



دانشگاه گواران

نشریه پژوهش‌های حفاظت آب و خاک
جلد بیست و چهارم، شماره دوم، ۱۳۹۶
<http://jwsc.gau.ac.ir>

بهبود نتایج حاصل از مدل دراستیک با استفاده از هوش مصنوعی جهت ارزیابی آسیب‌پذیری آبخوان آبرفتی دشت رامهرمز

*نازنین قنبری^۱، کاظم رنگزن^۲، مصطفی کابلی‌زاده^۳ و پوریا مرادی^۱

^۱دانش‌آموخته کارشناسی‌ارشد گروه سنجش از دور و سیستم اطلاعات جغرافیایی (GIS)، دانشگاه شهید چمران اهواز،
^۲دانشیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی (GIS)، دانشگاه شهید چمران اهواز،
^۳استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی (GIS)، دانشگاه شهید چمران اهواز
تاریخ دریافت: ۹۵/۴/۷؛ تاریخ پذیرش: ۹۶/۳/۲۰

چکیده

سابقه و هدف: آلودگی آب‌های زیرزمینی یک فرآیند پیچیده و پر از عدم قطعیت، در مقیاس منطقه‌ای می‌باشد. توسعه یک روش یکپارچه جهت ارزیابی آسیب‌پذیری آبخوان‌ها، می‌تواند به منظور مدیریت بهینه و حفاظت از آن‌ها کارآمد باشد. دشت رامهرمز به دلیل داشتن خاک حاصلخیز و منابع آب کافی دارای زمین‌های مستعد کشاورزی است که به دلیل توسعه کشاورزی، استفاده از کودهای شیمیایی و مواد آفت‌کش همواره در معرض خطر آلودگی قرار دارد. یکی از راه‌های مناسب برای جلوگیری از آلودگی آب‌های زیرزمینی، شناسایی مناطق دارای پتانسیل آلودگی می‌باشد. هدف از مطالعه حاضر، تهیه نقشه آسیب‌پذیری آبخوان آبرفتی دشت رامهرمز با استفاده از مدل دراستیک و سپس به‌کارگیری روش‌های هوش مصنوعی جهت بهبود نتایج حاصل از مدل دراستیک است. با توجه به اهمیت منابع آب زیرزمینی در منطقه مورد مطالعه که برای مقاصد مختلف از جمله کشاورزی مورد استفاده قرار می‌گیرد، مطالعه آسیب‌پذیری آبخوان و حفاظت این مناطق برای توسعه و مدیریت بهینه منابع آب ضروری به نظر می‌رسد.

مواد و روش‌ها: در این مطالعه، ارزیابی آسیب‌پذیری آبخوان آبرفتی دشت رامهرمز در ابتدا با استفاده از مدل دراستیک انجام شد و در ادامه از روش‌های هوش مصنوعی جهت بهینه‌سازی مدل استفاده گردید. مدل دراستیک شامل پارامترهای: عمق تا سطح ایستابی، تغذیه، جنس سفره، نوع خاک، توپوگرافی، مواد تشکیل‌دهنده منطقه غیراشباع و هدایت هیدرولیکی می‌باشد که در ارزیابی آسیب‌پذیری سفره آب زیرزمینی مؤثر هستند. این روش بر اساس وزن‌های استاندارد پارامترهای مدل دراستیک و لایه‌های به‌دست آمده برای هر یک از هفت پارامتر میزان آسیب‌پذیری آبخوان را محاسبه می‌نماید. پس از آماده‌سازی لایه‌ها، آسیب‌پذیری آبخوان آبرفتی دشت رامهرمز با استفاده از روش دراستیک، تعیین گردید. هم‌چنین نقشه آسیب‌پذیری آبخوان و شاخص دراستیک برای کل منطقه محاسبه شد. به‌منظور ارزیابی دقت نتایج این مدل، از داده‌های غلظت نیترات موجود در آبخوان جهت صحت‌سنجی استفاده شده است. در ادامه به‌منظور بهبود نتایج، مدل دراستیک با روش‌های شبکه عصبی مصنوعی، منطق فازی (سوگنو و ممدانی) و سیستم

* مسئول مکاتبه: ghanbari_nazanin70@yahoo.com

استنتاج تطبیقی عصبی- فازی تلفیق شد و چهار نقشه آسیب‌پذیری با استفاده از مدل‌های مختلف هوش مصنوعی حاصل گردید.

یافته‌ها: نقشه آسیب‌پذیری آبخوان نسبت به آلودگی، با تقسیم‌بندی به سه محدوده آسیب‌پذیری کم، متوسط و زیاد تهیه و شاخص دراستیک برای کل منطقه بین ۴۸ تا ۱۵۶ محاسبه گردید. ضریب همبستگی ۰/۹۷ بین شاخص دراستیک و غلظت نیترات نشان‌دهنده دقت نسبتاً مناسب این روش است. نتایج نشان داد که مدل‌های هوش مصنوعی به‌کار گرفته شده، قابلیت بهبود نتایج مدل دراستیک اولیه را دارا می‌باشند. با مقایسه نتایج مدل‌ها می‌توان نتیجه گرفت که مدل سیستم استنتاج تطبیقی عصبی- فازی بهترین نتیجه را در بردارد.

نتیجه‌گیری: ضریب تعیین (R^2) برای مدل‌های سیستم استنتاج تطبیقی عصبی- فازی، شبکه عصبی و مدل‌های فازی سوگونو و ممدانی به ترتیب ۰/۹۹، ۰/۹۴، ۰/۹۸ و ۰/۸۷ به دست آمد. طبق مدل نهایی، نواحی جنوب- جنوب شرقی منطقه دارای بیش‌ترین میزان پتانسیل آلودگی هستند.

واژه‌های کلیدی: آسیب‌پذیری آب زیرزمینی، مدل دراستیک، سیستم اطلاعات جغرافیایی، هوش مصنوعی

مقدمه

سفره‌های آب زیرزمینی، به‌عنوان یکی از مهم‌ترین منابع آبی آسیب‌پذیر، به شکل‌های مختلف در معرض آلودگی قرار دارند که تشخیص و کنترل آلودگی در آن‌ها نسبت به آب‌های سطحی پیچیده‌تر و پرهزینه‌تر است. به دلیل استمرار آلودگی در این منابع، بهترین روش جلوگیری از آلودگی آن‌ها، شناسایی منابع آلوده‌کننده و مناطق آسیب‌پذیر، تهیه نقشه‌های پهنه‌بندی آسیب‌پذیری و اتخاذ سیاست‌های مدیریتی مناسب است. از آنجایی که مناطق خشک و نیمه‌خشک وابستگی بیشتری به منابع آب زیرزمینی دارند، بنابراین جلوگیری از آلودگی منابع آب زیرزمینی امری کاملاً ضروری در مدیریت یکپارچه منابع آب به‌شمار می‌رود (۱۴). همان‌طور که گفته شد، یکی از ابزارهای مناسب که کمک مؤثری به مدیریت آب‌های زیرزمینی می‌کند، تهیه نقشه‌هایی است که در آن‌ها مناطق آسیب‌پذیر یا حساس به آلودگی مشخص شده باشند. بدین‌منظور نقشه‌هایی از مناطق حساس و مستعد نسبت به بروز آلودگی تهیه می‌شود. مفهوم آسیب‌پذیری برای اولین بار در اواخر سال ۱۹۶۰ میلادی در فرانسه

برای آگاهی بخشی در مورد آلودگی آب زیرزمینی ارائه شده است (۴۰). آسیب‌پذیری یک ویژگی نسبی، بدون بُعد و غیرقابل اندازه‌گیری است و به ویژگی‌های آبخوان، محیط زمین‌شناسی و هیدروژئولوژی بستگی دارد (۴). یکی از روش‌های متداول برای ارزیابی آسیب‌پذیری ذاتی آبخوان روش دراستیک است که پرکاربردترین روش از مدل‌های PCSM^۱ است. در این مدل‌ها علاوه بر طبقه‌بندی پارامترهای مختلف، ضرایب وزنی نسبی برای هر عامل تعیین می‌شود (۳۰). مدل دراستیک توسط آژانس حفاظت محیط زیست ایالات متحده^۲ برای ارزیابی آسیب‌پذیری آب‌های زیرزمینی در کل ایالات متحده ابداع شد (۴). این مدل بر پایه مفهوم وضعیت هیدروژئولوژیکی استوار است. وضعیت هیدروژئولوژیکی در حقیقت توصیف‌کننده ترکیبی از تمام عوامل زمین‌شناسی و هیدرولوژیکی است که حرکت آب‌های زیرزمینی را در ورود، درون و خروج از سیستم در یک ناحیه تحت‌تأثیر قرار داده و کنترل می‌کند (۳). امروزه با

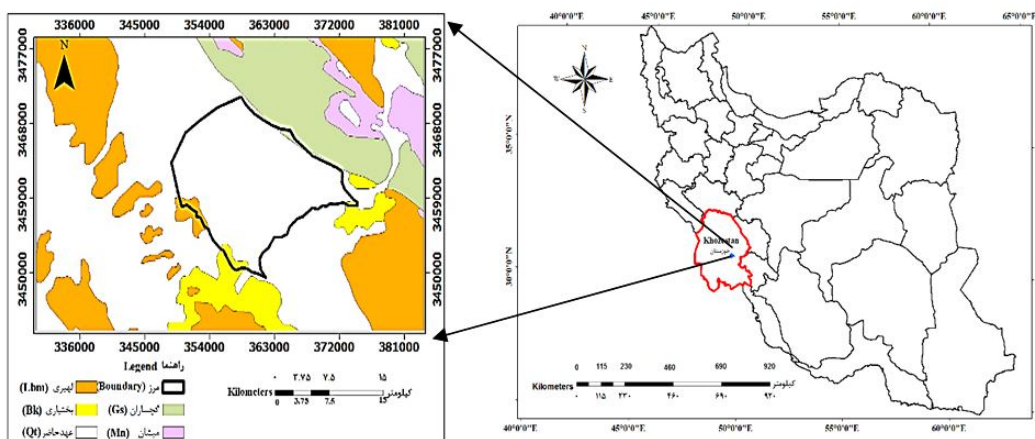
1- Point count system models
2- Environmental protection agency

