگشتی نمایش داده شده است.



شکل ۳: ساختار مدل LSTM

ج) شبکه عصبی کانولوشنی: این شبکه نوع خاصی از شبکه عصبی با چندین لایه است که داده‌های دارای آرایش شبکه‌ای را مورد پردازش قرار می‌دهد و براساس ویژگی‌های خاص تحلیل می‌کند. این شبکه عصبی دارای یک مزیت مهم بوده که نیاز به انجام پیش‌پردازش زیادی روی تصاویر نیست. در این شبکه، ویژگی فیلترها مورد آموزش قرار گرفته و چون به پارامترهای چندانی نیاز ندارد، صرفه‌جویی زیادی در وقت و عملیات آزمون و خطا انجام می‌گیرد. یک تفاوت بزرگ بین CNN و شبکه عصبی معمولی این است که CNNها برای مدیریت ریاضیات پشت صحنه، از کانولوشن استفاده می‌کنند. حداقل در یک لایه از CNN، به‌جای ضرب ماتریس از کانولوشن استفاده می‌شود. کانولوشن‌ها تا دو تابع را می‌گیرند و یک تابع را برمی‌گردانند. CNNها با اعمال فیلتر روی داده‌های ورودی شما کار کرده و می‌توانند فیلترها را هم‌زمان با فرایند آموزش تنظیم کنند. به‌این ترتیب، حتی وقتی مجموعه داده‌های عظیمی مانند تصاویر داشته باشید، نتایج به‌خوبی و در لحظه دقیق‌تر می‌شوند. مهم‌ترین ضعف این نوع شبکه، کمبود داده است که یکی از مشکلاتی است که مانع استفاده از CNN می‌شود. با وجود اینکه می‌توان شبکه‌ها را با تعداد داده نسبتاً کمی (تقریباً ۱۰,۰۰۰) آموزش داد، هرچه اطلاعات بیشتری در دسترس باشد، CNN بهتر تنظیم می‌شود. در شکل ۴، نمای ساختار CNN نمایش داده شده است.



شکل ۴: ساختار مدل CNN

۵.۲. رویکردهای یادگیری عمیقی

باتوجه به هدف این مطالعه، ارزیابی کارایی شاخص آسیب‌پذیری با رویکرد روش‌های مبتنی بر یادگیری عمیق مورد آنالیز قرار گرفته است. الف) شبکه عصبی عمیق با الگوریتم شاهین: در این نوع شبکه، خروجی مرحله قبل به عنوان ورودی در مرحله فعلی استفاده می‌شود. در واقع این نوع شبکه‌ها به علت حافظه داخلی خود می‌توانند موارد مهمی را در مورد ورودی دریافت‌شده به خاطر بسپارند که به آن‌ها اجازه می‌دهد در پیش‌بینی موارد بعدی مفید واقع شوند. یکی از جدیدترین و قوی‌ترین الگوریتم‌های بهینه‌سازی الگوریتم شاهین (HHO) است که در سال ۲۰۱۹ مطرح شد [۲۹]. این الگوریتم الهام‌گرفته از طبیعت و مبتنی بر جمعیت است که برگرفته از شکار خرگوش توسط شاهین هریس است. این الگوریتم نسبت به الگوریتم‌های دیگر کمی پیچیده‌تر است و از مراحل متفاوتی برای رسیدن به همگرایی استفاده می‌کند. روش شکار شاهین هریس شامل دو مرحله محاصره نرم و سخت است. در محاصره نرم، خرگوش هنوز انرژی کافی دارد و سعی می‌کند با پرش‌های گمراه‌کننده تصادفی فرار کند. شاهین‌ها به آرامی طعمه را احاطه می‌کنند تا بیشتر خسته شود؛ اما در محاصره سخت، طعمه کاملاً خسته است و انرژی فرار کمی دارد. شاهین‌های هریس به سختی طعمه را احاطه می‌کنند تا در نهایت ضربه غافلگیرکننده را تحویل دهند. در این الگوریتم، شاهین‌های هریس به صورت تصادفی برای یافتن طعمه حرکت می‌کنند و موقعیت آن‌ها با معادله تعیین می‌شود.

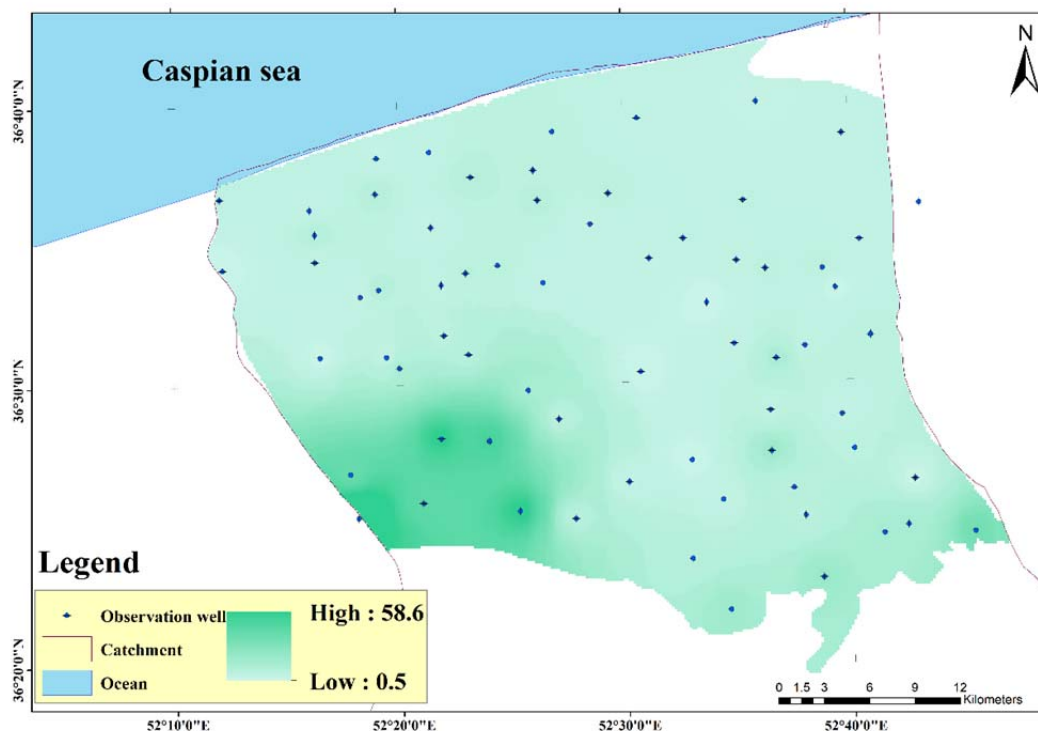
ب) شبکه عصبی LSTM با الگوریتم شکارچیان دریایی: روش شبکه عصبی مصنوعی بازگشتی عمیق، شبکه LSTM توسط Hochreiter و Schmidhuber در سال ۱۹۹۷ پیشنهاد شد [۳۰]. داده ورودی از طریق شبکه برای ایجاد یک پیش‌بینی انتشار داده می‌شود. این نوع شبکه یک نوع جدید از اتصالات بازگشتی دارد که سریع‌تر و آسان‌تر از سایر شبکه‌های عصبی سنتی در هنگام برخورد با مسائل پیش‌بینی توالی زمانی به راه‌حل بهینه همگرا می‌شود. نورون‌های RNN متفاوت از نورون‌های استاندارد، ساختار چرخه‌ای دارند و می‌تواند اطلاعات را از حالت قبلی به حالت فعلی انتقال دهند. هنگامی که اطلاعات ورودی یک سری زمانی است، می‌توان آن را به یک سری از نورون‌های استاندارد متصل متقابل گسترش داد. مشابه بیشتر روش‌های فراابتکاری، MPA^۲ روش مبتنی بر جمعیت است که در آن راه‌حل اولیه به عنوان اولین آزمون به طور یکنواخت در فضای جست‌وجو توزیع می‌شود. الگوریتم شکارچیان دریایی (MPA) پیشنهادی در سال ۲۰۲۰ توسط فرامرزی و همکاران از جدیدترین الگوریتم‌هاست که از رفتار شکارچی که می‌تواند از شکارچیان دریایی مانند کوسه، مارمولک‌های نظارتی، خورشیدماهی، اسب‌ماهی و اره‌ماهی و... باشد، الهام گرفته شود [۳۱]. این فرایند به سه مرحله اصلی بهینه‌سازی براساس نسبت‌های مختلف سرعت و درعین حال تقلید زندگی طبیعی شکارچیان و طعمه‌ها تقسیم می‌شود.

