

مقایسه روش های شبکه عصبی و نروفازی برای بهبود چهار چوب عملی دراستیک (مطالعه موردی: آبخوان دشت شبستر)

فاطمه کدخدائی ایلخچی^۱، اصغر اصغری مقدم^{۲*}، رحیم بزرگر^۳، مریم قره خانی^۴

تاریخ دریافت: ۹۶/۰۷/۰۱

تاریخ پذیرش: ۹۷/۰۹/۲۵

۱-دانش آموخته کارشناسی ارشد هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز

۲-استاد، دانشکده علوم طبیعی، دانشگاه تبریز

۳-دانش آموخته دکتری هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز

۴-دانشجوی دکتری هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز

* مسئول مکاتبات، پست الکترونیکی: Moghaddam@tabrizu.ac.ir

چکیده

رشد روزافزون جمعیت و افزایش نیازهای آبی، استفاده از منابع آب شیرین بویژه منابع آب زیرزمینی را افزایش داده است. به همین جهت ارزیابی آسیب‌پذیری آب‌های زیرزمینی روشی مناسب برای شناخت مناطق آسیب‌پذیر و محافظت از این منابع به شمار می‌رود. دشت شبستر در استان آذربایجان شرقی یک منطقه فعال از نظر کشاورزی است و استفاده از منابع آب زیرزمینی در آن به علت کمبود منابع سطحی از اهمیت فوق‌العاده زیادی برخوردار است. در این مطالعه از چهار چوب عملی دراستیک برای ارزیابی آسیب‌پذیری آبخوان دشت شبستر استفاده شده است. مقدار شاخص آسیب‌پذیری دراستیک در منطقه مورد مطالعه برابر ۵۳/۳ تا ۱۱۸/۳ محاسبه شد. با توجه به اینکه ضرایب وزنی اختصاص یافته به هر پارامتر دراستیک، تا حدودی از روی نظر کارشناسی است بنابراین هدف اصلی این مطالعه بهبود دراستیک با دو مدل شبکه عصبی و عصبی فازی بوده است. ورودی‌های دراستیک به عنوان ورودی هر دو مدل هوش مصنوعی قرار داده شدند. شاخص دراستیک تصحیح شده با غلظت نیترات به عنوان خروجی مدل‌ها در نظر گرفته شد. مقادیر نیترات به دو دسته آموزش و آزمایش دسته‌بندی شد. پس از آموزش هر دو مدل، نتایج مدل در مرحله آزمایش با غلظت نیترات مورد ارزیابی قرار گرفت. نتایج نشان داد هر دو مدل هوش مصنوعی توانایی بالایی جهت بهبود مدل دراستیک دارند. با این وجود مدل عصبی فازی با داشتن ضریب همبستگی بالاتری با نیترات روشی مناسب جهت ارزیابی آسیب‌پذیری آبخوان دشت شبستر بوده است.

واژه‌های کلیدی: آب زیرزمینی، آسیب‌پذیری، بهینه‌سازی، دشت شبستر، شبکه عصبی، نروفازی.

Comparison of Neural Network and Neuro-Fuzzy Techniques to Improve the DRASTIC Frame Work (Case Study: Shabestar plain Aquifer)

F. Kadkhodaie Ilkhchi¹, A. Asghari Moghaddam^{2*}, R. Barzegar³, M. Gharehkhani⁴

Received: January 17, 2019

Accepted:

¹MSc. in Hydrogeology, Faculty of Natural Sciences, University of Tabriz, Iran

²Prof., Faculty of Natural Sciences, University of Tabriz, Iran

³Ph.D. in Hydrogeology, Faculty of Natural Sciences, University of Tabriz, Iran

⁴Ph.D. Student in Hydrogeology, Faculty of Natural Sciences, University of Tabriz, Iran

*Corresponding Author, Email: Moghaddam@tabrizu.ac.ir

Abstract

Increasing population and rising water requirements have raised the use of freshwater resources such as groundwater. Therefore, assessing the vulnerability of groundwater is a suitable method for identifying the vulnerable areas and protecting these resources. Shabestar plain in East Azarbaijan province is an active agricultural area and the use of groundwater resources in this plain is important due to the shortage of annual precipitation. In this study, the DRASTIC frame work was used to assess the vulnerability of the Shabestar plain aquifer. The amount of DRASTIC vulnerability index in the study area was calculated as 53.3 to 118.3. Given that the weights of the DRASTIC frame work were somewhat expert, so the main purpose of this study was improvement of the DRASTIC by two methods of Neural Network and Neuro-Fuzzy. DRASTIC inputs were introduced as inputs of the both artificial intelligence models. The corrected DRASTIC index with nitrate concentration was considered as the outputs of the models. Nitrate values were categorized into two groups of train and test. After training the model the results of the model were evaluated at the test step with nitrate concentration. The results showed that the both artificial intelligence models had the high ability to improve the DRASTIC model. Nevertheless, the neuro-fuzzy model having a higher correlation coefficient with nitrate was a suitable method for assessing the vulnerability of Shabestar plain aquifer.

Keywords: Groundwater, Neural Network, Neuro Fuzzy, Optimization, Shabestar Plain, Vulnerability

مقدمه

ای مطلق نمی باشد و شاخصی نسبی برای احتمال آلودگی در یک محل است. آسیب پذیری ذاتی به امکان آلودگی در یک منطقه بدون در نظر گرفتن آلاینده خاص اشاره دارد (آلماسری ۲۰۰۸). روش های مختلفی برای ارزیابی آسیب پذیری آب زیرزمینی وجود دارد. متداول ترین روش برای ارزیابی آسیب پذیری دراستیک می باشد. عمق آب زیرزمینی (D)، تغذیه خالص (R)، محیط آبخوان (A)، محیط خاک (S)، توپوگرافی (T)، تاثیر زون غیراشباع (I) و هدایت هیدرولیکی (C) پارامترهای موثر در این روش می باشند. با رتبه دهی و وزندهی به این عوامل شاخص دراستیک محاسبه می شود. هزینه اندک

منابع آب زیرزمینی به عنوان یکی از مهم ترین منابع آبی آسیب پذیر به شکل های مختلف در معرض آلودگی قرار دارند که تشخیص و کنترل آلودگی در آن ها نسبت به آب های سطحی پیچیده تر و پرهزینه تر است (قنبری و همکاران ۲۰۱۷). یکی از ابزارهای مناسب که کمک موثری به مدیریت آب های زیرزمینی می کند، تهیه نقشه هایی است که در آن ها مناطق آسیب پذیر مشخص شده باشند. مفهوم آسیب پذیری آب های زیرزمینی نخستین بار در اواخر دهه ۱۹۶۰ در فرانسه برای هشدار درباره ی آلودگی آب ارائه شد (وربا و زپرته ۱۹۹۴). آسیب پذیری آب های زیرزمینی مشخصه