را با استفاده از روش‌های آماری انجام دادند (۳۰). در این پژوهش، سعی شده تا با استفاده از روش‌های هوش مصنوعی بهبود مدل دراستیک صورت بگیرد به طوری که با حفظ مزایای این روش، نتایج دقیق‌تری نسبت به مدل دراستیک اولیه به دست آید. دشت رامهرمز به دلیل داشتن خاک حاصلخیز و منابع آب کافی دارای زمین‌های مستعد کشاورزی است. از آنجایی که در دشت رامهرمز عمده کاربری به صورت کشاورزی است و از کودهای شیمیایی نیز استفاده می‌شود و همچنین وجود فاضلاب شهری و روستایی، منابع آب زیرزمینی دشت در معرض خطر آلودگی قرار می‌گیرد، بنابراین با تهیه نقشه‌های آسیب‌پذیری و مدیریت صحیح می‌توان از منابع آب زیرزمینی دشت رامهرمز و همچنین دشت‌های مشابه، محافظت کرد.

مواد و روش‌ها

منطقه مورد مطالعه: محدوده مطالعاتی رامهرمز با مساحت ۱۸۴۸ کیلومتر در مختصات جغرافیایی ۴۹ درجه و ۹ دقیقه تا ۴۹ درجه و ۶ دقیقه عرض شمالی و ۳۱ درجه و ۶ دقیقه تا ۳۱ درجه و ۴۱ دقیقه طول شرقی از نصف‌النهار گرینویچ قرار گرفته است. این محدوده محدوده‌های مطالعاتی مسجدسلیمان، شوشتر و از جنوب با محدوده‌های شادگان و جازران و از شرق با محدوده‌های مطالعاتی دالون-می‌داود و باغملک همسایه می‌باشد (۳۱). ارتفاع متوسط دشت ۱۷۰ متر از سطح دریا است و با میانگین دمای سالانه ۲۵/۳ درجه سانتی‌گراد دارای آب و هوای استپی محلی می‌باشد (۳۲). دشت رامهرمز دارای امتداد جنوب‌غربی-شمال‌شرقی است و بزرگ‌ترین دشت محدوده می‌باشد. شکل ۱ موقعیت منطقه را نشان می‌دهد.

استفاده از تکنیک GIS^۱ امتیازبندی و ترکیب لایه‌های این مدل آسان‌تر شده و دقت انجام این محاسبات نیز تا حد زیادی افزایش یافته است (۴۱). پژوهش‌ها نشان داده است که استفاده از محیط GIS برای ارزیابی آسیب‌پذیری آبخوان نتایج قابل‌قبولی در پی خواهد داشت (۲۳). مطالعات بسیاری از این روش بهره جسته‌اند که از آن جمله می‌توان به نشات و همکاران (۲۰۱۴)، سنر و همکاران (۲۰۱۵)، باغاپور و همکاران (۲۰۱۴)، کرمی شاهملکی و همکاران (۲۰۱۰) و متکان و همکاران (۲۰۰۸) اشاره کرد (۹، ۱۷، ۲۵، ۲۸ و ۳۷). احمدی و همکاران (۲۰۱۳) در مطالعه خود آسیب‌پذیری آبخوان دشت سلفچگان-نیزار را با استفاده از مدل دراستیک و اعمال آنالیز حساسیت تک‌پارامتری و حذفی تعیین کردند. نتایج نشان داد که حریم‌های مختلف کیفی، قبل و بعد از تصحیح مدل تغییراتی در محدوده‌شان نشان دادند و همچنین به‌طورکلی نتایج تحلیل حساسیت تک‌پارامتری در این روش نشان داد که وزن مؤثر و تئوریک پارامترهای به‌کار رفته، کاملاً بر هم منطبق نیستند (۱). نخعی و همکاران (۲۰۱۳) ارزیابی پتانسیل آلودگی و آنالیز حساسیت آب زیرزمینی در آبخوان خاتون‌آباد را با استفاده از مدل دراستیک انجام دادند و نشان دادند که این آبخوان از نظر طبقه‌بندی استعداد آلودگی در محدوده کم تا متوسط قرار می‌گیرد (۲۶). به‌منظور بهبود مدل دراستیک از روش‌های مختلفی استفاده شده است. دیکسون (۲۰۰۵b)، با استفاده از منطق فازی، آسیب‌پذیری آبخوان آرکانزاس نسبت به آلودگی را در مقیاس منطقه‌ای پیش‌بینی کرد. اهداف پژوهش شامل تهیه مدل‌های فازی با استفاده از بعضی پارامترهای شاخص دراستیک اصلاح‌شده، مقایسه نتایج مدل فازی با مدل دراستیک و نتایج آنالیز کیفی آبخوان بود (۱۲). پاناگوپولز و همکاران (۲۰۰۶)، بهبود روش دراستیک



شکل ۱- موقعیت منطقه مورد مطالعه.

Figure 1. Location of the study area.

داده‌های مختلف وجود دارد. با استفاده از امکانات تحلیل فضایی که در GIS قابل دسترسی است، لایه‌های اطلاعاتی براساس هفت مؤلفه دراستیک ایجاد می‌شوند. وقتی مقادیر دراستیک از طریق GIS نشان داده شوند، رابطه فضایی بین اجرای مدیریت اراضی و آسیب‌پذیری آب زیرزمینی مشخص می‌شود (۳۸). به هر پارامتر بر اساس استعداد و حساسیت نسبی در برابر آلاینده، یک وزن نسبی از ۱ تا ۵ اختصاص داده می‌شود (مهم‌ترین پارامتر دارای وزن ۵ و کم‌اهمیت‌ترین دارای وزن ۱ است). هر کدام از پارامترهای دراستیک به بازه‌هایی تقسیم می‌شوند که نسبت تأثیر آن‌ها بر روی آسیب‌پذیری متفاوت است. به بازه‌های هر کدام از پارامترهای دراستیک نیز یک رتبه بین ۱-۱۰ اختصاص می‌یابد. نحوه وزندهی فاکتورهای مؤثر در مدل دراستیک در جدول ۱ نشان داده شده است. نتیجه مدل دراستیک یک اندیس عددی است که از رتبه‌ها و وزن‌های اختصاص‌یافته به پارامترهای مدل مشتق می‌شود (۳۵). رابطه مربوط برای تعیین اندیس دراستیک به صورت زیر است (۳):

$$I(\text{DRASTIC Index}) = D_R D_W + R_R R_W + A_R A_W + S_R S_W + T_R T_W + I_R I_W + C_R C_W \quad (1)$$

مدل دراستیک (DRASTIC): رایج‌ترین روش برای برآورد آسیب‌پذیری آب‌های زیرزمینی نسبت به آلودگی استفاده از مدل‌های وزندهی است. در این روش‌ها، پارامترها بر اساس تأثیری که بر آلودگی آب زیرزمینی دارند، امتیازدهی می‌شوند (۲۱). متداول‌ترین مدل وزندهی برای ارزیابی آسیب‌پذیری ذاتی آبخوان، استفاده از روش دراستیک است. واژه دراستیک از هفت پارامتر دخیل در این مدل تشکیل شده است که عبارتند از: ۱- عمق تا سطح ایستابی، ۲- تغذیه خالص، ۳- محیط آبخوان، ۴- محیط خاک، ۵- توپوگرافی، ۶- محیط غیراشباع و ۷- هدایت هیدرولیکی آبخوان. هدف مطالعات آسیب‌پذیری آب زیرزمینی، تهیه نقشه و تعیین مناطقی با پتانسیل بالای آسیب‌پذیری می‌باشد. استفاده از روش مناسب برای تهیه نقشه پهنه‌بندی آسیب‌پذیری در یک منطقه بستگی به وجود داده‌ها و توزیع آن‌ها، موقعیت هیدروژئولوژیکی، مقیاس و هدف نقشه دارد (۶). برای تهیه نقشه پهنه‌بندی آسیب‌پذیری آبخوان می‌توان از محیط GIS استفاده نمود. در محیط GIS امکان تلفیق مجموعه

که در آن، R رتبه و W وزن هر عامل می‌باشد (۳۶). حساسیت کم‌تر را نشان می‌دهد. در نهایت با رتبه‌بندی شاخص دراستیک بزرگ‌تر نشان‌دهنده حساسیت بیش‌تر منطقه نسبت به آلودگی می‌باشد و عدد کوچک‌تر (۲۶).