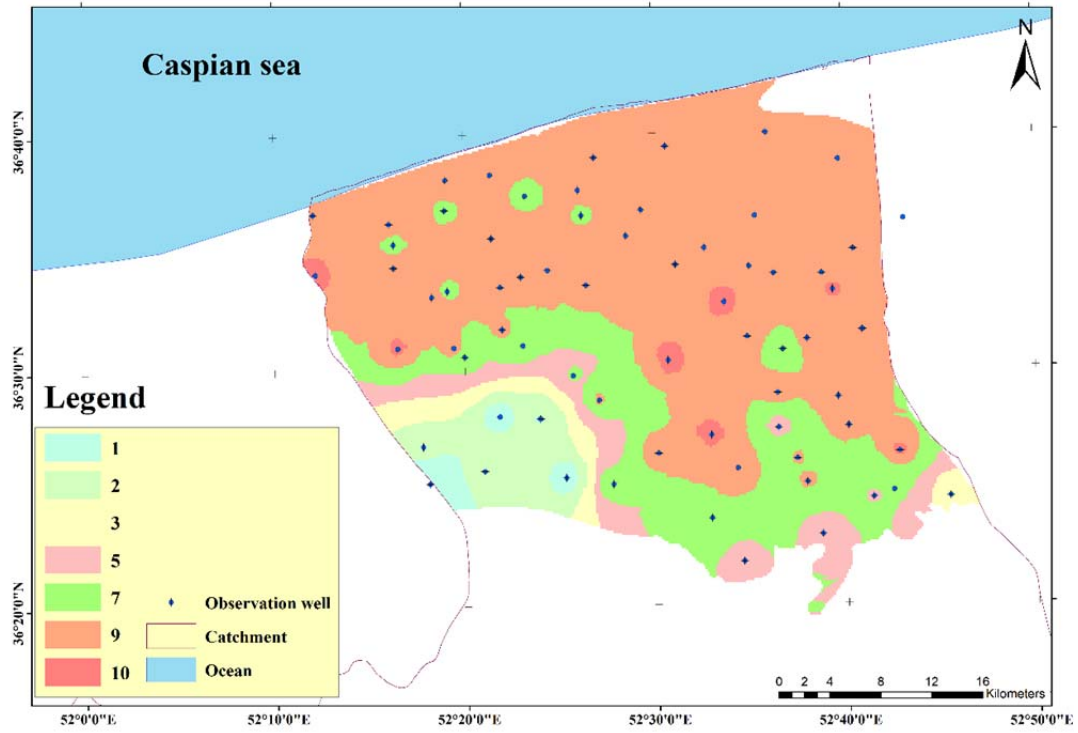
باتوجه به روش‌های در نظر گرفته شده برای واسنجی شاخص آسیب‌پذیری، هدف اصلی در بهینه‌سازی، دستیابی به حداکثر همبستگی بین شاخص آسیب‌پذیری و غلظت نیترات است. بر این اساس در هر الگوریتم، با تغییر وزن و رتبه به صورت هم‌زمان به عنوان متغیرهای تصمیم برای رسیدن به هدف معادله و حداکثرسازی همبستگی است. در تابع بهینه‌سازی شاهین با تغییر رتبه و وزن پارامترهای شاخص آسیب‌پذیری تعریف شده است؛ بدین گونه که در محاصره نرم، تغییر در وزن هر پارامتر و در محاصره سخت رتبه هر پارامتر تغییر و به سمت بهینه پیش می‌رود. در الگوریتم شکارچیان نیز با اعطای مقادیر حدی به وزن و رتبه‌ها به صورت حمله برای دستیابی به حداکثرسازی همبستگی انجام گرفت.

۳. نتایج و بحث

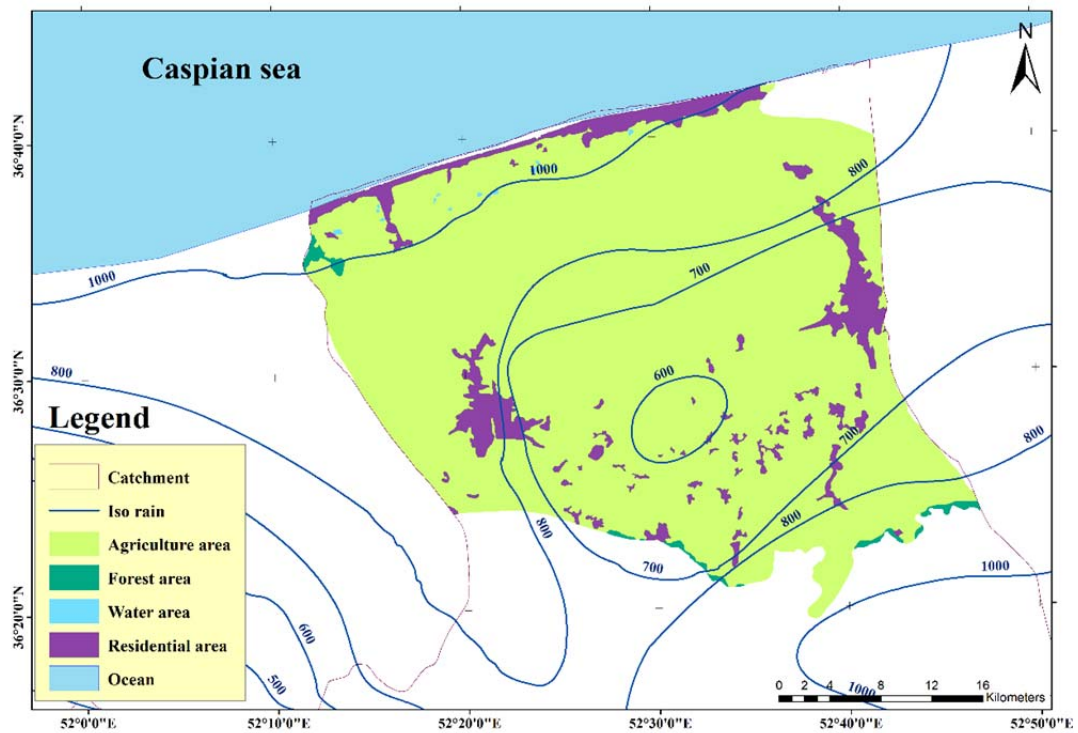
۱.۳. ارزیابی پارامترهای شاخص آسیب‌پذیری

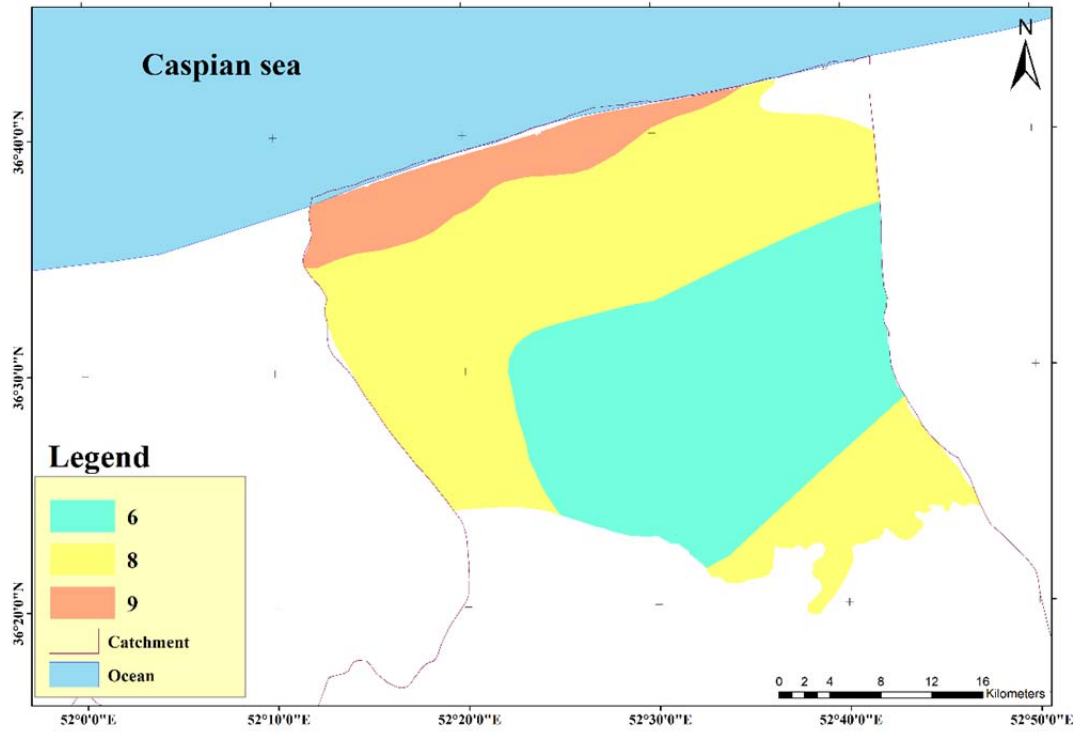
پس از بررسی منطقه مورد مطالعه براساس آخرین آمار ثبت‌شده برای چاه‌های مشاهده‌ای مربوط به شهریور ۱۴۰۲، پهنه‌بندی عمق آب زیرزمینی در آبخوان انجام شد. همچنین براساس جدول ۱، رتبه‌بندی آبخوان انجام گرفت. نتایج ارائه‌شده نشان داد که بخش نزدیک به ساحل دارای عمق کمتری نسبت به سایر مناطق آبخوان بوده و در رتبه ۱۰ قرار دارد. با فاصله از ساحل دریا میزان عمق آب زیرزمینی افزایش یافته و عملاً میزان رتبه اختصاص داده‌شده نیز کاهش یافته است. باتوجه به گرادیان بارش در منطقه که بخش ارتفاعات بیشترین میزان بارش و بخش منتهی به ساحل نیز دارای مقادیر بالاتری نسبت به کوهپایه‌هاست و از ظرفی وضعیت کاربری اراضی و نفوذپذیری خاک، میزان تغذیه آبخوان ناشی از فعالیت‌های طبیعی مورد ارزیابی قرار گرفته و در نهایت رتبه‌دهی این پارامتر در شاخص آسیب‌پذیری محاسبه گردید. بیشترین رتبه در پارامتر تغذیه آبخوان مربوط به بخش ساحلی و کمترین مقدار مربوط به بخش میانی آبخوان بود که با رتبه ۶ محاسبه شد. بخش ساحلی باتوجه به مقادیر بالاتر بارش نسبت به ارتفاعات و بالا بودن جریانات سطحی باتوجه به درشت‌دانه بودن این منطقه دارای بیشترین رتبه است. باتوجه به لوگ‌های حفاری و پهنه‌بندی جنس آن‌ها، سه پارامتر محیط آبخوان، خاک و محیط غیراشباع محاسبه شد. بر این اساس باتوجه به درشت و ریزدانه بودن ساختار آبرفتی، رتبه‌بندی این سه پارامتر انجام گرفت. تنوع بالای جنس خاک، محیط آبخوان و محیط غیراشباع در منطقه مشهود بوده که این موضوع باتوجه به تنوع رسوب‌گذاری و تغییرات ایجادشده توسط بشر به وجود آمده است. بخش‌های مرکزی آبخوان باتوجه به درشت‌دانه بودن ساختار دارای رتبه بالاتری در هر سه پارامتر است. با استفاده از نقشه‌های مدل رقومی ارتفاعی منطقه نیز نقشه شیب و به تبع آن رتبه‌بندی انجام گرفت. این آبخوان دارای شیب کمی بوده و در بیشتر محدوده در رتبه بالایی از نظر امتیازدهی قرار گرفت. هدایت هیدرولیکی آبخوان نیز باتوجه به نتایج آزمایش‌های پمپاژ و ضخامت آبخوان محاسبه و رتبه‌بندی آن انجام شد. بخش جنوب غربی آبخوان باتوجه به درشت‌دانه بودن و بالا بودن مقادیر قابلیت انتقال دارای مقادیر بالاتر هدایت هیدرولیکی است. در شکل ۵، پارامترهای شاخص آسیب‌پذیری دراستیک نمایش داده شده است.