و نیاز به داده‌های کم از جمله مزایای این روش‌ها به شمار می‌رود با این حال اعمال نظر کارشناسانه در تعیین وزن و رتبه‌ها ضعف عمده این روش‌ها می‌باشد (اصغری مقدم و همکاران ۲۰۱۵). در همین راستا روش‌های زیادی برای بهینه‌سازی وزن‌ها و رتبه‌های مدل‌های آسیب‌پذیری صورت گرفته است. به عنوان مثال پاناگوپولوس و همکاران (۲۰۰۶) جهت بهبود دراستیک از روش‌های آماری استفاده کرده‌اند. نشات و همکاران (۲۰۱۴) در ارزیابی آسیب‌پذیری آبخوان دشت کرمان از دراستیک بهبود یافته با استفاده از آزمون ناپارامتری ویلکوکسون بهره گرفته‌اند. آصفی و همکاران (۲۰۱۴) برای بهینه‌سازی دراستیک در ارزیابی آسیب‌پذیری آب‌زیرزمینی دشت اندیمشک از فرآیند تحلیل سلسله مراتبی استفاده کرده‌اند. مدل‌های هوش مصنوعی نیز روشی کارآمد در بهینه‌سازی چهارچوب عملی دراستیک به شمار می‌روند. دیکسون (۲۰۰۵) از مدل نروفازی برای ارزیابی آسیب‌پذیری آبخوان آرکانزاس در مقیاس منطقه‌ای استفاده کرده است. قنبری و همکاران (۲۰۱۷) از مدل‌های مختلف هوش مصنوعی مانند شبکه عصبی، منطق‌فازی و سیستم استنتاج تطبیقی عصبی-فازی برای بهبود دراستیک استفاده کرده‌اند. مهدوی و زارع آبیانه (۲۰۱۵) در تعیین پتانسیل آسیب‌پذیری آبخوان دشت همدان- بهار از مدل‌های دراستیک و منطق‌فازی بهره برده‌اند. همامین و ندیری (۲۰۱۸) از سه مدل فازی ساجنو، ممدانی و لارسن جهت بهبود دراستیک در ارزیابی آسیب‌پذیری آبخوان چندگانه حوضه بصره در عراق استفاده نمودند. ندیری و همکاران (۲۰۱۸ a) برای بهبود چهارچوب عملی دراستیک در ارزیابی آسیب‌پذیری آبخوان دشت اردبیل از روش‌های متنوعی استفاده نموده‌اند. نتایج

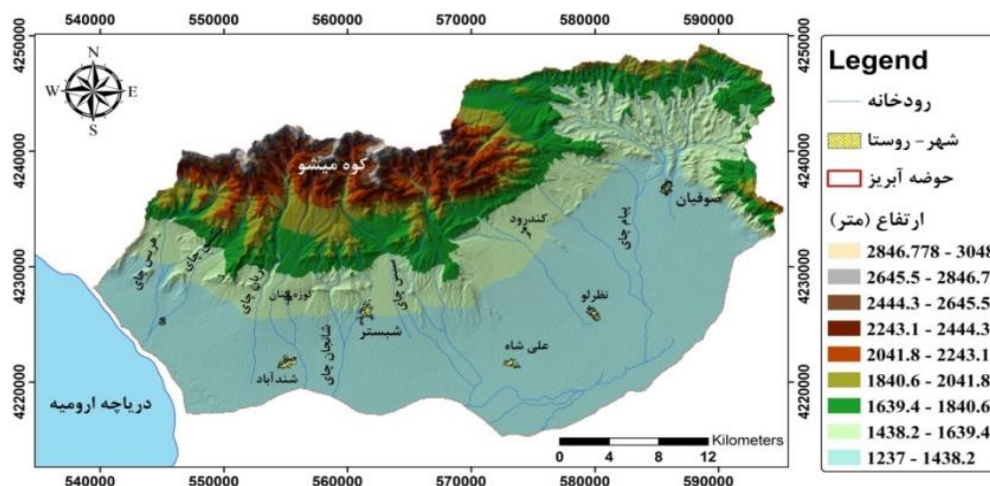
آنها نشان داد استفاده از هوش مصنوعی برای چهارچوب‌های چندگانه (AIMF) قادر بوده است ضریب همبستگی با نیترات را تا ۰/۸۴ افزایش دهد. ندیری و همکاران (b ۲۰۱۸) در ارزیابی آسیب‌پذیری آبخوان چندگانه ورزقان از دراستیک و کاتاستروف فازی استفاده کرده‌اند. و با روش ماشین بردار پشتیبان آسیب‌پذیری را به طور جداگانه برای آبخوان آزاد و تحت فشار ارزیابی نموده‌اند. نتایج آن‌ها نشان داد مدل ماشین بردار پشتیبان، ضریب همبستگی با نیترات را به مقدار زیادی افزایش داده است. کدخدائی و همکاران (۲۰۱۹) از روش‌های آماری و الگوریتم ژنتیک و ویلکوکسن به منظور بهبود دراستیک استفاده کرده‌اند نتایج آن‌ها نشان داد ترکیب روش الگوریتم ژنتیک و ویلکوکسن روشی مناسب برای بهبود مدل دراستیک بوده است. تمامی این مطالعات نشان داده‌اند بهبود چهارچوب عملی دراستیک توانسته است نتایج بهتری را برای ارزیابی آسیب‌پذیری آبخوان‌ها داشته باشد. دشت شبستر یکی از دشت‌های حاصل‌خیز استان آذربایجان شرقی می‌باشد که به دلیل اهمیت منابع آب زیرزمینی آن برای اهالی منطقه به منظور فعالیت‌های کشاورزی، صنعتی و شرب، شناخت مناطق آسیب‌پذیر آن حائز اهمیت می‌باشد. در این مطالعه از مدل‌های شبکه عصبی و نروفازی جهت بهینه‌سازی چهارچوب عملی دراستیک برای ارزیابی آسیب‌پذیری ذاتی آبخوان دشت شبستر استفاده شده است. بهینه‌سازی همزمان رتبه‌ها و وزن‌های چهارچوب عملی دراستیک به صورت همزمان، هدف اصلی این مطالعه می‌باشد.