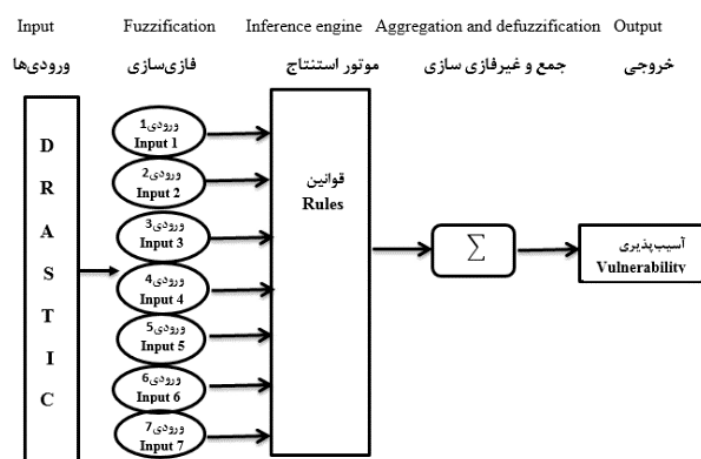
جدول ۱- طبقه‌بندی و نرخ‌گذاری پارامترهای مدل دراستیک (۳).

Table 1. Classification and rating of DRASTIC parameters (3).

رتبه Rating	بازه Range	رتبه Rating	بازه Range
W=5	Vadose zone محیط غیراشباع	W=5	عمق تا سطح ایستابی (متر) Depth to water table (m)
9	Karstic aquifer آبخوان کارستی	10	0-1.5
8	Sand ماسه	9	1.5-4.6
7	Silty sand ماسه سیلتی	7	4.6-9.1
6	Clay sand ماسه رسی	5	9.1-15.2
5	Sandy silt سیلت ماسه‌ای	3	15.2-22.9
4	Sandy clay رس ماسه‌ای	2	22.9-30.5
3	Silty clay رس سیلتی	1	>30.5
2	Marl and clay مارن و رس		
1	Confining layer with dense clay لایه محصورکننده با رس متراکم		
W=4	تغذیه خالص (میلی متر بر سال) Net recharge (mm/year)	W=3	هدایت هیدرولیکی (متر بر روز) Hydraulic conductivity (m/day)
1	<51	1	<4.1
3	51-102	2	4.1-12.2
5	102-178	4	12.2-28
8	178-254	6	28-40
		8	40-80
		10	>80
W=2	Soil media محیط خاک	W=3	Aquifer media محیط آبخوان
10	Gravel or thin layer of soil گراول یا لایه نازک خاک	2	سیلت و رس Silt and clay
9	Sand ماسه	4	سیلت و رس با کمی ماسه و گراول Silt and clay with a little sand and gravel
8	Peat تورب	6	ماسه با مقداری سیلت و رس Sand with silt and clay
7	Dense clay رس متراکم	8	ماسه و گراول Sand and gravel
6	Sandy loam لوم ماسه‌ای	W=1	توپوگرافی (درصد) (%) Topography
5	loam لوم	10	0-2
4	Silty loam لوم سیلتی	9	2-6
3	Clay loam لوم رسی	5	6-12
2	Fertilizer کود	3	12-18
1	non condensing clay رس غیر متراکم	1	>18

است: الف) فازی کردن داده‌ها که این عمل با تعریف تابع عضویت انجام می‌شود، ب) ایجاد ارتباط بین ورودی و خروجی که این کار نیز با یک سری قوانینی مانند اگر-آن‌گاه (if-then) انجام می‌پذیرد، ج) مرحله آخر، بررسی سیستم است که به دو روش ممدانی^۲ یا سوگنو^۳ قابل اجراست. تفاوت این دو روش در خروجی آن‌هاست که در روش سوگنو بر خلاف روش ممدانی تابع عضویت خروجی سیستم فازی، به صورت ثابت یا رابطه خطی است (۶). ساختار مدل منطق فازی در شکل ۲ نشان داده شده است.

منطق فازی^۱: سیستم‌های فازی مبتنی بر قواعد منطقی شرط- نتیجه است که با استفاده از مفهوم متغیرهای زبانی و روند تصمیم‌گیری فازی، فضای متغیرهای ورودی را بر فضای متغیرهای خروجی تصویر می‌کند (۲). توانایی پیاده‌سازی دانش بشری با استفاده از مفاهیم برجسب‌های زبانی و قواعد فازی، غیرخطی بودن، قابلیت سازش‌پذیری این سیستم‌ها و دقت بهتر آن‌ها در مقایسه با سایر روش‌ها در شرایط محدودیت داده‌ها، از جمله مهم‌ترین ویژگی‌های این سیستم‌ها است (۳۴). هر سیستم فازی شامل سه بخش اصلی



شکل ۲- ساختار مدل منطق فازی (۱۳).

Figure 2. Structure of the fuzzy logic (FL) model (13).

دسته است. در نهایت تعداد قواعد با تعداد خوشه‌ها برابر خواهد بود. از نظر مفهومی خوشه‌بندی به معنی افراز داده‌ها به زیر مجموعه‌ها یا خوشه‌های مجزا است، به نحوی که داده‌های یک خوشه تا حد امکان به هم شبیه و در عین حال متفاوت از داده‌های خوشه‌های دیگر باشند (۲۲). از آن‌جا که ایجاد سیستم استنتاج فازی به صورت غیر خودکار وقت‌گیر و دشوار است و غالباً به نتایج پذیرفتنی و معقولی نمی‌انجامد، به روشی نیاز است که بتوان با آن توابع عضویت و قوانین فازی را به صورت خودکار استخراج کرد (۸).

خوشه‌بندی: یکی از نکات بسیار مهم در طراحی سیستم‌های فازی، انتخاب تعداد مناسب قواعد است. انتخاب تعداد زیادی از قواعد باعث پیچیده شدن سیستم می‌شود و انتخاب تعداد کمی از قواعد ممکن است سیستم فازی ضعیفی را ایجاد کند که اهداف مورد نظر را تامین نکند. علت اصلی خوشه‌بندی، گروه‌بندی زوج‌های ورودی- خروجی در دسته‌های مختلف و استفاده از یک قاعده یا قانون فازی برای هر

- 1- Fuzzy logic
- 2- Mamdani
- 3- Sugeno

برای هر داده یک درجه عضویت تعیین می‌کند. با به‌هنگام کردن مراکز و درجه عضویت‌ها برای هر داده، FCM مراکز خوشه‌ها را تصحیح می‌کند. این تکرار بر پایه کمینه کردن تابع هدف می‌باشد که در این‌جا تابع هدف، فاصله هر داده از مرکز خوشه‌ها می‌باشد که البته این مراکز خوشه‌ها به‌وسیله درجه عضویت هر داده وزن‌دهی می‌شوند (۲۷). با تصویر کردن هر خوشه بر روی محورهای مختصات می‌توان به توابع فازی موردنظر دست یافت. در این روش، هر خوشه به‌دست آمده به‌عنوان یک قانون فازی که فضای ورودی را به فضای خروجی مرتبط می‌کند، در نظر گرفته می‌شود (۸). روش خوشه‌بندی FCM سازگارترین روش با سیستم استنتاج فازی ممدانی می‌باشد که توسط نیوتن و همکاران (۱۹۹۲) و لی (۲۰۰۴) بحث شده است (۲۰ و ۲۹). برای ارزیابی آسیب‌پذیری با استفاده از مدل MFL^۲ در این مطالعه، قانون فازی i به‌صورت زیر بیان می‌شود:

$$\text{Rule } i: \text{if } (D \text{ is } MF_D^i) \text{ And } (R \text{ is } MF_R^i) \text{ And } (A \text{ is } MF_A^i) \text{ And } (S \text{ is } MF_S^i) \text{ And } (T \text{ is } MF_T^i) \text{ And } (I \text{ is } MF_I^i) \text{ And } (C \text{ is } MF_C^i), \quad (2)$$

then $(Vul_i \text{ is } MF_{Vul}^i)$

احتمال را بر مبنای تراکم داده‌های مجاور، محاسبه می‌کند. این روش در چند مرحله انجام می‌شود:

- ۱- یافتن داده‌ای که بیش‌ترین پتانسیل اولین مرکز بودن را دارا می‌باشد ۲- جدا کردن همه داده‌های مجاور اولین مرکز، به‌وسیله شعاع مشخص شده، به‌منظور مشخص کردن خوشه و مرکز خوشه بعدی
- ۳- تکرار این مراحل تا زمانی که همه داده‌ها در شعاع مراکز قرار گیرند (۲۷). سیستم استنتاج فازی سوگنو، توابع عضویت ثابت یا خطی را به‌کار می‌برد. خوشه‌های ورودی و توابع عضویت خروجی توسط فرایند خوشه‌بندی تعیین می‌شود. روش خوشه‌بندی کاهشی،

به‌علاوه برای بسیاری از کاربردها امکان دسترسی به کارشناس وجود ندارد. بدین‌ترتیب استخراج خودکار توابع عضویت و قوانین فازی از طریق خوشه‌بندی می‌تواند پاسخگویی مشکلاتی از این دست باشد (۳۹). خوشه‌بندی داده‌های عددی، مبنای بسیاری از طبقه‌بندی‌ها و الگوریتم‌های مدل‌سازی می‌باشد. در ادامه دو روش خوشه‌بندی به اختصار شرح داده می‌شوند.