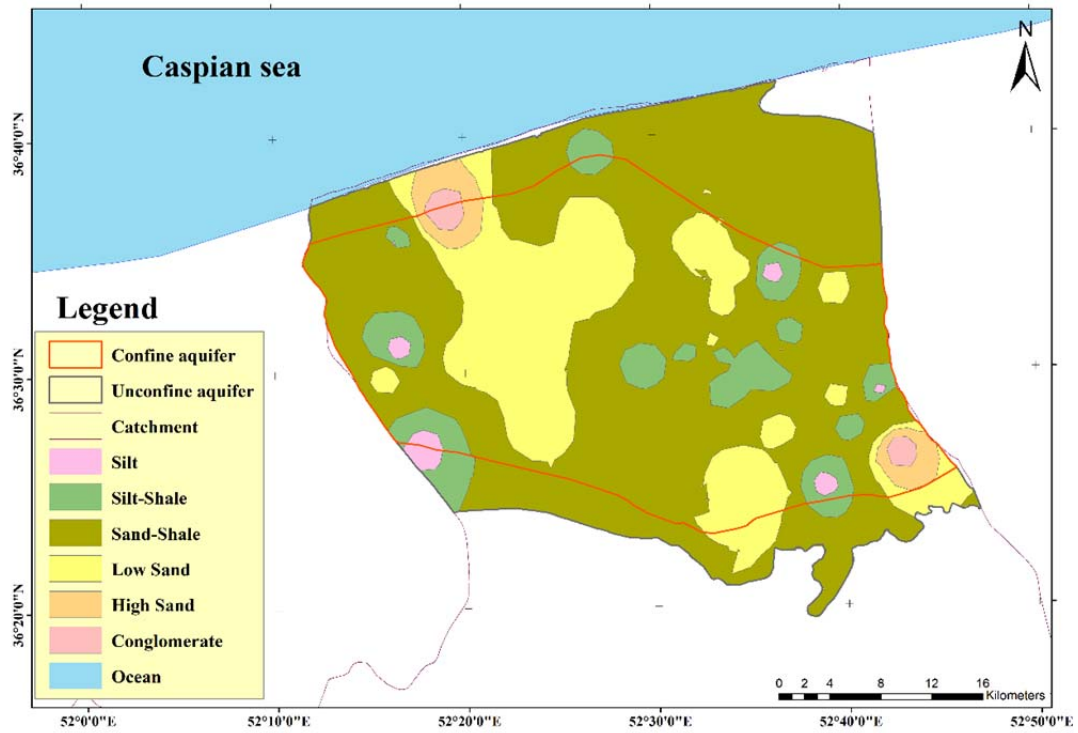


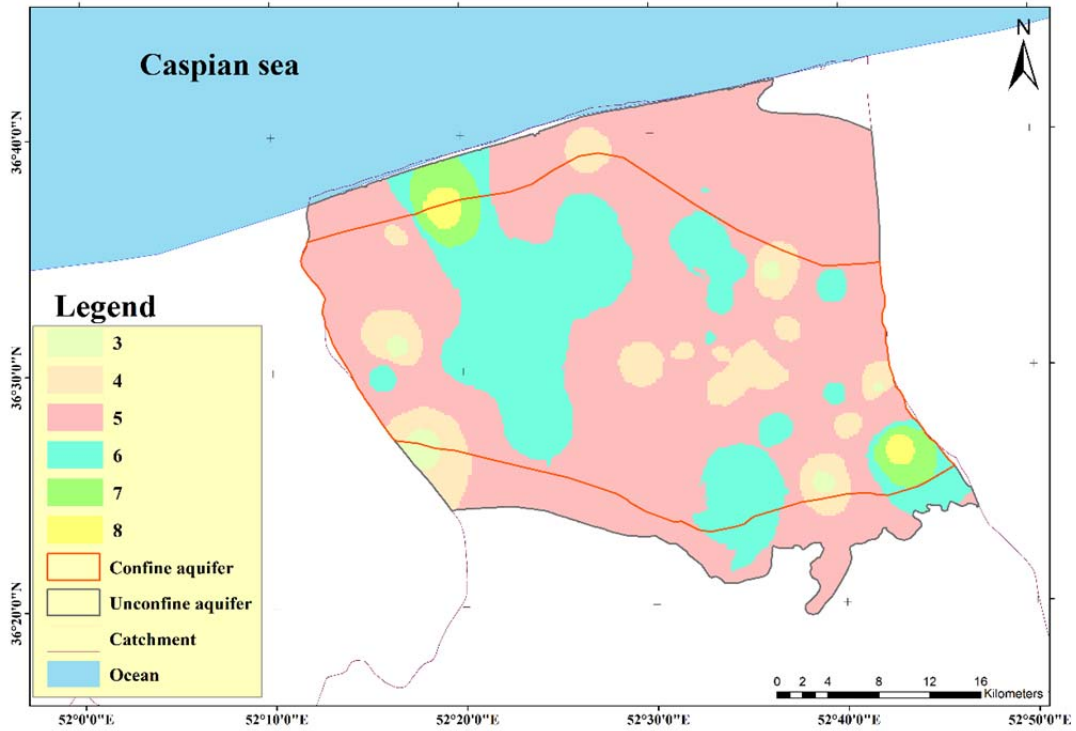
الف) عمق آب زیرزمینی



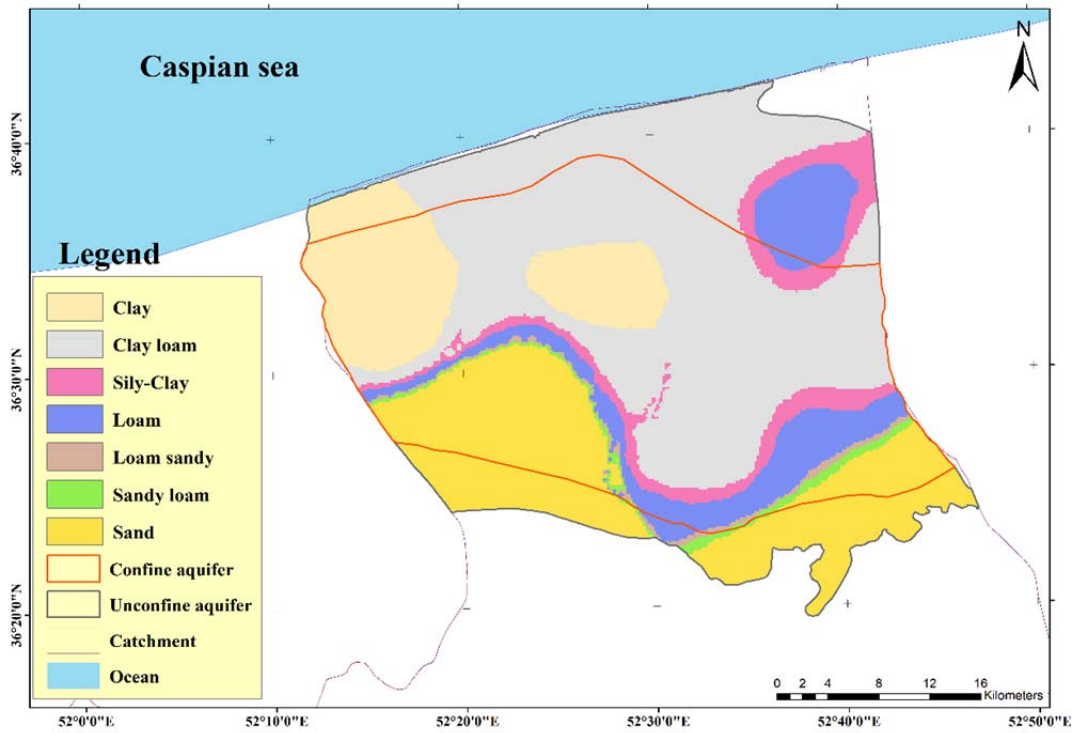


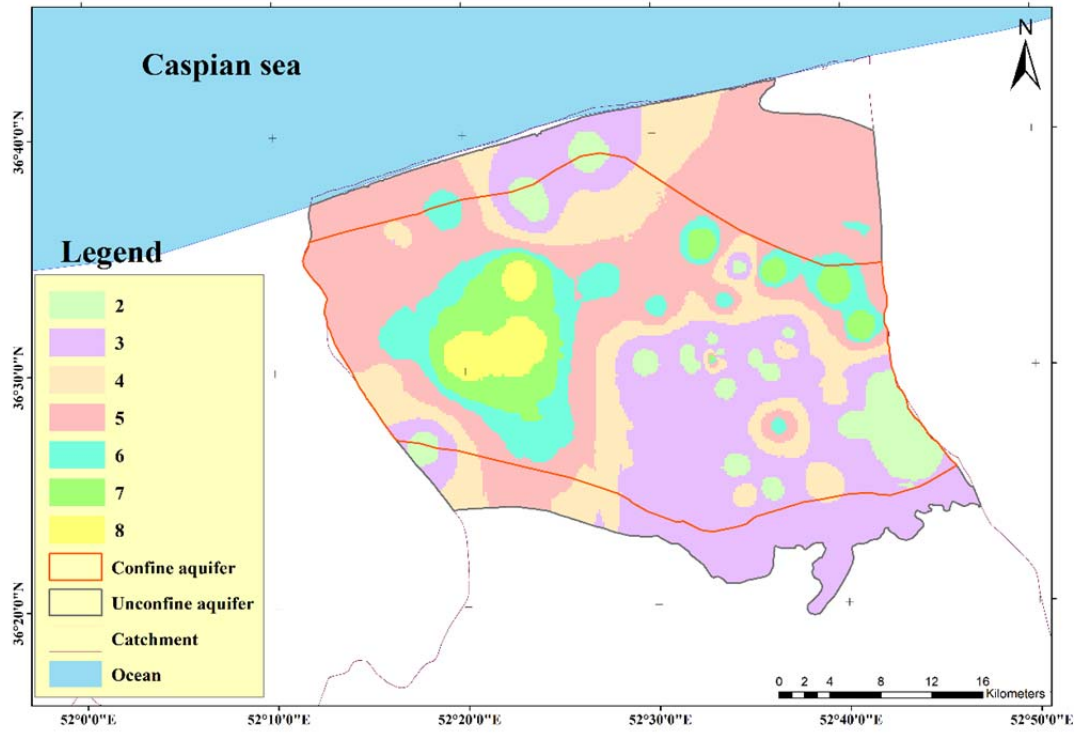
ب) تغذیه آبخوان



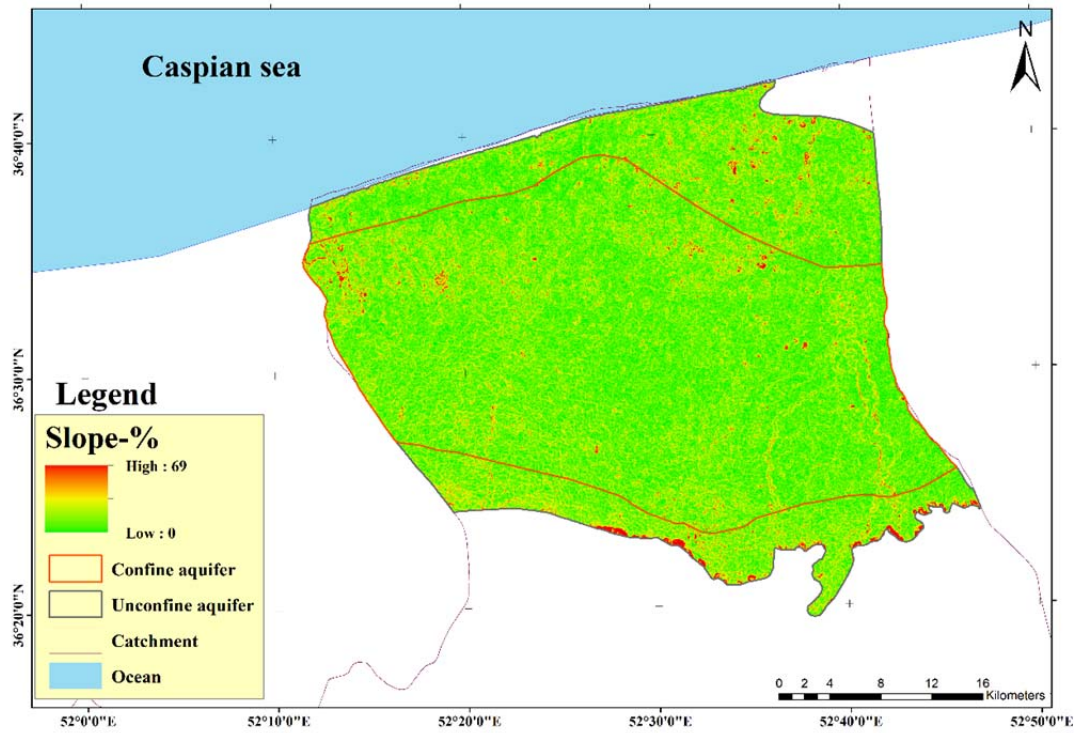


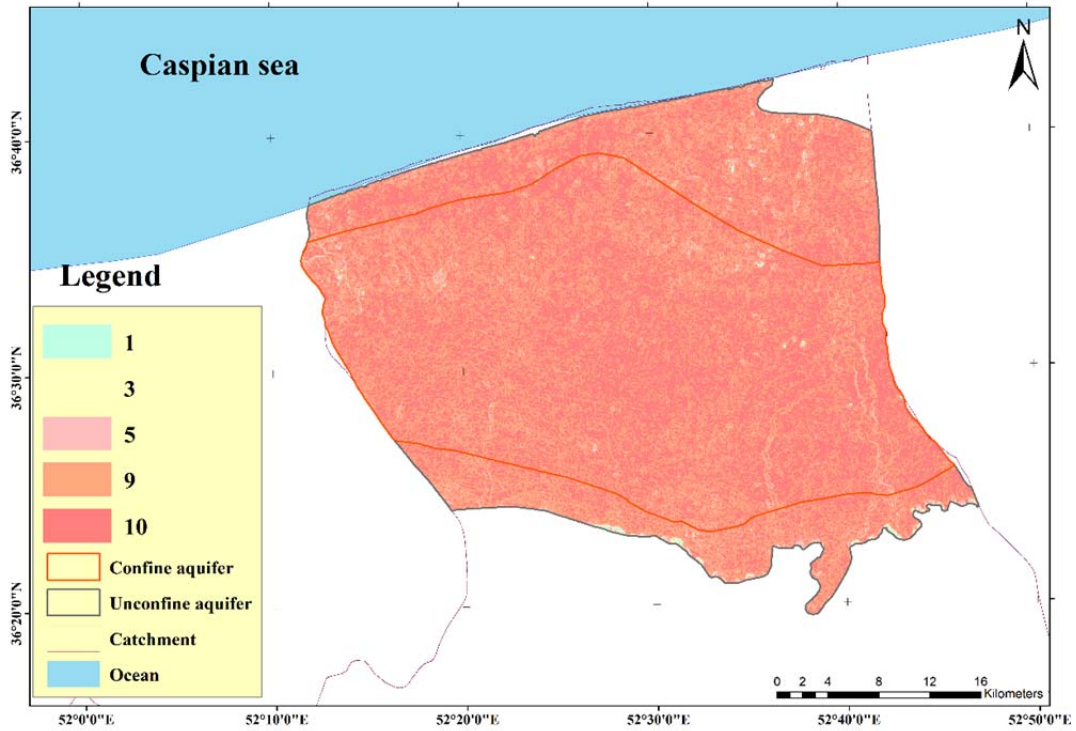
ج) جنس آبخوان



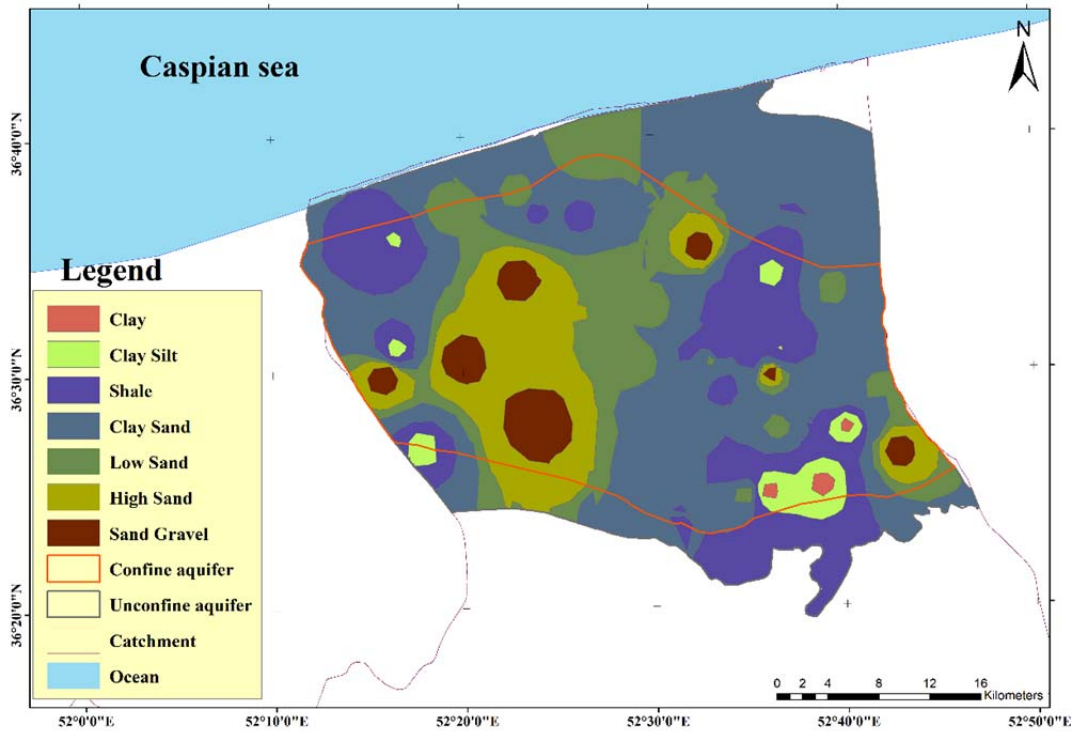


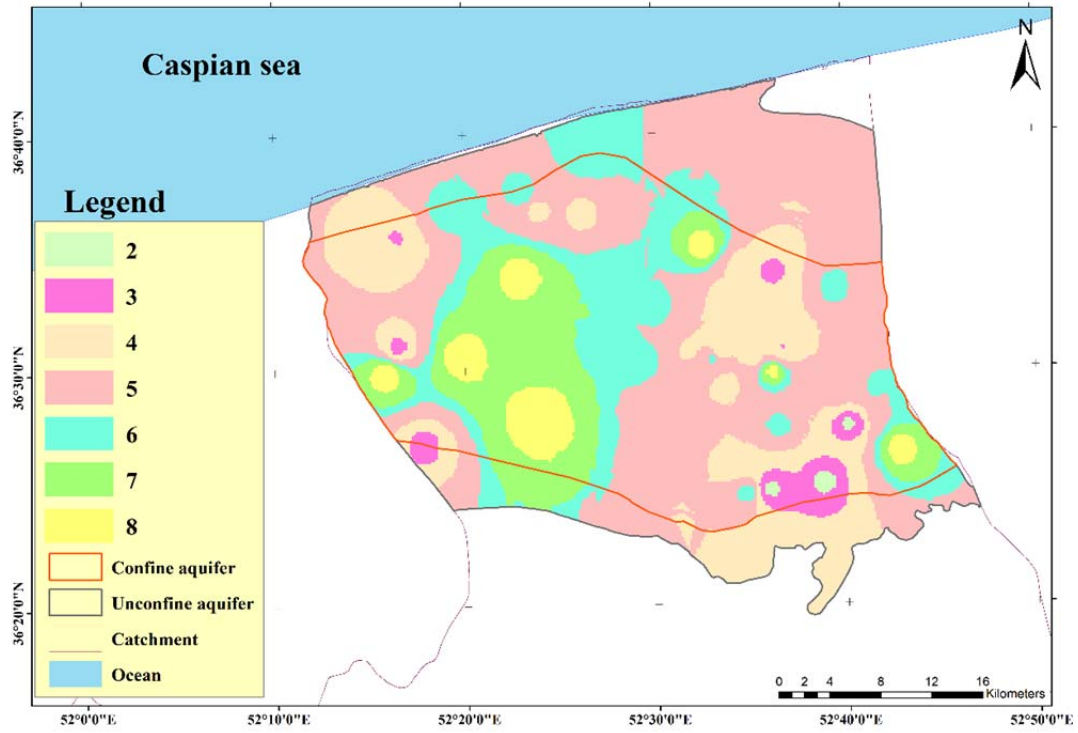
(د) جنس خاک



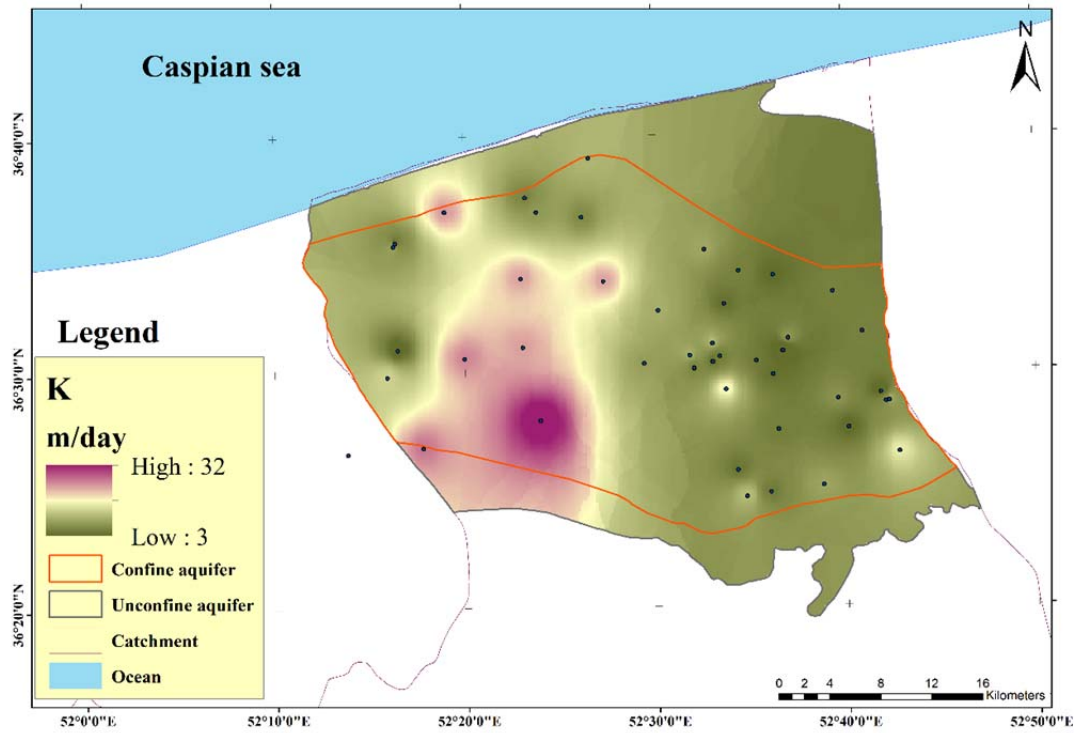


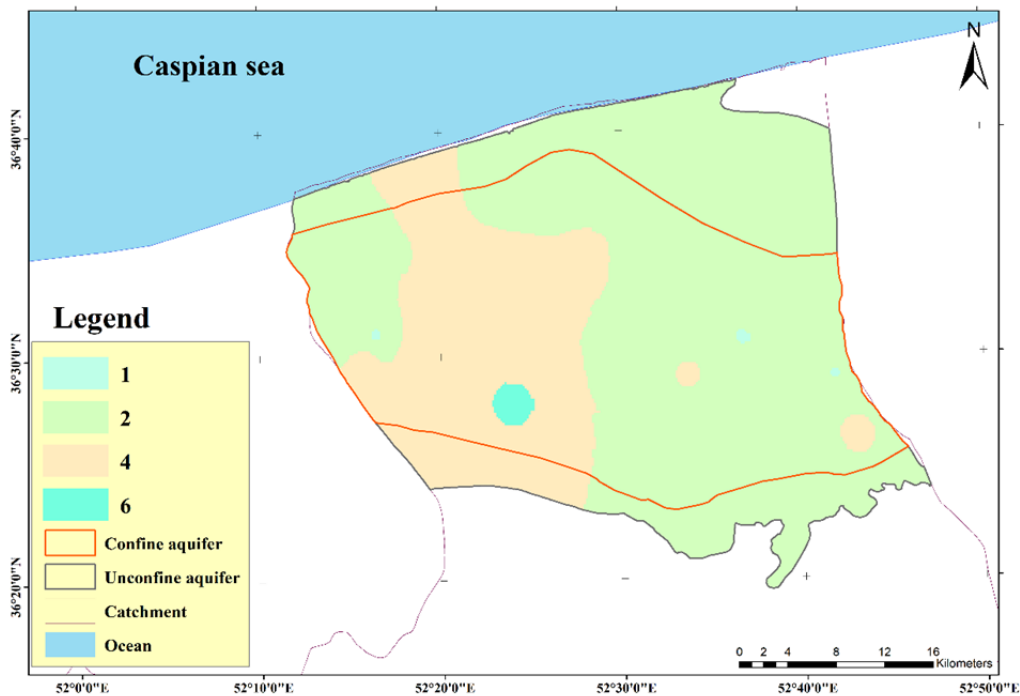
(ه) شیب منطقه





(و) محیط غیراشباع

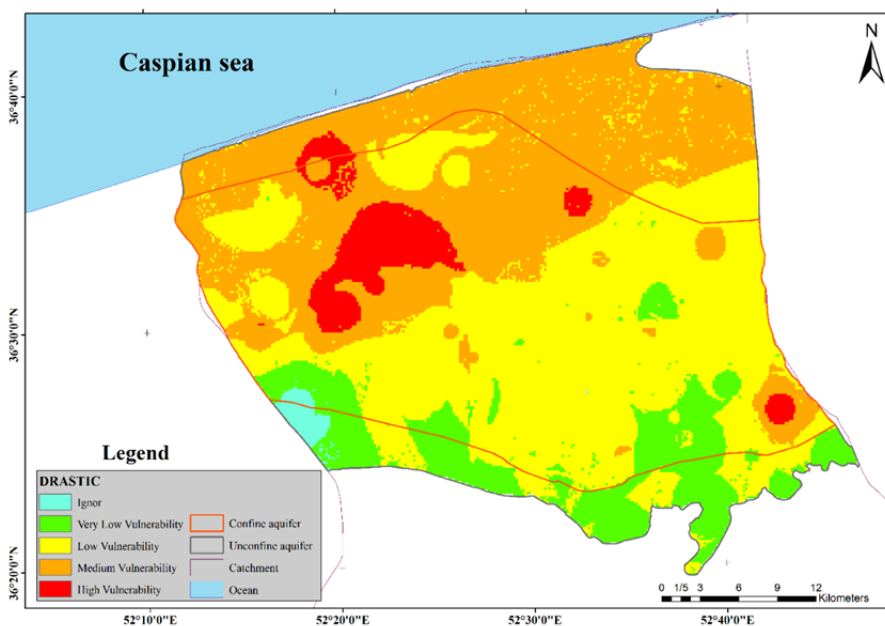




ز) هدایت هیدرولیکی

شکل ۵: پارامترهای شاخص آسیب پذیری دراستیک

باتوجه به نتایج به دست آمده از ۷ پارامتر، مقدار شاخص آسیب پذیری دراستیک در سطح آبخوان بابل-آمل مورد ارزیابی قرار گرفت. بررسی نتایج به دست آمده نشان داد که مقدار آسیب پذیری بین ۸۲ تا ۱۷۳ متغیر بوده و بخش شمال غربی نسبت به سایر مناطق دارای مقادیر بالاتری از نظر آسیب پذیری