مواد و روش‌ها

موقعیت جغرافیایی و هیدروژئولوژی منطقه مورد مطالعه

محدوده مطالعاتی در این پژوهش دشت شبستر می‌باشد. این محدوده با مختصات جغرافیایی $x = 540500$ تا $x = 587500$ طول شرقی و $y = 4215000$ تا $y = 4239500$ عرض شمالی، در ۶۰ کیلومتری غرب شهرستان تبریز قرار گرفته است. از طرف شمال به کوه‌های میشو، از غرب به منطقه تسوج، از شرق به محدوده شهر تبریز و از جنوب به دریاچه ارومیه و پهنه های نمکی-رسی محدود می‌شود. مهم‌ترین رودخانه‌های جاری در دشت، رودخانه‌های دریان‌چای، شانجان‌چای، سیس‌چای و پیام‌چای می‌باشند که امتداد تقریباً شمالی-جنوبی دارند. منطقه مورد مطالعه برای ارتفاعات و دشت بر اساس اقلیم نمای آمبرژه به ترتیب دارای اقلیم نیمه‌خشک سرد و خشک سرد است (بی‌نام

۲۰۱۷). آبخوان دشت شبستر از نوع تک‌لایه و آزاد است اگرچه در قسمت‌های جنوبی دشت، آبخوان تحت-فشار نیز وجود دارد اما داده‌های سطح آب از پیزومترهای نفوذ کرده به آبخوان نشان می‌دهد آبخوان محبوس از نظر هیدروژئولوژیکی دیگر صرفاً یک آبخوان تحت‌فشار نیست و مانند یک آبخوان آزاد عمل می‌کند. مقدار قابلیت‌انتقال در مرکز دشت حدود ۱۰۰۰ تا ۱۵۰۰ مترمربع در روز برآورد می‌شود که به سمت شوره‌زار های جنوبی کاهش می‌یابد و در کناره‌ها به ۱۰۰ مترمربع در روز می‌رسد. آبدهی ویژه لایه آبدار سطحی در نیمه شرقی دشت بیشتر به دلیل دانه‌بندی آبرفت کمتر از سایر بخش‌ها و در نیمه شمالی آن بین ۵ تا ۸ درصد می‌باشد. مقدار آبدهی ویژه در این منطقه به سمت جنوب کاهش یافته و در جنوب دشت به حدود ۲ درصد می‌رسد (بی‌نام ۲۰۱۷). شکل ۱ نقشه رقومی ارتفاعی منطقه مورد مطالعه و سیستم زهکشی آن را نشان می‌دهد.



شکل ۱- نقشه رقومی ارتفاعی منطقه مورد مطالعه.

چهار چوب عملی دراستیک

چهار چوب عملی دراستیک برای محاسبه پتانسیل آلودگی در مقیاس ناحیه‌ای به‌کار می‌رود. پارامترهای مختلف موثر در این چهار چوب عملی شامل عمق آب زیرزمینی، تغذیه خالص، محیط آبخوان، محیط

خاک، توپوگرافی یا شیب سطح زمین، محیط غیراشباع، ضریب هدایت هیدرولیکی می‌باشد (آلر و همکاران ۱۹۸۷). به هر یک از این پارامترها با توجه به اهمیت آن در انتقال آلودگی به سیستم آب زیرزمینی نسبت به سایر عوامل یک وزن نسبی از ۱ (کم‌اهمیت ترین پارامتر) تا ۵ (مهم‌ترین پارامتر) اختصاص داده می‌شود. هر کدام

آب زیرزمینی تهیه و بر اساس استانداردهای آئر رتبه-بندی شد. عمق برخورد به آب زیرزمینی در دشت شبستر از ۲/۵۶ تا ۸۶/۶ متر متفاوت است. قسمت‌های شمالی آبخوان دارای عمق آب بیش‌تری نسبت به قسمت‌های جنوبی می‌باشند بنابراین رتبه کم‌تری به آن‌ها تعلق گرفته است (شکل ۲ الف).

لایه تغذیه خالص

تغذیه خالص مقدار آبی است که از سطح زمین نفوذ کرده و به سطح ایستابی می‌رسد. تغذیه آب موجب می‌گردد تا آلوده کننده به صورت عمودی یا نزدیک به حالت قائم انتقال یافته و به سطح ایستابی برسد و بیشتر به صورت افقی در آبخوان حرکت کند. همچنین این پارامتر حجم آبی را که موجب رقیق شدن آلوده کننده در منطقه اشباع و غیراشباع می‌گردد، در کنترل دارد. معمولاً با افزایش میزان تغذیه در یک منطقه، پتانسیل آلودگی آب‌های زیرزمینی در آن منطقه افزایش می‌یابد (رحمان ۲۰۰۸). جهت تهیه لایه تغذیه خالص از روش پیسکوپو (۲۰۰۱) استفاده شد. برای این منظور سه لایه نقشه بارش، نقشه شیب و نقشه نفوذپذیری خاک در محیط نرم‌افزار GIS تهیه شدند. نقشه شیب با استفاده از مدل رقومی ارتفاعی منطقه تهیه شد. جنس دومتر بالایی لاگ چاه‌های مشاهده‌ای برای تهیه لایه نفوذپذیری خاک استفاده شد و در نهایت این دو لایه بر اساس جدول ۱ رتبه‌بندی شدند. با توجه به اینکه مقدار بارش برای منطقه کمتر از ۵۰۰ میلی‌متر در سال می‌باشد، رتبه ۱ برای لایه بارش در نظر گرفته شد. در نهایت سه نقشه رستری تهیه‌شده شامل نفوذپذیری خاک، میزان بارندگی و شیب زمین همپوشانی شدند و لایه تغذیه محاسبه گردید (شکل ۲ ب).

از عوامل به محدوده‌هایی تقسیم‌بندی می‌شوند. اهمیت هر محدوده با توجه به تاثیر بر روی پتانسیل آلودگی تعیین می‌گردد که همان نرخ می‌باشد. نرخ پارامترهای دراستیک بین ۱ تا ۱۰ تغییر می‌کند (پاناگولوس و همکاران ۲۰۰۶). برای محاسبه پتانسیل آلودگی آبخوان، این پارامترها در یک معادله ساده خطی به صورت زیر وارد می‌شوند:

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

در رابطه بالا DRASTIC Index شاخص آسیب‌پذیری دراستیک و حروف بزرگ D, R, A, S, T, I, C به ترتیب نشان دهنده عمق برخورد به آب زیرزمینی، تغذیه خالص، محیط آبخوان، محیط خاک، توپوگرافی، محیط غیراشباع و هدایت هیدرولیکی، نرخ ارزش (رتبه) و W وزنی است که به هر پارامتر تخصیص داده می‌شود. با استفاده از این رابطه، می‌توان بیان نمود که کدام منطقه در معرض آلودگی قرار دارد. بدین صورت که هر چه شاخص بزرگتر باشد، پتانسیل آلودگی بیشتر می‌گردد.