خوشه‌بندی به روش FCM^۱: یک روش خوشه‌بندی داده‌ها است که در آن به هر داده یک خوشه یا یک مقدار تعلق، اختصاص داده می‌شود. این مقدار تعلق با درجه عضویت مشخص می‌شود (۲۷). با داشتن مجموعه‌ای از داده‌های ورودی و خروجی و خوشه‌بندی آن‌ها می‌توان سیستم استنتاج فازی را به‌صورت خودکار ایجاد کرد (۸). در این روش ابتدا یک حدس اولیه، که به احتمال بسیار زیاد نادرست می‌باشد، برای مرکز خوشه، زده می‌شود تا به‌وسیله آن مکان میانگین هر خوشه به‌دست آید. در ضمن FCM

که در آن، Vul_i خروجی قانون i ، MF_D^i تابع عضویت خوشه i ام ورودی D ، MF_R^i تابع عضویت خوشه i ام ورودی R و ... می‌باشد. عملگر (minimize) And برای توابع عضویت ورودی و عملگر Or (maximize) برای خروجی قوانین استفاده می‌شود.

خوشه‌بندی کاهشی (Subtractive Clustering): این روش برای به‌دست آوردن مراکز خوشه‌ها به‌وسیله خوشه‌بندی کاهشی می‌باشد. روش خوشه‌بندی کاهشی بر این پایه استوار است که فرض می‌کند هر داده این پتانسیل را دارد که مرکز خوشه شود (۱۸) و این

1- Fuzzy C-Means
2- Mamdani Fuzzy Logic

منجر به قوانین کم‌تری می‌شود. مدل سوگنو بدون تعداد کافی قوانین نمی‌تواند سیستم کاملی را ارائه دهد و به همین ترتیب سیستمی با تعداد زیاد قوانین، پیچیده خواهد شد و دقت کمی خواهد داشت. بنابراین شعاع خوشه‌بندی باید بهینه شود تا قوانین و خوشه‌های مناسب ایجاد گردد (۶). برای ارزیابی آسیب‌پذیری با استفاده از مدل SFL^۱ در این مطالعه، قانون فازی I به صورت زیر بیان می‌شود:

$$\text{Rule } i: \text{if } (D \text{ is } MF_D^i) \text{ And } (R \text{ is } MF_R^i) \text{ And } (A \text{ is } MF_A^i) \text{ And } (S \text{ is } MF_S^i) \text{ And } (T \text{ is } MF_T^i) \text{ And } (I \text{ is } MF_I^i) \text{ And } (C \text{ is } MF_C^i), \quad (3)$$

$$\text{then } Vul_i = m_i D + n_i R + p_i A + q_i S + u_i T + k_i I + l_i C + c_i$$

می‌باشد. $m_i, n_i, p_i, q_i, u_i, k_i, l_i, c_i$ ضرایبی هستند که به وسیله تخمین حداقل مربعات خطی تعیین می‌شوند. خروجی نهایی میانگین وزنی تمام قوانین می‌باشد:

$$Vul = (\sum_i W_i Vul_i) / (\sum_i W_i) \quad (4)$$

عناصر عملیاتی ساده‌ای ساخته می‌شوند که به صورت موازی در کنار هم عمل می‌کنند (۱۹). اصول زیر نشانگر اساس شبکه‌های عصبی مصنوعی می‌باشند:

- ۱- پردازش داده‌ها در واحدهای منفردی به نام نرون صورت می‌گیرد.
- ۲- سیگنال‌های بین نرون‌ها از طریق خطوط ارتباطی انتقال می‌یابند.
- ۳- وزن نسبت داده شده به هر خط ارتباطی نشانگر قدرت ارتباطی آن خط است.
- ۴- هر نرون به‌طور معمول دارای توابع فعال‌سازی و تبدیل‌گر برای تعیین سیگنال‌های خروجی از داده‌های ورودی شبکه می‌باشد (۶). اکثر شبکه‌های عصبی دارای سه لایه و یا بیش‌تر می‌باشند. لایه ورودی، که برای ورود داده‌ها به شبکه استفاده می‌شود، لایه خروجی، برای تولید پاسخ‌های مناسب به ورودی‌های داده شده و یک یا تعداد بیش‌تر لایه حدواسط که از گره‌های پردازشگر تشکیل شده‌اند و محل پردازش داده‌ها به‌شمار می‌روند. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به

روشی مؤثر برای مدل استنتاج فازی سوگنو، جهت استخراج قوانین اگر-آن‌گاه می‌باشد (۶). مهم‌ترین پارامتر در خوشه‌بندی کاهشی که تعداد خوشه‌ها و قوانین را کنترل می‌کند، شعاع خوشه‌بندی است که می‌تواند مقادیری بین ۰ و ۱ داشته باشد. کاهش شعاع خوشه‌بندی، تعداد خوشه‌ها را افزایش می‌دهد و منجر به تشکیل خوشه‌های کوچک می‌شود. در مقابل شعاع بزرگ‌تر، خوشه‌های بزرگ در داده‌ها ایجاد می‌کند و

که در آن، Vul_i خروجی قانون MF_D^i تابع عضویت خوشه i ام ورودی D ، MF_R^i تابع عضویت خوشه i ام ورودی R و...

که در آن، W_i وزن قانون i که توسط عملگر And به‌دست می‌آید.

شبکه‌های عصبی مصنوعی (Artificial Neural Networks): شبکه‌های عصبی مصنوعی، یکی از روش‌های محاسباتی هستند که با الگوبرداری از سیستم کارکرد مغز انسان، با پردازش داده‌های تجربی و بدون توجه به فیزیک مسأله به‌منظور یادگیری و ایجاد دانش، قانون نهفته در ورای اطلاعات را استخراج می‌کنند (۲). شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات توده‌ای هستند که به‌صورت موازی قرار گرفته‌اند و عملکردی شبیه شبکه عصبی مغز انسان دارند (۱۶). هم‌چنین شبکه عصبی مصنوعی با شناخت روابط ذاتی و قوانین میان داده‌ها، فضای ورودی را به فضای خروجی تصویر می‌کند. مشخصه‌های قابل‌توجه شبکه‌های عصبی، قابلیت یادگیری آن‌ها است (۱۵). این شبکه‌ها از

از شبکه پرسپترون چندلایه که از تعداد بیش‌تری لایه میانی تشکیل شده استفاده می‌شود. در شبکه پرسپترون چندلایه، هر لایه شامل تعدادی نرون با توابع تبدیل متفاوت می‌باشد. مراحل انجام شده در یک شبکه توسط الگوریتم‌های ریاضی متفاوت صورت می‌گیرد که مهم‌ترین آن‌ها عبارتند از: ۱- الگوریتم انتشار خطا به عقب ۲- الگوریتم گرادیان مزدوج و ۳- الگوریتم لونیبرگ- مارکوآرت^۲، که از این میان الگوریتم لونیبرگ- مارکوآرت، کاراترین الگوریتم به‌شمار می‌رود (۵). روابط ریاضی برای یک شبکه عصبی مصنوعی سه لایه به‌صورت زیر است:


$$O_i = f_1(b_j + \sum_i W_{ji} I_i) \quad (5)$$

$$O_k = Vul = f_2(b_k + \sum_j W_{kj} O_j) \quad (6)$$

تنظیم مقادیر متوسط لایه ورودی و لایه خروجی به‌کار می‌روند. O_k خروجی شبکه عصبی (آسیب‌پذیری آب زیرزمینی) می‌باشد. شکل ۳ نمایانگر ساختار مدل شبکه عصبی است.

ماهیت مسأله مورد بررسی مشخص می‌شود، حال آن‌که شمار لایه‌های مخفی و تعداد نرون در هر لایه مخفی معمولاً به‌وسیله روش آزمون و خطا در جهت کاهش مقدار خطا توسط طراح مشخص می‌شود (۲۴). شبکه‌های عصبی مصنوعی به روش‌های مختلفی مانند چگونگی ارتباط نرون‌ها و حرکت داده‌ها در شبکه دسته‌بندی می‌شوند (۷). در این مطالعه از شبکه‌های پیشرو^۱ استفاده شده است. پرسپترون^۲ یکی از ساده‌ترین و پرکاربردترین نوع شبکه‌های عصبی پیشرو می‌باشد که به‌صورت پرسپترون تک‌لایه و چندلایه اجرا می‌شود (۳۳). پرسپترون تک‌لایه برای حل مسائل مجزای خطی قابل‌استفاده است. برای مسائل پیچیده‌تر

که در آن، f_1 و f_2 به‌ترتیب توابع فعال‌سازی برای لایه پنهان و لایه خروجی، I_i ورودی i ام، Q_j خروجی j ام، W_{ji} و W_{kj} وزن‌هایی که طول ارتباط بین ۲ لایه را کنترل می‌کنند و بایاس‌های b_j و b_k به‌ترتیب برای



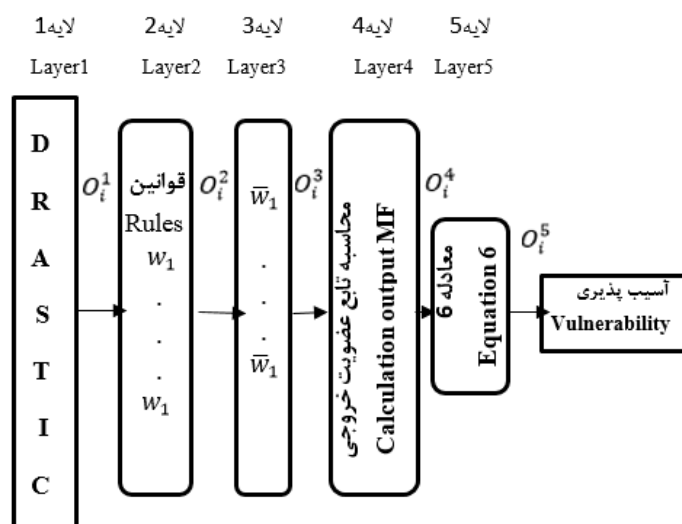
شکل ۳- ساختار مدل شبکه عصبی مصنوعی (۱۳).