است. پهنه بندی و کلاس بندی آسیب پذیری نشان می دهد که ۴ منطقه آبخوان بابل-آمل دارای مقادیر آسیب پذیری بالایی بوده که سه منطقه آن منتهی به بخش غربی آبخوان بوده و تنها یک منطقه در بخش جنوب شرقی متمرکز است. بررسی مکانی این ۴ منطقه نشان داد که همبستگی بالایی بین جنس ساختار آبخوان با مقدار شاخص آسیب پذیری برقرار است. در شکل ۶، پهنه بندی آسیب پذیری در آبخوان بابل-آمل نمایش داده شده است. بیشترین سطح آبخوان در کلاس آسیب پذیری کم قرار داشته و کمترین کلاس مربوط به مناطقی است که قابلیت نادیده گرفتن مقدار آسیب پذیری را دارد. این مناطق علاوه بر جنس ریزدانه فاقد عمق بالای آب زیرزمینی نیز است.



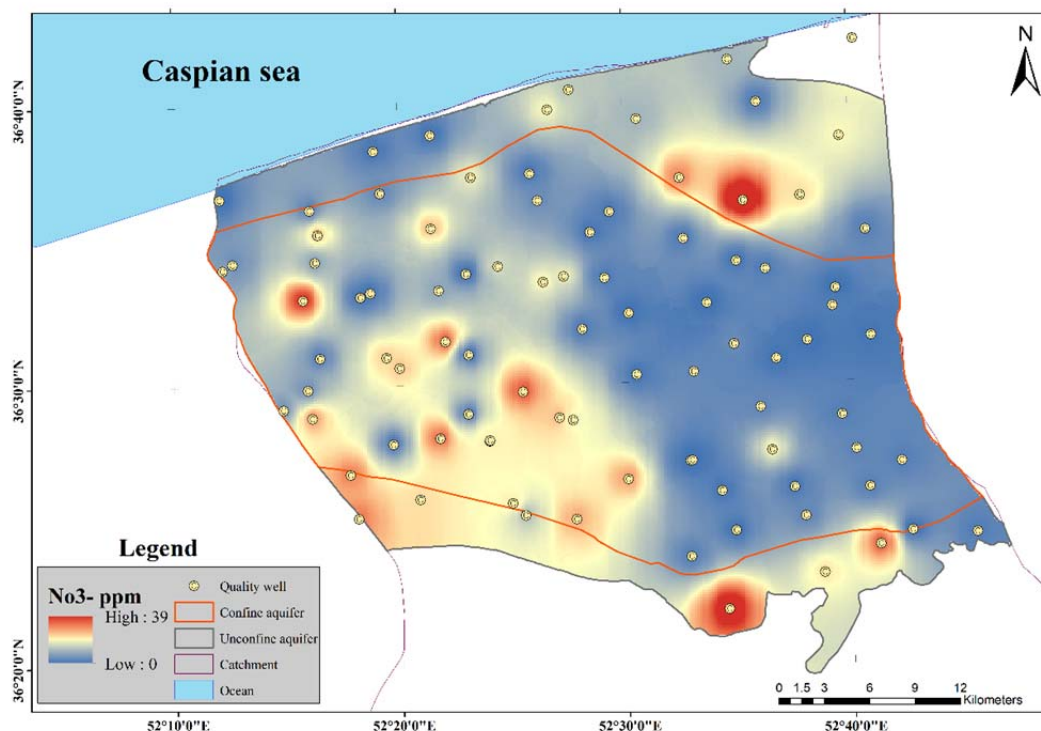
شکل ۶: پهنه بندی شاخص آسیب پذیری دراستیک در آبخوان بابل-آمل

۲.۳. تدوین مدل بهینه‌سازی با رویکرد هوش مصنوعی

یکی از رویکردهای جدید در واسنجی شاخص‌های کمی، استفاده از مدل‌های بهینه‌سازی مبتنی بر شاخص‌های آماری نظیر همبستگی است. بر این اساس به‌منظور واسنجی شاخص آسیب‌پذیری مبتنی