لایه عمق آب زیرزمینی

این پارامتر تعیین کننده عمقی است که آلوده کننده باید طی کند تا به سطح ایستابی برسد. معمولاً ظرفیت میرایی با افزایش عمق تا سطح ایستابی افزایش می‌یابد چرا که هر چقدر سطح آب دارای عمق بیش‌تری باشد، زمان حرکت و ماندگاری آلاینده افزایش می‌یابد. با افزایش عمق تا سطح آب زیرزمینی پتانسیل آلودگی سفره کاهش می‌یابد. برای تهیه لایه عمق آب زیرزمینی، اطلاعات سطح آب ۲۴ پیزومتر موجود در محدوده مورد مطالعه برای سال آبی ۹۶-۹۵، در محیط نرم افزار GIS وارد شده و با روش معکوس وزنی فاصله درون‌یابی شد و در نهایت لایه رستری عمق برخورد به

جدول ۱- امتیازات پارامترهای تغذیه برای بارش (پسکوپو ۲۰۰۱).

تغذیه خالص		شیب (%)		بارش (mm)		نفوذپذیری خاک	
رتبه	محدوده	رتبه	محدوده	رتبه	محدوده	رتبه	مقدار
10	11-13	4	>2	4	<850	5	زیاد
8	9-11	3	2-10	3	700-850	4	متوسط تا زیاد
5	7-9	2	10-33	2	500-700	3	متوسط
3	5-7	1	<33	1	>500	2	کم
1	3-5					1	خیلی کم

لایه محیط اشباع

محیط اشباع و مواد تشکیل دهنده آن طول و چگونگی روند سیستم جریان آب زیرزمینی در آبخوان را مشخص می‌کند. این عامل به خصوصیات مواد تشکیل دهنده منطقه اشباع مانند میزان تخلخل، جنس و اندازه ذرات و جورشدگی (یکدست بودن اندازه ذرات) ذرات اشاره دارد که میزان پویایی و تحرک آلودگی را کنترل می‌کند. به منظور تهیه این لایه از لاگ چاه‌های اکتشافی منطقه استفاده شد. رتبه‌دهی به جنس قسمت اشباع این لاگ‌ها صورت گرفت به این ترتیب که به قسمت‌های ریزدانه رتبه کمتر و به قسمت‌های درشت-دانه رتبه بیش‌تری تعلق گرفت (شکل ۲ پ).

لایه محیط خاک

محیط خاک به بخش هوازده بالایی منطقه غیراشباع گفته می‌شود که تا حد نفوذ ریشه گیاهان ادامه دارد. این بخش از نظر فعالیت‌های بیولوژیکی و وجود مواد آلی اهمیت بسیاری دارد و میزان آب نفوذی و نفوذ آلاینده‌ها را به داخل آبخوان کنترل می‌کند. به طور کلی هر قدر اندازه ذرات خاک ریزتر و نفوذپذیری خاک کمتر و درصد مواد آلی و ضخامت خاک بیش‌تر باشد، پتانسیل آلودگی آب زیرزمینی کاهش می‌یابد. با

در نظر گرفتن جنس قسمت ۲ متر بالای لاگ چاه‌های اکتشافی و رتبه‌دهی به آن‌ها و در نهایت درون‌یابی این رتبه‌ها در محیط نرم‌افزار Arc GIS لایه محیط خاک تهیه شد. قسمت‌های جنوبی دشت دارای بافت خاک ریزدانه هستند بنابراین رتبه کم‌تری را به خود اختصاص داده‌اند (شکل ۲ ت).

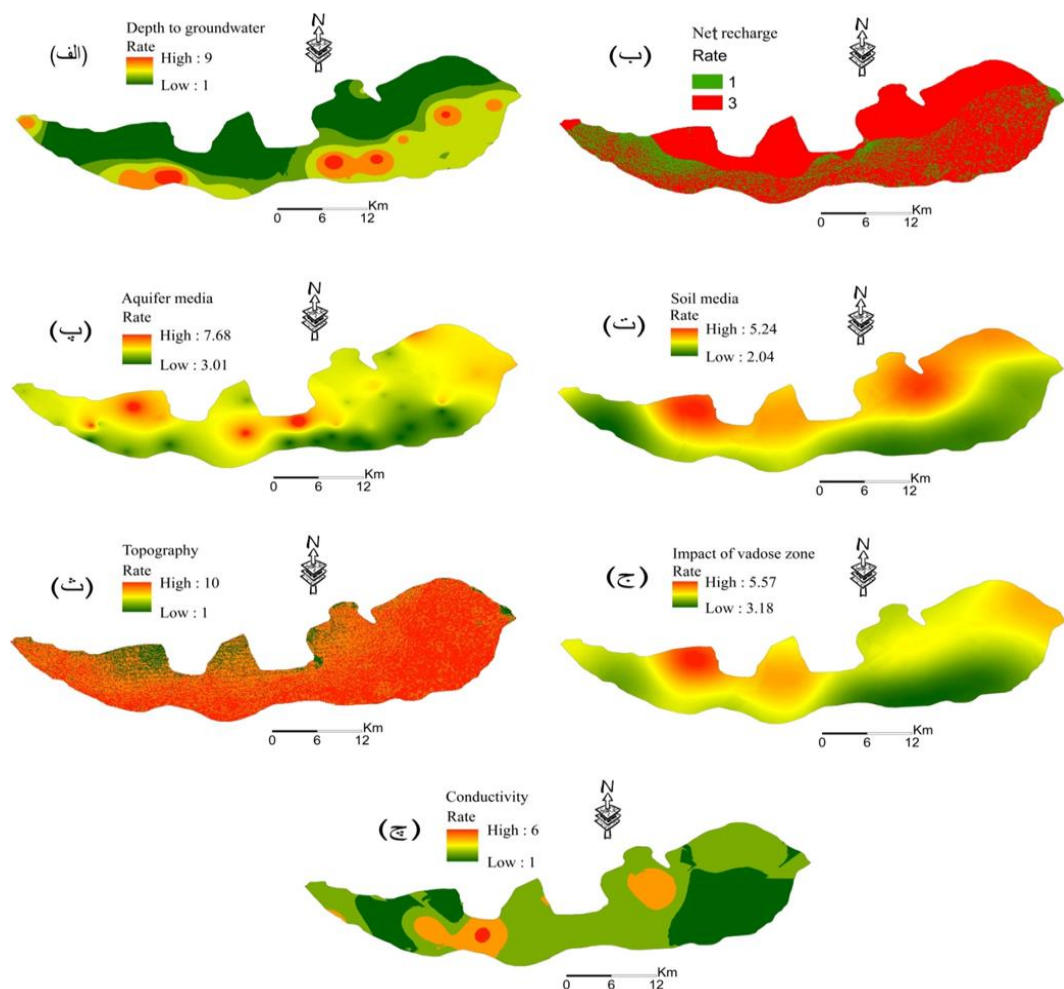
لایه توپوگرافی

توپوگرافی به صورت شیب و تغییرات شیب زمین مورد توجه قرار می‌گیرد. توپوگرافی حرکت آلوده کننده و نگهداری آن را بر سطح زمین در کنترل دارد. شیب‌های کم باعث افزایش ماندگاری آب بر روی سطح زمین می‌شود و نرخ نفوذ را افزایش می‌دهد بنابراین رتبه بیش‌تری را خواهند داشت. به منظور تهیه لایه توپوگرافی مدل رقومی- ارتفاعی منطقه تهیه شد و سپس نقشه درصد شیب از آن استخراج گردید و در نهایت این نقشه بر اساس معیارهای دراستیک رتبه‌بندی شد. قسمت‌های شمالی دشت دارای شیب توپوگرافی بیش‌تری هستند بنابراین رتبه کم‌تری را به خود اختصاص داده‌اند (شکل ۲ ث).