Figure 3. Structure of the artificial neural network (ANN) model (13).

- 1- Feed forward Networks
- 2- Perceptron
- 3- Levenberg-Marquardt

دارد. در سامانه عصبی- فازی متناسب با داده‌های ورودی، درجه عضویت، قوانین و توابع درجه عضویت خروجی انتخاب می‌شود (۱۵). در حقیقت از شبکه عصبی مصنوعی برای تعیین قوانین و از فازی روش، شبکه عصبی مصنوعی به‌جای بهینه کردن وزن‌ها، قوانین فازی را بهینه می‌کند. در این روش تنها می‌توان از روش فازی سوگنو که خروجی آن ثابت یا خطی است، استفاده نمود (۶). ساختار مدل ANFIS از پنج لایه همانند شکل ۴ و به‌شرح زیر تشکیل می‌شود:

سیستم استنتاج تطبیقی عصبی فازی (Adaptive Neuro Fuzzy Inference System): ترکیب سیستم‌های استنتاج فازی که مبتنی بر قواعد منطقی بوده و روش شبکه‌های عصبی مصنوعی که توان استخراج دانش از اطلاعات عددی را دارند، منجر به ارائه سیستم استنتاج تطبیقی عصبی فازی می‌شود (۲). سیستم استنتاج تطبیقی عصبی- فازی از الگوریتم‌های شبکه عصبی و منطق فازی به‌منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند. این سیستم به‌عنوان ابزاری قدرتمند قابلیت پیش‌بینی نتایج با استفاده از داده‌های عددی موجود را



شکل ۴- ساختار مدل انفیس (۱۳).

Figure 4. Structure of the ANFIS model (13).

را با توجه به مجموعه‌های فازی مناسب تعیین می‌کند.

$$O_i^1 = \mu_{ji}(X) \quad i = 1, \dots, 7 \quad (V)$$

لایه دوم: با ضرب مقادیر ورودی به هر گره در یکدیگر، وزن هر قانون، در لایه دوم به‌دست می‌آید (W_i وزن قانون i ام است).

لایه اول (فازی سازی): هر گره از این لایه با استفاده از تابع عضویت، میزان تعلق هر ورودی

که در آن، j تعداد خروجی‌ها، i ایندکس تابع عضویت، X مجموعه ورودی $\{D,R,A,S,T,I,C\}$ و $\mu_{ji}(X)$ مجموعه فازی مرتبط با گره i می‌باشد.

$$O_i^2 = W_i = \mu_{1i}(X) \mu_{2i}(X) \mu_{3i}(X), \dots, \mu_{7i}(X) \quad (8)$$

به عنوان ضریب خطی جمله شرطی در نظر می گیریم (رابطه ۱۰).

لایه پنجم: در این لایه خروجی کلی با جمع کردن همه سیگنال های ورودی محاسبه می شود (رابطه ۱۱).

$$O_i^3 = \bar{W}_i = \frac{w_i}{\sum_i w_i} \quad i=1, \dots, 7 \quad (9)$$

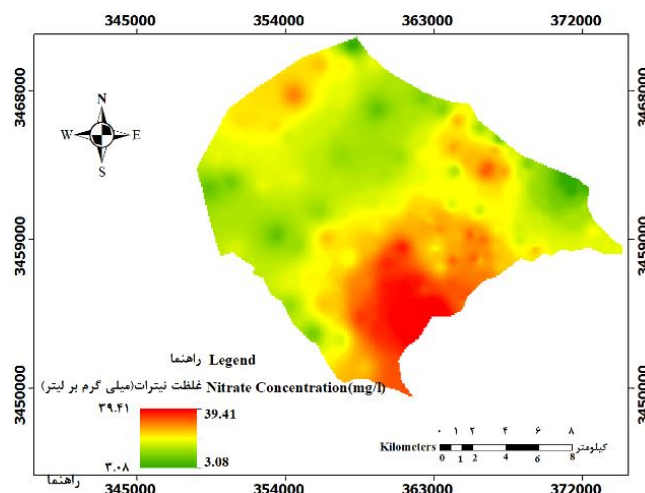
$$O_i^4 = \bar{W}_i \text{Vul} = \bar{W}_i (m_i D + n_i R + p_i A + q_i S + u_i T + k_i I + l_i C + c_i) \quad i=1, \dots, 7 \quad (10)$$

$$O_i^5 = \text{Vul} = \sum_i \bar{W}_i \text{Vul}_i \quad (11)$$

کودهای حیوانی و شیمیایی حاوی نیترات استفاده می شود، جهت ارزیابی نتایج مدل از داده های غلظت یون نیترات در آب زیرزمینی استفاده شده است. گام دوم بهینه سازی روش دراستیک توسط مدل های هوش مصنوعی شامل سیستم استنتاج فازی ممدانی، سیستم استنتاج فازی سوگنو، شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی - فازی می باشد. مهم ترین مرحله در پیاده سازی مدل های هوش مصنوعی آماده سازی داده هاست. ورودی مدل های هوش مصنوعی مشابه مدل دراستیک است، اگرچه خروجی آن ها شاخص آسیب پذیری تصحیح شده توسط داده های غلظت نیترات در منطقه مورد مطالعه است. هم چنین از داده های غلظت نیترات جهت مقایسه نتایج مدل ها استفاده شد. پهنه بندی داده های غلظت نیترات به روش درونیابی Spline در شکل ۵ نشان داده شده است.

لایه سوم: وظیفه گره های این لایه محاسبه وزن نرمالیزه هر یک از قوانین است (رابطه ۹).
لایه چهارم: خروجی های فازی صریح می شوند. به این صورت که مقادیر حقیقی از توابع عضویت به دست آمده و نسبت آن ها را که عددی حقیقی است،

در مرحله آموزش، با اصلاح پارامترهای درجه عضویت براساس میزان خطای قابل قبول، مقادیر خروجی به مقادیر واقعی نزدیک تر می شوند. روش های آموزش رایج، روش پسانتشار خطا و هیبرید است. در روش پسانتشار خطا با استفاده از الگوریتم شیب نزولی خطا، مقدار خطا به سمت ورودی ها پخش می گردد و پارامترها تصحیح می شوند. در روش هیبرید از ترکیب روش گرادیان نزولی و کم ترین مربعات خطا استفاده می شود. انتخاب تصادفی داده ها از جمله نکاتی است که در آموزش و تست شبکه ANFIS باید به آن ها توجه کرد (۱۸). در مطالعه حاضر مدل دراستیک توسط چهار مدل هوش مصنوعی بهینه سازی شده است. به این منظور، اولین گام ارزیابی آسیب پذیری آبخوان با مدل دراستیک است. با توجه به این که در منطقه مورد مطالعه، کشاورزی از رونق خاصی برخوردار است و غالباً از



شکل ۵- توزیع غلظت نیترات در منطقه مورد مطالعه.

Figure 5. Distribution of nitrate concentration in the study area.

نتایج دقیق‌تری نسبت به مدل دراستیک اولیه به دست آید. داده‌های مورد نیاز برای تهیه پارامترهای دراستیک از منابع مختلف، به فرمت مورد قبول نرم‌افزار ArcGIS درآمدند. همچنین به منظور تهیه نقشه‌های معیار مدل دراستیک آنالیزهای مکانی مختلفی بر روی داده‌های موجود در محیط GIS صورت گرفت. شکل‌های ۱۲-۶ نقشه‌های پارامترهای دراستیک را نشان می‌دهد. پس از آماده‌سازی لایه‌های هفتگانه مدل دراستیک، آسیب‌پذیری آبخوان آبرفتی دشت رامهرمز با استفاده از روش DRATIC، تعیین شد. این روش بر اساس وزن‌های استاندارد پارامترهای مدل دراستیک و لایه‌های به دست آمده برای هر یک از هفت پارامتر می‌باشد. با ضرب کردن لایه‌های به دست آمده برای هر پارامتر در وزن مربوط به آن پارامتر و جمع کردن آن‌ها طبق رابطه ۱، نقشه آسیب‌پذیری آبخوان به روش DRATIC حاصل گردید (شکل ۱۳). برای درک بهتر و نشان دادن وضعیت آسیب‌پذیری منطقه شاخص آسیب‌پذیری به سه کلاس مختلف طبقه‌بندی شده است. مقادیر شاخص دراستیک در این مطالعه بین ۴۸ تا ۱۵۶ قرار گرفت. این مدل با استفاده از داده‌های غلظت نیترات موجود در آبخوان مطابقت داده شد و ضریب

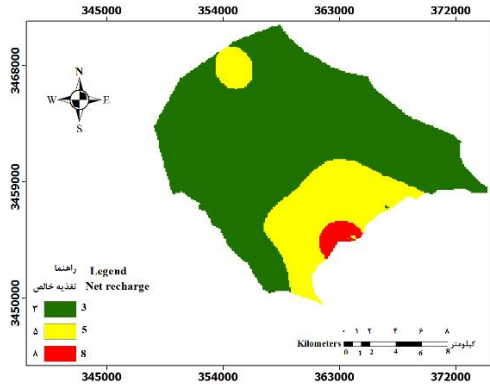
در این مطالعه، هدف نهایی، استفاده از روش‌های فازی، شبکه عصبی و سیستم استنتاج تطبیقی عصبی- فازی برای ارائه مدل‌هایی با کارایی بالاتر و بهبود روش دراستیک است. در این پژوهش، داده‌های ورودی مدل دراستیک و مقادیر نیترات مربوطه به دو دسته آموزش و آزمایش تقسیم شدند. ورودی مدل در مرحله آموزش، پارامترهای دراستیک و خروجی آن مقادیر تصحیح‌شده شاخص آسیب‌پذیری است. برای اجرای مرحله آزمایش مدل، پارامترهای دراستیک در داده‌های مربوط به این مرحله به عنوان ورودی در نظر گرفته شد و شاخص آسیب‌پذیری آب زیرزمینی به عنوان خروجی مدل برای این نقاط محاسبه گردید و نتایج حاصله با استفاده از غلظت یون نیترات، مورد ارزیابی قرار گرفت. در انتخاب داده‌های مربوط به مرحله آموزش و آزمایش سعی بر آن بود که این داده‌ها به صورت تصادفی از بین داده‌های مربوط به اندازه‌گیری‌های واقعی انتخاب شود.