بر دو متغیر تصمیم وزن و رتبه، تابع هدف حداکثرسازی همبستگی بین شاخص آسیب‌پذیری و غلظت پارامتری که نشان‌دهنده آلودگی است، باید برقرار گردد [۱۱]. باتوجه به بررسی پارامترهای مختلف کیفی و نزدیک بودن غلظت نیترات در منابع آب زیرزمینی به فعالیت‌های منتهی به آلودگی، از این پارامتر کیفی استفاده می‌شود. برای این مدل بهینه‌سازی نیز محدوده تغییرات وزن بین ۱ تا ۸ و رتبه‌های ۱ تا ۱۰ در نظر گرفته شد. بر این اساس، این رویکرد بهینه‌سازی با استفاده از روش CNN-Harris Hawks و LSTM-MPA مورد بررسی قرار گرفت و براساس نتایج به‌دست‌آمده آسیب‌پذیری مجدد پهنه‌بندی گردید.

۳.۳. پهنه‌بندی نیترات در آبخوان

باتوجه به اهمیت غلظت نیترات در شناسایی آلاینده‌های کیفی اعم از فعالیت‌های انسانی و کشاورزی، پهنه‌بندی کیفی این پارامتر کیفی در سطح آبخوان آبرفتی با استفاده از روش درون‌یابی Kriging و IDW انجام گرفت. درنهایت پهنه‌بندی انجام‌شده باتوجه به نظر کارشناسی مورد تدقیق قرار گرفت. در شکل ۷، پهنه‌بندی غلظت نیترات در سطح آبخوان بابل-آمل ارائه شده است.