لایه محیط غیراشباع

محیط غیراشباع منطقه بالای سطح ایستابی است که از آب، غیراشباع باشد و یا به صورت غیر پیوسته از آب اشباع شده باشد. این محیط، رسوبات موجود از سطح ایستابی تا زون خاک را شامل می‌شود که عبور و رقیق شدن مواد آلاینده را به محیط اشباع کنترل می‌کند. برای تهیه این لایه، جنس قسمت اشباع لاگ چاه‌های اکتشافی رتبه‌دهی شد. پس از درونیابی این رتبه‌ها در محیط نرم‌افزار Arc GIS، لایه رتبه‌بندی شده محیط غیراشباع تهیه شد (شکل ۲ ج).

لایه هدایت هیدرولیکی



شکل ۲- نقشه لایه‌های ورودی در مدل دراستیک الف) عمق آب‌زیرزمینی، ب) تغذیه خالص، پ) محیط آبخوان، ت) محیط خاک، ث) توپوگرافی، ج) محیط غیراشباع، چ) هدایت هیدرولیکی.

هدایت هیدرولیکی یک سفره گنجایش تحرک-پذیری آب زیرزمینی در محیط اشباع را نشان می‌دهد. بنابراین تحرک‌پذیری مواد آلاینده توسط آب زیرزمینی تقریباً برابر هدایت هیدرولیکی سفره می‌باشد (سیویتا و مایو ۱۹۹۸). هر چه هدایت هیدرولیکی بیشتر باشد امکان جریان یافتن آلاینده‌ها در آبخوان بیشتر است. بر اساس اطلاعات آزمایش پمپاژ در آبخوان دشت شبستر، مقادیر هدایت هیدرولیکی درونیابی و به رستر تبدیل شد و در نهایت رتبه‌بندی شد (شکل ۲ چ).

تقسیم بندی شاخص آسیب پذیری دراستیک

به منظور تقسیم بندی شاخص دراستیک، روش-های مختلفی وجود دارد. در این مطالعه از تقسیم بندی پیشنهادی هوآن و همکاران (۲۰۱۲) و کازاکیس و دوریس (۲۰۱۵) استفاده شد. این تقسیم بندی به صورت هندسی است و محدوده شاخص آسیب پذیری با مشخص کردن تعداد دسته ها، توسط نرم افزار تقسیم بندی می شود. با استفاده از نرم افزار Arc GIS و انتخاب این نوع دسته بندی، تعداد دسته ها به صورت اختیاری برابر ۵ انتخاب شد و بر این اساس پنج محدوده با آسیب پذیری خیلی کم، کم، متوسط، زیاد و خیلی زیاد محاسبه شد.

نرمال سازی داده ها

به منظور وارد کردن داده های ورودی و خروجی در مدل های هوش مصنوعی، داده ها در بازه صفر و یک قرار گرفتند و به این ترتیب نرمال شدند. انتقال داده ها به یک بازه مشخص امکان مقایسه خروجی مدل را با معیارهای سنجش متفاوت فراهم می سازد. به همین جهت ابتدا بیشترین (X_{max}) و کمترین (X_{min}) مقدار ورودی ها و خروجی مدل در بازه مشخص شده به دست آمده و سپس با استفاده از رابطه ۲ هر داده به بازه ۰ تا ۱ انتقال داده می شود. X مقدار اصلی و X' مقدار نرمال شده را نشان می دهد. در نهایت تمام داده ها به صورت نرمال وارد مدل شبکه-عصبی و مدل نروفازی شدند.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad [2]$$

مدل شبکه عصبی


به طور کلی هر شبکه عصبی دارای سه لایه است: یک لایه ورودی، یک لایه پنهان یا داخلی و یک لایه خروجی. لایه داخلی اطلاعات را دریافت می کند. لایه پنهان که ممکن است شامل چندین لایه باشد، اطلاعات را

واکاوی می کند و لایه خروجی، نتایج واکاوی شده را دریافت کرده و خروجی را تولید می کند (زیدنبرگ ۱۹۹۰). طرح شماتیک MLP که یک مدل چند لایه از شبکه عصبی است در شکل ۳ نشان داده شده است. در این مطالعه از مدل شبکه عصبی برگشتی با تابع بهینه-سازی نوع لونیبرگ مارکوورت، به دلیل کارایی بهتر نسبت به سایر الگوریتم ها، جهت برای بهبود مدل دراستیک استفاده شده است. شبکه عصبی برگشتی یک تکنیک یادگیری نظارتی است که مقادیر ورودی را در طول شبکه رو به جلو می فرستد، سپس تفاوت بین خروجی محاسبه شده و خروجی متناظر مطلوب را از مجموعه آموزشی محاسبه می کند. سپس این خطا در طول شبکه به سمت عقب منتشر شده و وزن ها طی تعدادی از تکرارها تعدیل می شوند. یادگیری زمانی متوقف می شود که مقادیر خروجی محاسبه شده، مقادیر مطلوب را به بهترین حالت تقریب بزنند (بات و هل ۲۰۰۲). به منظور اجرای این مدل، ۷ ورودی دراستیک به عنوان ورودی شبکه عصبی در نظر گرفته شدند. خروجی مدل شاخص آسیب پذیری تصحیح شده با استفاده از غلظت نیترات در نظر گرفته شد. انتخاب خروجی مدل ها به صورت شاخص آسیب پذیری تصحیح شده برای این است که مدل، مناطق با نیترات بالا را به عنوان مناطق دارای آسیب پذیری بالا در نظر بگیرد. شاخص دراستیک تصحیح شده با استفاده از رابطه ۳ محاسبه شد (فیجانی و همکاران ۲۰۱۳).

$$CVI = \frac{vul_{max}}{(No_3)_{max}} \times (No_3)_i \quad [3]$$

در رابطه فوق، CVI شاخص آسیب پذیری دراستیک تصحیح شده، vul_{max} حداکثر مقدار شاخص دراستیک، No_{3max} حداکثر غلظت نیترات اندازه گیری شده از بین ۶۶ نقطه نمونه برداری و No_{3i} غلظت نیترات در هر نقطه نمونه برداری را نشان می دهد. پیش از وارد کردن داده ها در نرم افزار متلب برای اجرای مدل شبکه

شد. انتخاب تعداد نرون‌ها در لایه میانی و تعداد دوره های آموزش به صورت آزمون و خطا و با هدف بهترین خروجی (کمترین RMSE و بیشترین r بین آسیب‌پذیری مشاهداتی و محاسباتی) انجام شد. تعداد نرون خروجی برابر با تعداد خروجی داده شده به مدل انتخاب می‌شود.