نتایج و بحث

در پژوهش حاضر، سعی شده تا با استفاده از روش‌های هوش مصنوعی بهبود مدل دراستیک صورت بگیرد به طوری که با حفظ مزایای این روش،

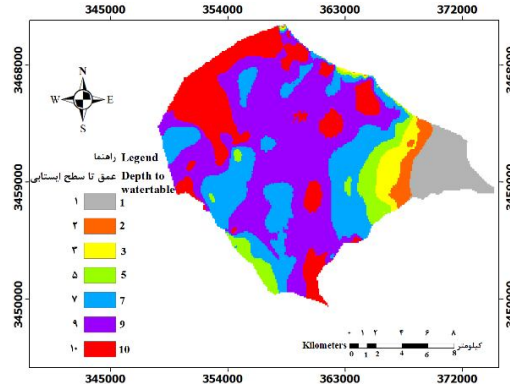
و سیستم استنتاج تطبیقی عصبی- فازی) انجام شد و چهار نقشه آسیب‌پذیری با استفاده از مدل‌های مختلف هوش مصنوعی تهیه شد.

همبستگی ۰/۹۷۵۶ بین شاخص دراستیک و غلظت نترات به‌دست آمد. به منظور بهبود نتایج مدل، تلفیق مدل دراستیک و چهار روش هوش مصنوعی (شبکه عصبی مصنوعی، منطق فازی شامل سوگنو و ممدانی،



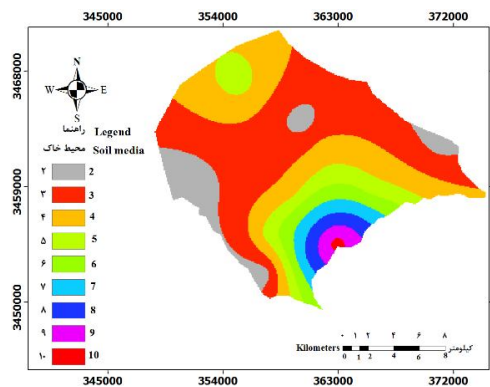
شکل ۷- لایه تغذیه خالص.

Figure 7. Net Recharge layer.



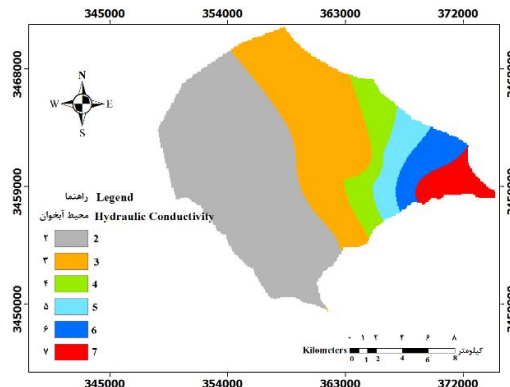
شکل ۶- لایه عمق تا سطح ایستابی.

Figure 6. Depth to Watertable layer.



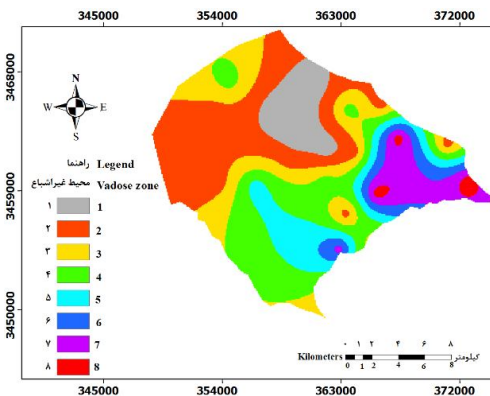
شکل ۹- لایه محیط خاک.

Figure 9. Soil Media layer.



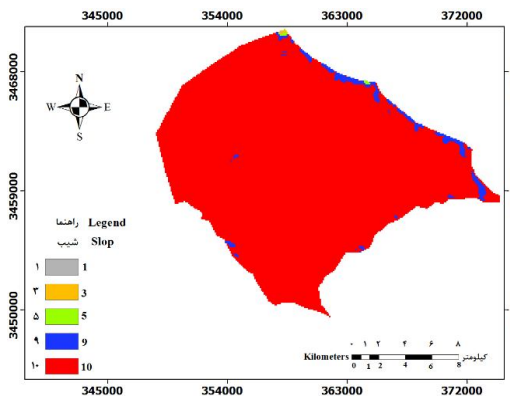
شکل ۸- لایه محیط آبخوان.

Figure 8. Aquifer Media layer.



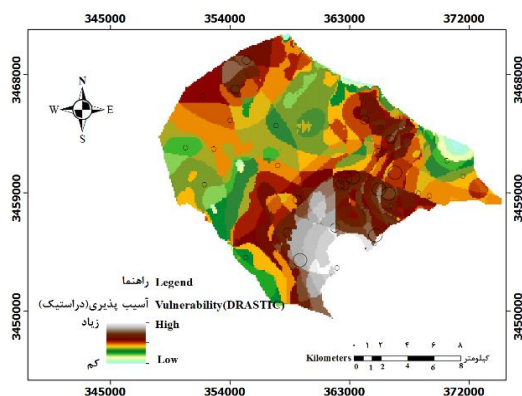
شکل ۱۱- لایه اثر محیط غیر اشباع.

Figure 11. Impact of the Vadose Zone layer.



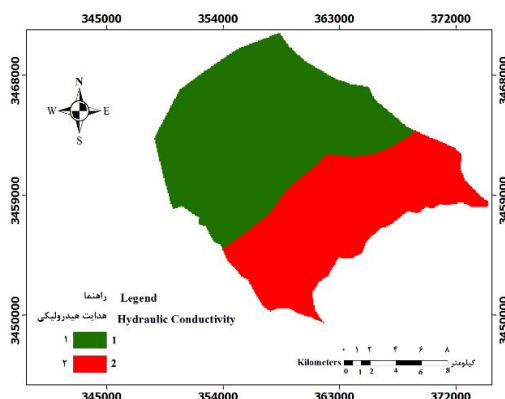
شکل ۱۰- لایه شیب.

Figure 10. Topography layer.



شکل ۱۳- نقشه آسیب‌پذیری آبخوان با مدل دراستیک.

Figure 13. The aquifer vulnerability map using DRASTIC model.

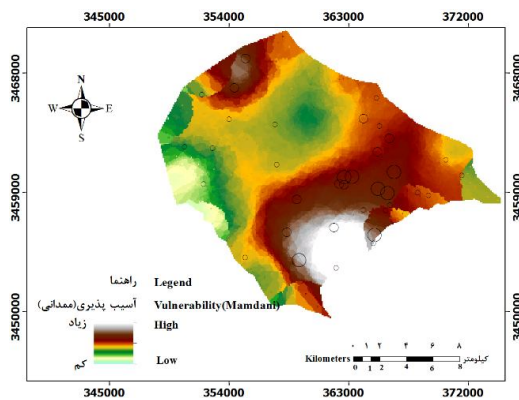


شکل ۱۲- لایه هدایت هیدرولیکی.

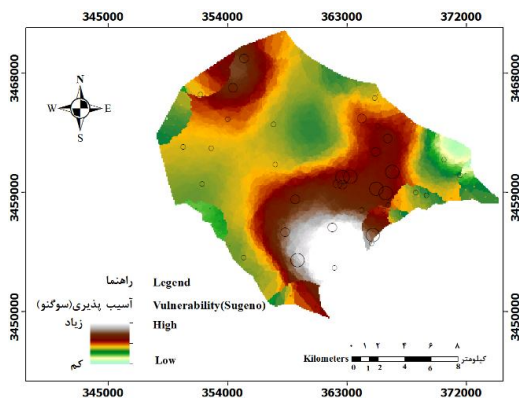
Figure 12. Hydraulic Conductivity.

به ترتیب ۰/۹۴ و ۴/۸۸ به دست آمد. نتیجه پیاده‌سازی مدل SFL در شکل ۱۴ نشان داده شده است. به منظور پیاده‌سازی روش MFL نیز از روش خوشه‌بندی FCM استفاده شد. ورودی‌های این مدل همانند مدل SFL، هفت پارامتر دراستیک می‌باشد. تابع عضویت ذوزنقه‌ای برای ورودی‌ها در نظر گرفته شد. در این مدل تعداد دسته‌ها برای پارامترهای ورودی و خروجی معادل ۲۳ انتخاب شده است. علت این امر این است که در این حالت بهترین نتیجه (کم‌ترین RMSE) حاصل می‌شود. از آنجایی که تعداد خوشه‌ها برابر تعداد قوانین است، پس تعداد ۲۳ قانون برای مدل MFL ایجاد شد. در انتها و به منظور تولید خروجی قطعی، از روش غیرفازی‌سازی مرکز ثقل استفاده شد. پس از پیاده‌سازی این مدل، در مرحله آموزش مقادیر RMSE و R^2 به ترتیب ۷/۸۴ و ۰/۸۷ به دست آمد. نتیجه پیاده‌سازی این مدل در شکل ۱۵ ارائه شده است.