شکل ۷: پهنه‌بندی غلظت نیترات در آبخوان بابل-آمل

بررسی نتایج پهنه‌بندی نیترات نشان می‌دهد که غلظت بالای نیترات در چند نقطه تا مرز ۴۰ میلی‌گرم در لیتر وجود دارد و این موضوع باتوجه به پراکنش بالای اراضی کشاورزی در این آبخوان الزاماً نمی‌تواند براساس فعالیت‌های کشاورزی در منطقه باشد و قطعاً نقش ذات آبخوان در آن مطرح است.

۴.۳. واسنجی شاخص آسیب‌پذیری دراستیک

بررسی اجمالی ارتباط بین شاخص آسیب‌پذیری و غلظت نیترات حاکی از وجود رابطه ضعیف از نظر همبستگی بوده لذا موضوع واسنجی شاخص آسیب‌پذیری بسیار حائز اهمیت است. باتوجه به تعریف دو رویکرد یادگیری عمیقی CNN-Harris Hawks و یادگیری ماشین LSTM-MPA، شبیه‌سازی برای دستیابی به حداکثر همبستگی بین غلظت نیترات و مقدار شاخص آسیب‌پذیری انجام شد. بر این اساس دو شبکه Raster تلفیق گردید و براساس ماتریس تعریف‌شده در محیط MATLAB بهینه‌سازی انجام شد. با تعریف محدودیت‌های انجام‌شده میزان وزن و رتبه‌های شاخص آسیب‌پذیری پس از اجرا مطابق جدول ۳ محاسبه شد.