شکل ۳- نمودار شمانیک MLP (خسروی ۲۰۰۵).

هرچه مقادیر جذر میانگین مربع خطا به صفر و مقدار ضریب همبستگی به یک میل کند بازده مدل هوش مصنوعی بالاتر خواهد بود.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Vul_i - \hat{V}ul_i)^2}{n}} \quad [4]$$

$$r = \frac{\sum_{i=1}^n (Vul_i - \bar{Vul})(N_i - \bar{N})}{\sqrt{\sum_{i=1}^n (Vul_i - \bar{Vul})^2} \sqrt{\sum_{i=1}^n (N_i - \bar{N})^2}} \quad [5]$$

در روابط بالا $\hat{V}ul_i$ آسیب‌پذیری محاسباتی، Vul_i شاخص آسیب‌پذیری مشاهداتی، میانگین آسیب‌پذیری، N_i غلظت نیترات، N میانگین غلظت نیترات و n تعداد کل مشاهداتی را نشان می‌دهند.

مجموعه داده غلظت نیترات

جهت صحت‌سنجی مدل‌های آسیب‌پذیری از داده‌های غلظت نیترات در ۶۶ نقطه نمونه برداری شده

عصبی، تمام آن‌ها با استفاده از رابطه ۲ نرمال شده و در بازه صفر و یک قرار گرفتند. تعداد کل داده‌ها برابر ۱۸۷۵ بودند که ۷۰ درصد از آن‌ها به عنوان داده آموزش، ۱۵ درصد به عنوان داده اعتبار‌سنجی و ۱۵ درصد به عنوان داده آزمایش در نظر گرفته شد. انتخاب داده‌های آموزش و آزمایش و اعتبار‌سنجی به صورت تصادفی و با استفاده از نرم‌افزار متلب انجام

مدل عصبی فازی

سیستم استنتاج تطبیقی عصبی-فازی (نروفازی) از الگوریتم‌های شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیر خطی بین فضای ورودی و خروجی استفاده می‌کند. در این سیستم متناسب با داده‌های ورودی، درجه عضویت، قوانین و توابع درجه عضویت خروجی انتخاب می‌شود (هوشنگی و آل شیخ ۲۰۱۵، قنبری و همکاران ۲۰۱۷). ورودی‌ها و خروجی این مدل نیز مانند روش شبکه عصبی انتخاب شد. پس از نرمال سازی داده‌ها ۸۰ درصد آنها به عنوان داده آموزش و ۲۰ درصد به عنوان داده آزمایش در نظر گرفته شد. از روش خوشه‌سازی کاهشی جهت دسته‌بندی داده‌ها استفاده شد و مدل عصبی فازی اجرا شد.

معیار ارزیابی دقت مدل‌های هوش مصنوعی

به منظور ارزیابی کارایی مدل‌های شبکه عصبی و عصبی فازی از ۲ معیار جذر میانگین مربع خطا (رابطه ۴) و ضریب همبستگی (رابطه ۵) استفاده شده است.

دقت کافی را ندارد. در همین راستا دو مدل شبکه عصبی و نروفازی به منظور بهبود مدل دراستیک مورد استفاده قرار گرفتند.

اجرای مدل شبکه عصبی

پس از انتخاب ورودی‌ها و خروجی مدل شبکه عصبی، این مدل پس از ۳ دوره آموزش با تعداد نرون میانی ۷ و تعداد نرون خروجی ۱ اجرا شد. تابع تبدیل نرون‌ها در لایه اول به دوم تابع سیگموئید تانژانتی و در لایه دوم به سوم تابع خطی انتخاب شد. خروجی نرمال حاصل از این مدل برای ارزیابی آسیب‌پذیری آبخوان دشت شبستر در دو مرحله آموزش و آزمایش خطای میانگین مربعات و ضریب همبستگی یکسانی را نشان داد. به طوریکه RMSE و r بین آسیب‌پذیری مشاهداتی و محاسبه شده توسط مدل در دو مرحله آموزش و آزمایش به ترتیب برابر $0/08$ و $0/7$ محاسبه شد.

اجرای مدل سیستم استنتاج تطبیقی عصبی-فازی (نروفازی)

در مدل نروفازی قسمتی از کار شبکه، مشابه مدل فازی ساجنو و قسمتی مشابه مدل شبکه عصبی انجام می‌گیرد. مناسب ترین شعاع خوشه‌سازی در این مدل، برابر $0/06$ و تعداد قوانین و تعداد توابع ورودی و خروجی برابر 1500 به دست آمد. در نهایت با هدف کمترین RMSE بین داده‌های آموزش محاسباتی و مشاهداتی و پس از ۵۰ دوره آزمایش مدل اجرا شد. در این مدل، مقادیر RMSE و r برای مرحله آموزش به ترتیب برابر $0/06$ و $0/82$ به دست آمد.

در محدوده مورد مطالعه استفاده شد. زیرا نیترا ت آلاینده‌ای است که توسط فعالیت‌های انسانی ایجاد می‌شود و منشا انسان‌زاد دارد و می‌تواند از سطح زمین به آب‌های زیرزمینی نفوذ کند. همچنین نیترا ت می‌تواند شاخصی برای کیفیت آب زیرزمینی باشد. مقادیر غلظت نیترا ت اندازه‌گیری شده در منطقه مورد مطالعه بین $0/2$ تا 70 میلی‌گرم بر لیتر متغیر است. به طور کلی محدوده‌های با نیترا ت بالا پتانسیل آسیب‌پذیری بالایی را خواهند داشت.