نتایج پیاده‌سازی مدل‌های فازی: در این مطالعه از دو روش منطق فازی، سیستم استنتاج فازی ممدانی (MFL) و سیستم استنتاج فازی سوگنو (SFL) برای ارزیابی آسیب‌پذیری آبخوان دشت رامهرمز استفاده شده است. اولین گام در ایجاد مدل SFL خوشه‌بندی داده‌ها می‌باشد. همان‌طور که ذکر شد، از روش خوشه‌بندی کاهش‌ی برای این منظور استفاده می‌شود. در این روش، شعاع خوشه‌بندی که یکی از مهم‌ترین پارامترهای آن می‌باشد، براساس کم‌ترین میزان خطای جذر میانگین مربعات (RMSE)، معادل ۰/۴ انتخاب شد. با شعاع ۰/۴ بهترین نتیجه به دست آمد. در این مدل، داده‌های ورودی و خروجی به ۷ دسته یا خوشه تقسیم شدند، بنابراین ۷ قانون نیز ایجاد می‌شود. براساس توابع عضویت هفت پارامتر ورودی، یک مجموعه‌ای از قوانین فازی اگر-آن‌گاه ایجاد شد تا با جمع خطی ورودی‌ها، خروجی سیستم به دست آید. تابع عضویت ذوزنقه‌ای که بهترین تابع عضویت برای هفت پارامتر ورودی، جهت ارزیابی آسیب‌پذیری آب زیرزمینی می‌باشد، استفاده شد (۱۱). هم‌چنین تابع عضویت خطی برای خروجی انتخاب شد. با استفاده از مدل SFL مقادیر R^2 و RMSE در مرحله آموزش



شکل ۱۵- نقشه آسیب پذیری آبخوان با مدل ممدانی (MFL).
Figure 15. The aquifer vulnerability map using Mamdani model (MFL).

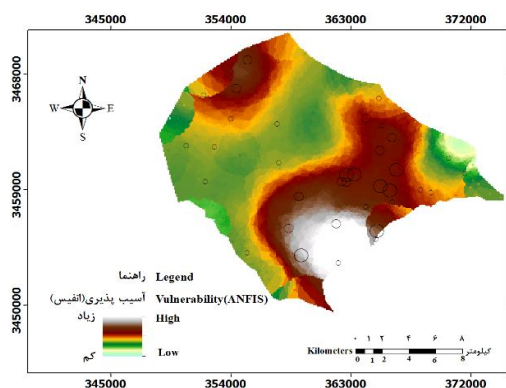


شکل ۱۴- نقشه آسیب پذیری آبخوان با مدل سوگنو (SFL).
Figure 14. The aquifer vulnerability map using Sugeno model (SFL).

نتایج مدل سیستم استنتاج تطبیقی عصبی- فازی: در این مطالعه مدل ANFIS برای ارزیابی آسیب پذیری، در کنار دیگر مدل‌ها استفاده شد. این ساختار که حاصل تلفیق شبکه عصبی با قوانین فازی است، از سیستم استنتاج سوگنو استفاده می‌کند. ساختار مناسب ANFIS متناسب با داده‌های ورودی، نوع تابع عضویت ورودی و خروجی، قوانین و تعداد تابع عضویت انتخاب می‌گردد. از آنجایی که مدل ANFIS در مواجهه با ورودی زیاد با مشکل روبه‌رو می‌شود، باید با پیش‌پردازش بر روی داده‌ها، آن‌ها را دسته‌بندی کرد. در این پژوهش این کار به روش خوشه‌بندی کاهشی مشابه مدل SFL انجام شد. بنابراین داده‌های ورودی و خروجی این مدل مشابه مدل SFL دسته‌بندی گردید. برای انجام خوشه‌بندی کاهشی بر روی داده‌ها محدوده تأثیر ۰/۴۵، نرخ قبول ۰/۵ و نرخ رد ۰/۱۵ انتخاب شد و این داده‌ها به‌عنوان ورودی به سیستم ANFIS وارد شدند. با توجه به ویژگی‌های تابع عضویت دوزنقه‌ای، نوع تابع عضویت نیز دوزنقه‌ای انتخاب شد. در این روش، تعداد قوانین برابر تعداد دسته‌ها خواهد بود. برای آموزش، بهینه و تنظیم پارامترهای توابع عضویت دوزنقه‌ای و ضرایب معادله خطی خروجی از الگوریتم هیبرید که ترکیبی از روش حداقل مربعات و روش

نتایج مدل شبکه‌های عصبی مصنوعی: در اجرای شبکه عصبی توابع متفاوت با آرایش نرون‌های مختلفی به‌صورت سعی و خطا مورد بررسی قرار گرفت. در نهایت یک شبکه سه لایه پرسپترون با الگوریتم لونیبرگ- مارکواریت برای پیش‌بینی آسیب‌پذیری آبخوان دشت رامهرمز استفاده شد. الگوریتم لونیبرگ- مارکواریت به دلیل خطای کم‌تر، به‌عنوان الگوریتم مناسب جهت بهینه‌سازی وزن‌ها و بایاس شبکه انتخاب گردید. هفت پارامتر دراستیک به‌عنوان ورودی در لایه اول وارد شدند. تعداد بیش از حد کوچک نرون‌های لایه پنهان منجر به تخمین کم‌تر از مقدار واقعی و زیادی بیش از حد نرون‌ها منجر به بیش‌برازش می‌شود (۱۰). بنابراین تعداد نرون‌ها در لایه میانی با آزمون و خطا برابر ۶ و در لایه خروجی برابر ۱ انتخاب شد. جهت ایجاد ساختار شبکه عصبی، توابع تبدیل مختلف با الگوریتم لونیبرگ- مارکواریت مورد بررسی قرار گرفتند و نتیجه مناسب زمانی حاصل شد که تابع تبدیل نرون‌ها در لایه دوم تابع سیگموئید تانژانتی و در لایه سوم تابع خطی باشد. بعد از ۴۶ دوره آموزش مقدار RMSE ثابت باقی ماند. مقادیر R^2 و RMSE مرحله آموزش در این روش ۴/۳۱ و ۰/۹۸ به‌دست آمد. نتیجه پیاده‌سازی مدل شبکه عصبی مصنوعی در شکل ۱۶ نشان داده شده است.

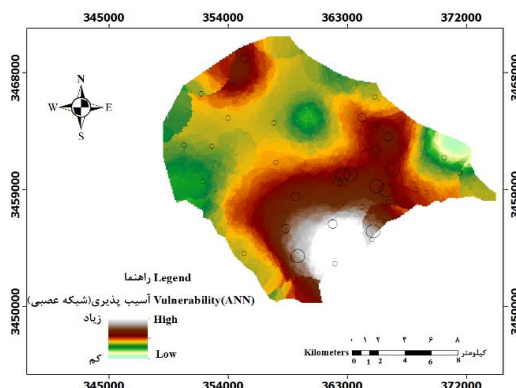
در شکل ۱۷ نشان داده شده است. جدول ۲ نتایج به‌دست آمده از روش‌های مختلف در مرحله آموزش و آزمایش را نمایش می‌دهد.



شکل ۱۷- نقشه آسیب‌پذیری آبخوان با مدل سیستم استنتاج تطبیقی عصبی- فازی (ANFIS).

Figure 17. The aquifer vulnerability map using Adaptive neuro fuzzy inference system model (ANFIS).

گرادیان نزولی انتشار به عقب است، استفاده شد (۴۲). RMSE و R^2 مدل در مرحله آموزش به ترتیب ۳/۱۱ و ۰/۹۹ محاسبه شد. نتیجه پیاده‌سازی مدل ANFIS



شکل ۱۶- نقشه آسیب‌پذیری آبخوان با مدل شبکه عصبی.

Figure 16. The aquifer vulnerability map using Neural Networks model.

جدول ۲- نتایج حاصل از مدل‌های مختلف هوش مصنوعی در مرحله آموزش و آزمایش.

Table 2. The results of the various artificial intelligence models in the training and test step.