جدول ۳: وزن و رتبه‌های واسنجی شده شاخص آسیب‌پذیری دراستیک

Parameters	Weight	Rank	Weight by CNN-HH	Weight by LSTM-MPA	Rank by CNN-HH	Rank by LSTM-MPA
D	5	1	6.75	6.42	4.5	4.2
		2			2.2	2.7
		3			3.1	3.5
		5			5.6	4.9
		7			7.1	6.8
		9			7.8	7.3
		10			8	7.9
		6			6.78	6.84
		8			8.62	8.52
		9			8.7	8.85
R	4	3	5.12	5.31	3.12	3.33
		4			4.11	4.18
		5			5.77	5.62
		6			6.34	6.41
		7			7.41	7.08
		8			8.05	8.17
		2			2.11	2.37
		3			3.23	3.18
A	3	4	3.57	3.87	4.86	4.72
		5			6.14	6.34
		6			6.47	6.78
		7			7.24	7.63
		8			7.93	8.14
		2			2.11	2.37
		3			3.23	3.18
		4			4.86	4.72
S	2	5	3.82	3.21	6.14	6.34
		6			6.47	6.78
		7			7.24	7.63
		8			7.93	8.14
		2			2.11	2.37
		3			3.23	3.18
		4			4.86	4.72
		5			6.14	6.34
T	1	1	2.74	2.61	2.5	2.7
		3			3.4	3.6
		5			5.6	5.7
		9			8.4	8.5
		10			8.8	8.9
I	5	2	5.78	5.23	2.2	2.12
		3			3.4	3.47
		4			4.14	4.17
		5			5.87	5.62
		6			6.48	6.34
		7			7.8	7.94
		8			8.45	8.61
		1			1.5	1.45
C	3	2	3.96	3.58	2.4	2.34
		4			6.1	5.8
		6			6.8	6.75

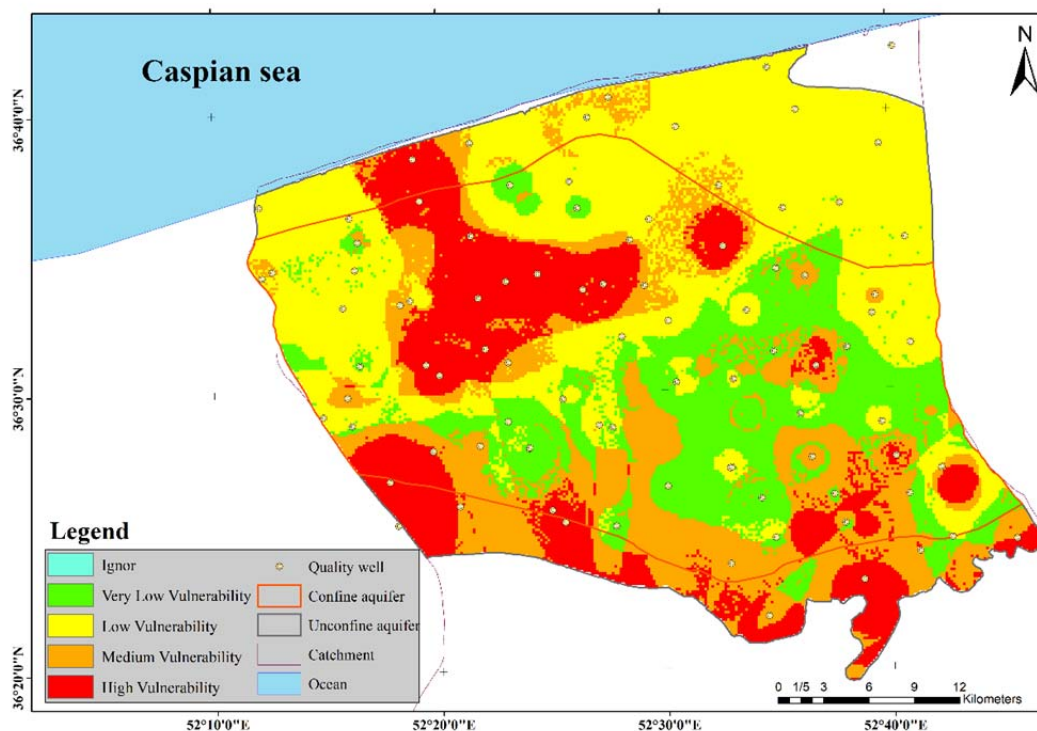
نتایج به‌دست‌آمده نشان داد که وزن هر ۷ پارامتر شاخص آسیب‌پذیری، در هر دو روش بهینه‌سازی افزایش داشته و بیشترین افزایش وزن مربوط به پارامتر عمق آب زیرزمینی است. بررسی نتایج مقایسه‌ای بین دو روش بهینه‌سازی نیز نشان داد که روند افزایش یا کاهش وزن و رتبه در پارامترهای مختلف به‌صورت یکسان بوده و هر دو روش در بهینه‌سازی تمایل به افزایش وزن و رتبه داشته‌اند. این افزایش وزن و رتبه باتوجه‌به همبستگی پایین شاخص آسیب‌پذیری و غلظت نیترات در شرایط اولیه در جهت افزایش میزان همبستگی در زمان بهینه‌سازی است. شرایط افزایش یا کاهش یکپارچه عملاً زمانی رخ می‌دهد که میزان پایین همبستگی برقرار بوده و طیف همه پارامترها در یک جهت باشد. بررسی هریک از ۷ پارامتر شاخص آسیب‌پذیری دراستیک نشان داد که همبستگی بالایی بین هر پارامتر و شاخص محاسباتی وجود ندارد؛ لذا

مدل بهینه‌سازی در هر دو روش نیز تمایل به افزایش داشته است. در جدول ۴، میزان همبستگی شاخص آسیب‌پذیری دراستیک و غلظت نیترات در آبخوان ارائه شده است.

جدول ۴: میزان همبستگی نیترات و شاخص‌های واسنجی شده در آبخوان

Parameters	Correlation		
	DRASTIC	DRASTIC-CNN	DRASTIC-LSTM
No ₃	0.24	0.62	0.59

نتایج همبستگی بین شاخص آسیب‌پذیری دراستیک و غلظت نیترات در آبخوان بابل-آمل نشان داد که میزان همبستگی با بهینه‌سازی وزن و رتبه‌ها بهبود داشته و از میزان ۰/۲۴ به ۰/۶۲ برای روش CNN_HH و ۰/۵۹ برای روش LSTM-MPA افزایش داشته است. بررسی موضوعی نشان می‌دهد که باتوجه‌به افزایش محاسبات روش شبکه عصبی کانولوشن میزان همبستگی بالاتری محاسبه شده اما درکل، میزان همبستگی هر دو روش بهبود و دارای کارایی مناسبی است. بر این اساس در شکل (۸) پهنه‌بندی واسنجی شده شاخص دراستیک براساس روش بهینه‌سازی CNN-Harris Hawks ارائه شده است. نتایج نشان داد که آسیب‌پذیری بالا در بخش‌های مختلف آبخوان متمایل به جنوب و غرب آبخوان است که ارتباط منطقی با کاربری اراضی کشاورزی و سکونتگاه‌های شهری و روستایی دارد.



شکل ۸: پهنه‌بندی شاخص آسیب‌پذیری دراستیک با روش CNN

۴. نتیجه‌گیری

این مطالعه در آبخوان ساحلی بابل-آمل که علاوه‌بر توسعه‌های شهری و صنعتی، یکی از مراکز کشاورزی در شمال کشور است، به‌منظور ارزیابی آسیب‌پذیری انجام شده است. بر این اساس با استفاده از شاخص آسیب‌پذیری DRASTIC پهنه‌بندی پتانسیل توسعه در منطقه انجام شد و نتایج به‌دست‌آمده نشان داد که بخش‌های شمال غربی نسبت به سایر مناطق، حساسیت بیشتری است. از طرفی نیز باتوجه‌به معرف بودن غلظت نیترات به‌عنوان پارامتر شناسایی آلاینده‌ها، همبستگی این پارامتر با شاخص آسیب‌پذیری حاکی از همبستگی بسیار پایین در ارتباط بوده است؛ لذا از رویکردهای واسنجی استفاده شد. بدین منظور از روش‌های نوین هوش مصنوعی مبتنی بر روش‌های یادگیری ماشین و یادگیری عمیق استفاده شد و واسنجی وزن و رتبه‌های شاخص آسیب‌پذیری با هدف افزایش دقت نتایج و شناسایی عرصه‌های حساس انجام گرفت. نتایج واسنجی نشان داد که میزان دقت روش‌های یادگیری عمیق نسبت به یادگیری ماشین برتری داشته و میزان همبستگی با

روش CNN-Harris Hawks برابر با ۰/۶۲ است. بررسی نتایج به دست آمده نشان داد که بخش‌های جنوب غربی آبخوان بابل-آمل دارای حساسیت بیشتری بوده و بخشی از این افزایش غلظت ناشی از توسعه کشاورزی و تمرکز جمعیت در این بخش از آبخوان بوده؛ اما باتوجه به نتایج به دست آمده قبل از واسنجی، ذات منطقه در افزایش غلظت نترات به صورت منطقه‌ای نیز وجود دارد. از طرفی نیز نتایج واسنجی وزن و رتبه‌های شاخص آسیب‌پذیری در هر دو روش CNN-Harris Hawks و LSTM-MPA حاکی از افزایش وزن و رتبه‌های واسنجی شده در هر ۷ پارامتر است. این افزایش همه پارامترها ناشی از این موضوع است که در حین بهینه‌سازی به دلیل پایین بودن میزان همبستگی شاخص و غلظت نترات و ارتباط پایین هر ۷ پارامتر با نترات سعی در بهبود وضعیت داشته که این عوامل باعث افزایش یا کاهش تمام وزن و رتبه‌ها می‌گردد که نتایج واسنجی در آبخوان بابل-آمل حاکی از افزایش بوده است. به طور کلی، نتایج به دست آمده نشان داد که علاوه بر کارایی بالای شاخص‌های آسیب‌پذیری، لزوم واسنجی و استفاده از ابزارهای جدید بسیار حائز اهمیت است. همچنین این موضوع در پهنه‌بندی توسعه مناطق و ارزیابی خطرهای احتمالی بسیار حائز اهمیت خواهد بود.