نتایج و بحث

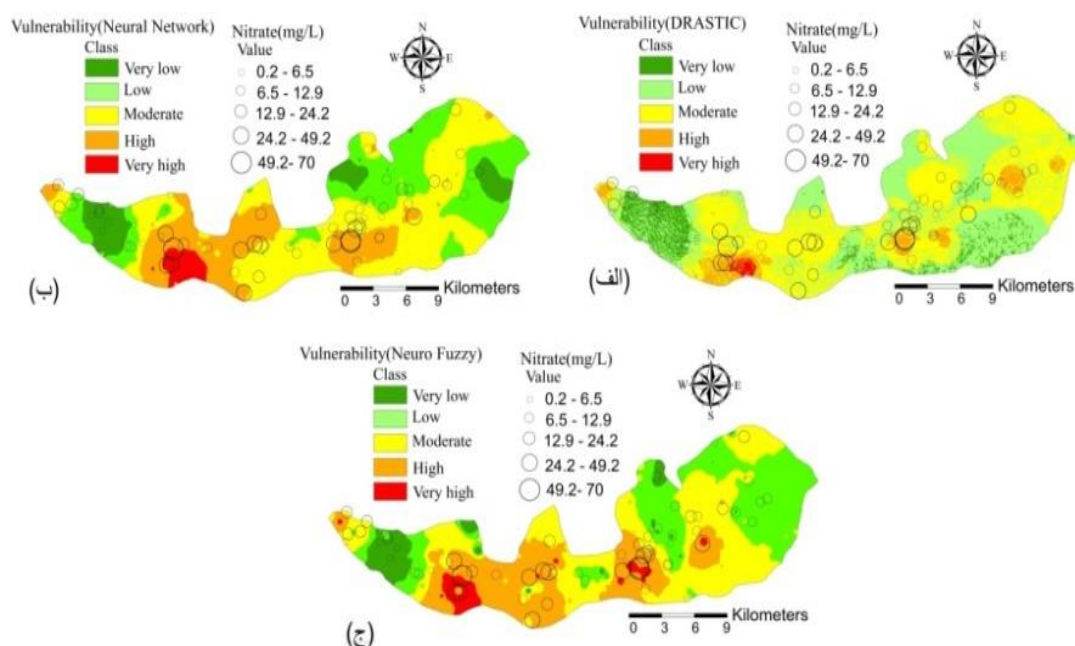
تهیه نقشه آسیب‌پذیری دراستیک

به منظور تهیه نقشه آسیب‌پذیری آبخوان دشت شبستر با دراستیک، هفت لایه نشان داده شده در شکل ۲ با استفاده از رابطه ۱ با یکدیگر تلفیق و همپوشانی شدند. شاخص آسیب‌پذیری دراستیک در منطقه مورد مطالعه برابر $53/3$ تا $118/3$ محاسبه شد. این شاخص بر اساس تقسیم‌بندی پیشنهادی هوآن به پنج منطقه با آسیب‌پذیری خیلی کم، کم، متوسط، زیاد و خیلی زیاد تقسیم‌بندی شد. بر اساس این تقسیم‌بندی به ترتیب $6/79$ ، $39/11$ ، $47/65$ ، $6/02$ و $0/6$ درصد از آبخوان دشت شبستر در محدوده آسیب‌پذیری خیلی کم، کم، متوسط، زیاد و خیلی زیاد قرار گرفته است. شکل ۴ الف نقشه آسیب‌پذیری دراستیک را نشان می‌دهد. بر اساس این روش نواحی با آسیب‌پذیری خیلی کم قسمت غربی منطقه مورد مطالعه و نواحی با آسیب‌پذیری خیلی زیاد بخش کوچکی از جنوب غربی منطقه مورد مطالعه را می‌پوشاند. برای صحت‌سنجی مدل دراستیک از داده‌های غلظت نیترا ت در ۶۶ نقطه نمونه‌برداری استفاده شد. ضریب همبستگی (r) بین داده‌های غلظت نیترا ت و شاخص آسیب‌پذیری برابر $0/3$ به دست آمد که نشان می‌دهد مدل دراستیک تا حدودی توانسته است آسیب‌پذیری آبخوان دشت شبستر را ارزیابی کند اما

صحت‌سنجی مدل‌های مختلف پیش‌بینی آسیب‌پذیری با غلظت نیترات

نقشه‌های آسیب‌پذیری با استفاده از مدل دراستیک اصلی و اصلاح شده به همراه غلظت نیترات در شکل ۴ نشان داده شده است. دایره‌های توخالی نشان‌دهنده غلظت نیترات در منطقه مورد مطالعه هستند که برای صحت‌سنجی مدل‌های آسیب‌پذیری به کار رفته اند. مقادیر ضریب همبستگی بین غلظت نیترات و شاخص دراستیک اصلی و اصلاح شده با روش شبکه عصبی و نروفازی به ترتیب برابر $0/3$ ، $0/7$ ، $0/8$ به دست آمد. این نتایج نشان می‌دهد هر دو مدل شبکه عصبی و عصبی فازی با افزایش ضریب همبستگی شاخص آسیب‌پذیری با نیترات توانسته‌اند بهتر از چهارچوب عملی دراستیک اصلی پتانسیل آسیب‌پذیری منطقه را نشان دهند. در دو مدل شبکه عصبی و عصبی فازی، با توجه به اینکه در مرحله آموزش، خروجی (شاخص آسیب‌پذیری تصحیح شده) به مدل داده شده بود بنابراین رتبه‌ها و ضرایب وزنی ورودی‌ها در این مرحله، باید به نحوی تغییر می‌کرد که خروجی داده شده به مدل برآورد شود. به این ترتیب ضرایب وزنی و

رتبه‌های اولیه دراستیک که بر اساس نظر شخصی تعیین شده بودند تغییر یافتند و بهینه شدند. از آنجا که در مرحله آزمایش خروجی برای مدل‌ها تعریف نشده بود، با جایگزینی ضرایب وزنی و رتبه‌های بهبود یافته مرحله آموزش در ورودی‌های مرحله آزمایش، آسیب‌پذیری آبخوان دشت شبستر ارزیابی شد. از بین مدل‌های بهینه‌سازی دراستیک، مدل نروفازی با داشتن ضریب همبستگی بالاتر نسبت به مدل شبکه عصبی کارایی بالاتری در برآورد آسیب‌پذیری آبخوان دشت شبستر داشته است. با توجه به این نکته که مدل نروفازی ترکیبی از مدل فازی ساجنو و مدل شبکه عصبی است بنابراین از مزایای هر دو مدل برای بهینه‌سازی و یا پیش‌بینی استفاده می‌کند. در واقع این مدل با خوشه‌بندی داده‌ها که مربوط به مدل فازی نوع ساجنو است و سپس ترکیب شبکه عصبی، مدل بهتری برای ارزیابی آسیب‌پذیری آبخوان دشت شبستر بوده است. بر اساس این مدل، زون‌های با آسیب‌پذیری خیلی کم، کم، متوسط، زیاد و خیلی زیاد به ترتیب $5/6$ ، $28/91$ ، $36/6$ ، $24/37$ و $3/13$ درصد از منطقه مورد مطالعه را می‌پوشاند.



شکل ۴- نقشه آسیب‌پذیری آب زیرزمینی و غلظت نیترات (الف) مدل دراستیک، (ب) مدل شبکه عصبی، (ج) مدل عصبی فازی.