منابع

1. Rupert MG. Calibration of the DRASTIC ground water vulnerability mapping method. *Groundwater*. 2001 Jul; 39(4): 625-30.
2. Lasagna M, De Luca DA, Franchino E. Intrinsic groundwater vulnerability assessment: issues, comparison of different methodologies and correlation with nitrate concentrations in NW Italy. *Environmental earth sciences*. 2018 Apr; 77: 1-6.
3. Kazakis N, Voudouris KS. Groundwater vulnerability and pollution risk assessment of porous aquifers to nitrate: Modifying the DRASTIC method using quantitative parameters. *Journal of Hydrology*. 2015 Jun 1; 525: 13-25.
4. Huan H, Wang J, Teng Y. Assessment and validation of groundwater vulnerability to nitrate based on a modified DRASTIC model: a case study in Jilin City of northeast China. *Science of the total environment*. 2012 Dec 1; 440: 14-23.
5. Alikhani J, Deinhart AL, Visser A, Bibby RK, Purtschert R, Moran JE, Massoudieh A, Esser BK. Nitrate vulnerability projections from Bayesian inference of multiple groundwater age tracers. *Journal of Hydrology*. 2016 Dec 1; 543: 167-81.
6. Groenendijk P, Heinen M, Klammler G, Fank J, Kupfersberger H, Pisinaras V, Gemitzi A, Peña-Haro S, García-Prats A, Pulido-Velazquez M, Perego A. Performance assessment of nitrate leaching models for highly vulnerable soils used in low-input farming based on lysimeter data. *Science of the total environment*. 2014 Nov 15; 499: 463-80.
7. Hansen B, Sonnenborg TO, Møller I, Bernth JD, Høyer AS, Rasmussen P, Sandersen PB, Jørgensen F. Nitrate vulnerability assessment of aquifers. *Environmental Earth Sciences*. 2016 Jun; 75: 1-5.
8. Javadi S, Kavehkar N, Mohammadi K, Khodadadi A, Kahawita R. Calibrating DRASTIC using field measurements, sensitivity analysis and statistical methods to assess groundwater vulnerability. *Water international*. 2011 Oct 1; 36(6): 719-32.
9. Javadi S, Kardan Moghaddam H, Neshat A. A new approach for vulnerability assessment of coastal aquifers using combined index. *Geocarto International*. 2022 Mar 19; 37(6): 1681-703.
10. Kardan Moghaddam H, Rahimzadeh Kivi Z, Bahreinimotlagh M, Moghddam HK. Evaluation of the groundwater resources vulnerability index using nitrate concentration prediction approach. *Geocarto International*. 2022 Mar 19; 37(6): 1664-80.
11. Barzegar R, Asghari Moghaddam A, Norollahi S, Inam A, Adamowski J, Alizadeh MR, Bou Nassar J. Modification of the DRASTIC framework for mapping groundwater vulnerability zones. *Groundwater*. 2020 May; 58(3): 441-52.
12. Thirumalaivasan D, Karmegam M, Venugopal K. AHP-DRASTIC: software for specific aquifer vulnerability assessment using DRASTIC model and GIS. *Environmental Modelling & Software*. 2003 Sep 1; 18(7): 645-56.

13. Sorichetta A, Ballabio C, Masetti M, Robinson Jr GR, Sterlacchini S. A Comparison of Data-Driven Groundwater Vulnerability Assessment Methods. *Groundwater*. 2013 Nov; 51(6): 866-79.
14. Ameer M, Aouiti S, Hamzaoui-Azaza F, Cheikha LB, Gueddari M. Vulnerability assessment, transport modeling and simulation of nitrate in groundwater using SI method and modflow-MT3DMS software: case of Sminja aquifer, Tunisia. *Environmental Earth Sciences*. 2021 Mar; 80: 1-6.
15. Saida S, Tarik H, Abdellah A, Farid H, Hakim B. Assessment of groundwater vulnerability to nitrate based on the optimised DRASTIC models in the GIS environment (case of Sidi Rached Basin, Algeria). *Geosciences*. 2017 Mar 31; 7(2): 20.
16. Elzain HE, Chung SY, Senapathi V, Sekar S, Lee SY, Roy PD, Hassan A, Sabarathinam C. Comparative study of machine learning models for evaluating groundwater vulnerability to nitrate contamination. *Ecotoxicology and Environmental Safety*. 2022 Jan 1; 229: 113061.
17. Fu G, Jin Y, Sun S, Yuan Z, Butler D. The role of deep learning in urban water management: A critical review. *Water Research*. 2022 Sep 1; 223: 118973.
18. LeCun Y, Bengio Y, Hinton G. Deep learning. *nature*. 2015 May 28; 521(7553): 436-44.
19. Kardan Moghaddam H, Jafari F, Javadi S. Vulnerability evaluation of a coastal aquifer via GALDIT model and comparison with DRASTIC index using quality parameters. *Hydrological Sciences Journal*. 2017 Jan 2; 62(1): 137-46.
20. Aller L, Thornhill J. DRASTIC: a standardized system for evaluating ground water pollution potential using hydrogeologic settings. Robert S. Kerr Environmental Research Laboratory, Office of Research and Development, US Environmental Protection Agency; 1987.
21. Gharekhani M, Nadiri AA, Asghari Moghaddam A, Sadeghi Aghdam F. Optimization of DRASTIC model by support vector machine and artificial neural network for evaluating of intrinsic vulnerability of Ardabil plain aquifer. *Iranian journal of Ecohydrology*. 2015 Sep 23; 2(3): 311-24.
22. Jafari SM, Nikoo MR. Groundwater risk assessment based on optimization framework using DRASTIC method. *Arabian Journal of Geosciences*. 2016 Dec; 9: 1-4.
23. Khosravi K, Sartaj M, Tsai FT, Singh VP, Kazakis N, Melesse AM, Prakash I, Bui DT, Pham BT. A comparison study of DRASTIC methods with various objective methods for groundwater vulnerability assessment. *Science of the total environment*. 2018 Nov 15; 642: 1032-49.
24. Norouzi H, Moghaddam AA, Celico F, Shiri J. Assessment of groundwater vulnerability using genetic algorithm and random forest methods (case study: Miandoab plain, NW of Iran). *Environmental Science and Pollution Research*. 2021 Aug; 28: 39598-613.
25. Sadatipoor E, Noori R, Baghvand A, Javadi Pirbazari S, Kardan Moghaddam H. Application of DRASTIC Model for groundwater vulnerability assessment of the Ghaen Aquifer. *Journal of Environmental Science Studies*. 2016 Dec 20; 1(2): 63-71.
26. Taghavi N, Niven RK, Paull DJ, Kramer M. Groundwater vulnerability assessment: A review including new statistical and hybrid methods. *Science of the Total Environment*. 2022 May 20; 822: 153486.
27. Marblestone AH, Wayne G, Kording KP. Toward an integration of deep learning and neuroscience. *Frontiers in computational neuroscience*. 2016 Sep 14; 10: 215943.
28. Bordbar M, Rezaie F, Bateni SM, Jun C, Kim D, Busico G, Moghaddam HK, Paryani S, Panahi M, Valipour M. Global Review of Modification, optimization, and improvement models for Aquifer Vulnerability Assessment in the era of Climate Change. *Current Climate Change Reports*. 2023 Dec; 9(4): 45-67.
29. Heidari AA, Mirjalili S, Faris H, Aljarah I, Mafarja M, Chen H. Harris hawks optimization: Algorithm and applications. *Future generation computer systems*. 2019 Aug 1; 97: 849-72.
30. Baraldi L, Grana C, Cucchiara R. Hierarchical boundary-aware neural encoder for video captioning. *In Proceedings of the IEEE conference on computer vision and pattern recognition 2017* (pp. 1657-1666).

31. Faramarzi A, Heidarinejad M, Mirjalili S, Gandomi AH. Marine Predators Algorithm: A nature-inspired metaheuristic. Expert systems with applications. 2020 Aug 15; 152: 113377.