نتیجه‌گیری کلی

خیلی زیاد بخش کوچکی از قسمت جنوب غربی منطقه را می‌پوشاند. بهینه‌سازی چهارچوب عملی دراستیک با مدل شبکه‌عصبی و نروفازی نشان می‌دهد هر کدام از این مدل‌ها نسبت به دراستیک اولیه ضریب‌همبستگی بالایی را با نیترا دارند. مدل نروفازی با داشتن ضریب‌همبستگی بالاتری نسبت به مدل شبکه‌عصبی روش مناسبی برای ارزیابی آسیب‌پذیری آب‌زیرزمینی دشت شبستر بوده است. بر اساس مدل نروفازی بخش‌هایی از جنوب غربی و مرکز منطقه مورد مطالعه دارای پتانسیل آلودگی بالایی هستند و باید محافظت گردند.

هدف از این پژوهش ارزیابی آسیب‌پذیری آبخوان دشت شبستر و سپس بهینه‌سازی آن با مدل‌های شبکه‌عصبی و نروفازی بوده است. با هم‌پوشانی و تلفیق هفت لایه عمق آب‌زیرزمینی، تغذیه خالص، محیط آبخوان، محیط خاک، توپوگرافی، محیط غیراشباع و هدایت‌هیدرولیکی بر اساس رابطه ۱ شاخص دراستیک در منطقه مورد مطالعه برابر $۵۳/۳$ تا $۱۱۸/۳$ محاسبه شد. بر اساس مدل دراستیک مناطق با آسیب‌پذیری

منابع مورد استفاده

- Aller L, Bennet T, Leher JH, Petty RJ and Hackett G, 1987. DRASTIC: A Standardized System for Evaluating Groundwater Pollution Potential Using Hydro-Geological Settings. EPA/600/2-87/035. Ada, Oklahoma: U.S. Environmental Protection Agency.
- Almasri MN, 2008. Assessment of intrinsic vulnerability to contamination for Gaza costal aquifer. *Jornal of Environmental Management* 88(4): 577-593.
- Anonymous, 2017. Study of Shabestar Plain abstraction wells water quantity and quality. East Azarbaijan water and wastewater Company.Iran.
- Asefi M, Radmanesh F and Zarei H, 2014. Optimization of DRASTIC model for vulnerability assessment of groundwater resources using analytical hierarchy process (Case study: Andimeshk plain). *Journal of Irrigation science and Engineering* 37(1):55-67(In Persian).
- Asghari Moghaddam A, Fijani E and Nadiri A, 2015. Optimization of DRASTIC model by artificial intelligence for groundwater vulnerability assessment in Maragheh- Bonab plain. *Journal of Geoscience* 94:169-176 (In Persian).
- Bhatt A, Helle H.B, 2002. Committee neural networks for porosity and permeability prediction from well logs. *Geophysical Prospecting* 50: 645-660.
- Civita M.V, De Maio M, 1998. Mapping groundwater vulnerability in areas impacted by flash food disasters. 13th ESRI European User Conference, France, Italy.
- Dixon B, 2005. Applicability of neuro-fuzzy techniques in predicting groundwater vulnerability. a GIS-based sensitivity analysis. *Journal of Hydrology* 309 (1-4): 17-38.
- Fijani E, Nadiri AA, Asghari Moghaddam A, Tsai F, Dixon B, 2013. Optimization of DRASTIC method by supervised committee machine artificial intelligence to assess ground water vulnerability for Maraghe-Bonab plain aquifer, Iran. *Journal of Hydrology* 503: 89-100.
- Ghanbari N, Rangzan K, kabolizade M and Moradi P, 2017. Improve the results of the DRASTIC model using artificial intelligence methods to assess groundwater vulnerability in Ramhormoz alluvial plain aquifer. *Journal of Water and Soil Conservation* 24(2): 45-65.
- Hamamin DF, Nadiri AA, 2018. Supervised Committee Fuzzy logic model to assess groundwater intrinsic vulnerability in multiple aquifer systems. *Arabian Journal of Geoscineces* 11(8): 1-14.
- Hoshangi N and Alesheikh A.A, 2015. Evaluation of ANN, ANFIS and Fuzzy system in estimation of solar radiation in Iran. *Journal of Geomatics Science and Technology* 4(3): 187-200 (In Persian).
- Huan H, Wang J and Teng Y, 2012. 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* 440: 14-23.
- Kazakis N, Voudouris K.S, 2015. Ground water vulnerability and pollution risk assessment of porous aquifers to nitrate modifying the DRASTIC method using quantitative parameters. *Journal of Hydrology* 525: 13-25.

- Kadkhodaie Ilkhchi F, Asghari Moghaddam A, Barzegar R, Gharekhani M, 2019. Optimization of the DRASTIC and SINTACS models in assessing the vulnerability of the Shabestar plain aquifer. *Iranian Journal of EcoHydrology* 6(1): 77-88 (In Persian).
- Khosravi H, 2005. Neural Network Classifier, The code project. <http://www.codeproject.com/KB/cpp/MLP.aspx>.
- Mahdavi A, Zare Abyaneh H, 2015. Determination of aquifer vulnerability potential based on DRASTIC and FUZZY Logic models (Case study: Hamedan- Bahar Plain). *Water and Soil Science- University of Tabriz* 26 (1-1): 1-17 (In Persian).
- Nadiri AA, Gharekhani M, Khatibi R, 2018a. Mapping aquifer vulnerability indices using Artificial Intelligence-running Multiple Frame works (AIMF) with supervised and unsupervised learning. *Water Resource Management* 32(9): 3023-3040.
- Nadiri AA, Sedghi Z, Khatibi R, Sadeghfam S, 2018b. Mapping specific vulnerability of multiple confined and unconfined aquifers by using artificial intelligence to learn from multiple DRASTIC frameworks. *Journal of Environmental Management* 227: 415-428.
- Neshat AR, Pradhan B, Pirasteh S and Shafri HZM, 2014. Estimating groundwater vulnerability to pollution using a modified DRASTIC model in the Kerman agricultural area, Iran. *Environmental Earth Science* 71 (7): 1-13.
- Panagopoulos G, Antonakos A and Lambrakis N, 2006. Optimization of DRASTIC model for groundwater vulnerability assessment, by the use of simple statistical methods and GIS. *Hydrogeology Journal* 14: 894-911.
- Piscopo G, 2001. Groundwater Vulnerability Map, Explanatory Notes, Castlereagh Catchment, NSW, Department of Land and Water Conservation, Australia.
- Vrba J and Zoporotec A, 1994. Guidebook on Mapping Groundwater Vulnerability. International Contributions to Hydrogeology. Verlag Heinz Heise GmbH and Co. KG
- Zeidenberg M, 1990. Neural Network in Artificial Intelligence. Ellis Horwood, NewYork.