مدل (Model)				معیار (Criteria)	مرحله (Step)
MFL	SFL	ANN	ANFIS	RMSE (خطای برآورد)	آموزش (Training)
7.84	4.88	4.31	3.11	R^2 (ضریب تعیین)	
0.87	0.94	0.98	0.99	RMSE (خطای برآورد)	آزمایش (Test)
7.95	5.01	4.6	3.54	R^2 (ضریب تعیین)	
0.76	0.91	0.97	0.98		

سه دسته کم، متوسط و زیاد تقسیم گردید. تعداد نمونه‌های نیتراتی که دقیقاً روی محدوده مربوط به خودشان در نقشه‌های آسیب‌پذیری، می‌افتند در ۳ ضرب می‌شوند. تعداد نمونه‌هایی که اختلاف (سطح) غلظت نیترات و آسیب‌پذیری آن‌ها ۱ یا ۲ است به ترتیب در ۲ و ۱ ضرب می‌شوند. سپس مقادیر به‌دست آمده با هم جمع می‌شود. نتیجه، شاخص همبستگی (Correlation Index) نام دارد که می‌تواند همبستگی بین نتایج مدل‌ها و غلظت نیترات

مقایسه نتایج مدل‌ها در پیش‌بینی آسیب‌پذیری آب زیرزمینی: همان‌طور که قبلاً گفته شد، غلظت نیترات به‌عنوان نشانگری جهت نمایش صحت شاخص آسیب‌پذیری در منطقه مورد مطالعه، که بیانگر شرایط واقعی است، به‌کار می‌رود. برای این منظور از روشی خاصی جهت تشخیص بهتر نتایج مدل‌ها که فیجانی و همکاران (۲۰۱۳) در مطالعه خود به‌کار بردند، استفاده شد (۱۳). در ابتدا غلظت نیترات و آسیب‌پذیری به‌دست آمده از روش‌های مختلف در این مطالعه، به

را نشان دهد (۱۳). مقادیر بالای CI نشان‌دهنده همبستگی بیش‌تر است. شاخص همبستگی نیترات با سه سطح آسیب‌پذیری پیش‌بینی شده توسط مدل‌های دراستیک، MFL، SFL، ANN و ANFIS در جدول ۳ نشان داده شده است.

جدول ۳- انطباق نمونه‌ها با سه سطح آسیب‌پذیری و غلظت نیترات (واحد= تعداد نمونه‌ها).

Table 3. Coincidence of samples with three contamination levels and nitrate concentration (unit = number of samples).

شاخص همبستگی Correlation Index	غلظت نیترات Nitrate concentration			
	کم Low	متوسط Moderate	زیاد High	
دراستیک DRASTIC				
85			زیاد High	
	5	5	4	متوسط Moderate
	8	5	3	کم Low
	7	0	0	
منطق فازی سوگنو Sugeno fuzzy logic				
91			زیاد High	
	3	1	1	متوسط Moderate
	5	9	5	کم Low
	12	0	0	
منطق فازی ممدانی Mamdani fuzzy logic				
90			زیاد High	
	3	1	2	متوسط Moderate
	6	9	5	کم Low
	10	0	0	
شبکه عصبی مصنوعی Artificial Neural Network				
92			زیاد High	
	2	1	2	متوسط Moderate
	6	9	5	کم Low
	11	0	0	
انفیس ANFIS				
93			زیاد High	
	2	2	1	متوسط Moderate
	5	10	4	کم Low
	12	0	0	

نتیجه‌گیری کلی

طبق نتایج به‌دست آمده از مدل‌های مختلف هوش مصنوعی (جدول ۲)، می‌توان گفت که تمام مدل‌های به‌کار رفته در این پژوهش، برای ارزیابی آسیب‌پذیری آب زیرزمینی مناسب هستند. مدل‌های اصلاح‌شده دراستیک، به‌وسیله مقادیر واقعی نترات اعتبارسنجی شدند. اگرچه در این مطالعه از روش‌های مختلفی برای تلفیق داده‌ها استفاده شده است اما چون پایه و اساس همه نقشه‌های به‌دست آمده، لایه‌های مدل دراستیک است، تفاوت خیلی زیادی در نقشه‌های نهایی مشاهده نمی‌گردد. با توجه به نتایج شاخص همبستگی بین چهار مدل هوش مصنوعی و غلظت نترات، مدل ANFIS بهترین مدل برای تخمین ریسک آلودگی آبخوان می‌باشد. طبق نقشه نهایی به‌دست آمده از این مدل، نواحی جنوب تا

جنوب‌شرقی دارای بیش‌ترین میزان پتانسیل آلودگی هستند. ضریب تعیین (R^2) برای مدل‌های سیستم استنتاج تطبیقی عصبی- فازی، شبکه عصبی و مدل‌های فازی سوگنو و ممدانی به‌ترتیب ۰/۹۹، ۰/۹۴، ۰/۹۸ و ۰/۸۷ به‌دست آمد. با توجه به اهمیت منابع آب زیرزمینی در منطقه مورد مطالعه، حفاظت از این منابع در مقابل آلودگی و مدیریت بهینه امری کاملاً ضروری است. نتایج حاصل از این پژوهش نشان می‌دهد که رویکرد به‌کار رفته، یک تخمین قابل‌قبول از ریسک آلودگی منطقه مورد مطالعه را ارائه می‌دهد. با اصلاح و بهبود مدل دراستیک، این امکان وجود دارد تا آسیب‌پذیری واقعی منطقه نسبت به آلودگی با دقت بیش‌تری، پیش‌بینی شود.

منابع

- Ahmadi, J., Akhondi, L., Abbasi, H., Khashei-Siuki, A., and Alimadadi, M. 2013. Determination of aquifer vulnerability using DRASTIC model and a single parameter sensitivity analysis and acts and omissions (Case study: Salafchegan-Neyzar Plain). *J. Water Soil Cons.* 20: 3. 1-25. (In Persian)
- Ahmadzadeh Gharah Gwiz, K., Mirlatifi, S., and Mohammadi, K. 2010. Comparison of Artificial Intelligence Systems (ANN & ANFIS) for Reference Evapotranspiration Estimation in the Extreme Arid Regions of Iran. *J. Water Soil.* 24: 4. 679-689. (In Persian)
- Aller, L., Bennet, T., Lehr, J.H., Petty, R.J., and Hackett, G. 1987. DRASTIC: a standardized system for evaluating groundwater pollution using hydrological settings. Ada, OK, USA: Prepared by the National Water Well Association for the US EPA Office of Research and Development.
- Antonakos, A.K., and Lambrakis, N.J. 2007. Development and testing of three hybrid methods for the assessment of aquifer vulnerability to nitrates, based on the drastic model, an example from NE Korinthia, Greece. *J. Hydrol.* 333: 288-304.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. Artificial neural network in hydrology, part I and II. *J. Hydrol. Engin.* 5: 115-137.
- Asghari Moghaddam, A., Fijani, A., and Nadiri, A. 2015. Optimization of DRASTIC model by Artificial Intelligence for Groundwater Vulnerability Assessment in Maraghe-Bonab Plain. *Engineering and Environmental Geology.* 24: 94. 169-176. (In Persian)
- Asghari Moghaddam, A., Nadiri, A., and Fijani, A. 2010. Spatial Prediction of Fluoride Concentration Using Artificial Neural Networks and Geostatic Models. *Water and soil science.* 19: 2. 129-145. (In Persian)
- Aslani, M., Alesheikh, A.A., and Shad, R. 2011. Landslide Susceptibility Mapping, Using Fuzzy Inference System and GIS (Case study: Sections of Mazandaran Province). *Iran. J. Rem. Sens. GIS.* 2: 2. 35-54. (In Persian)

9. Baghapour, M., Nasser, T., Sayed Hamidreza, T., and Amir, F. 2014. Assessment of groundwater nitrate pollution and determination of groundwater protection zones using DRASTIC and composite DRASTIC (CD) models: the case of Shiraz unconfined aquifer. *J. Health Sci. Surv. Sys.* 2: 2. 54-65.
10. Demuth, H., Beale, M., and Hagan, M. 2010. *Neural Network Toolbox™ 6 User's guide*.
11. Dixon, B. 2005a. Applicability of neuro-fuzzy techniques in predicting groundwater vulnerability: a GIS-based sensitivity analysis. *J. Hydrol.* 309: 1-4. 17-38.
12. Dixon, B. 2005b. Groundwater vulnerability mapping: a GIS and fuzzy rule based integrated tool. *J. Appl. Geograph.* 25: 327-347.
13. Fijani, E., Nadiri, A.A., Asghari Moghaddam, A., Tsai, F., and Dixon, B. 2013. Optimization of DRASTIC method by supervised committee machine artificial intelligence to assess groundwater vulnerability for Maragheh–Bonab plain aquifer, Iran. *J. Hydrol.* 503: 89-100.
14. Guo, O., Wnag, Y., Gao, X., and Ma, T. 2007. A new model (DRARCH) for assessing groundwater vulnerability to arsenic contamination at basin scale: a case study in Taiyuan basin, northern China. *Environmental Geology.* 52: 5. 923-32.
15. Hooshangi, N., and Alesheikh, A.A. 2015. Evaluation of ANN, ANFIS and fuzzy systems in estimation of solar radiation in Iran. *J. Geomat. Sci. Technol.* 4: 3. 187-200. (In Persian)
16. Hopfield, J.J. 1982. Neural network and physical systems with emergent collective computational abilities. *Proceeding of National Academy of scientists.* 79: 2554-2558.
17. Karami shahmaleki, N., Behbahani, S.M., Masahbavani, A., and Khodai, K. 2010. Optimization of DRASTIC model by statistical nonparametric methods. *Iran. J. Geol.* 4: 14. 73-82. (In Persian)
18. Khazaii, A., Al Sheikh, A., Karimi, M., and Hassan Vahidnia, M. 2012. Prediction and modeling of carbon monoxide concentration with the combination of an adaptive neuro-fuzzy network and GIS. *J. Appl. RS & GIS Techniq. Natur. Resour. Sci.* 3: 3. 21-35. (In Persian)
19. Kia, M. 2011. *Neural networks in MATLAB*. Kian Rayan Sabz Press. (In Persian)
20. Lee, K.H. 2004. *First Course on Fuzzy, Theory and Applications*. Springer, Berlin, 335p.
21. Legrand, H.E. 1964. System for evaluating the contamination potential of some waste sites. *J. AWWA.* 56: 959-974.
22. Li-Xin Wang, A. 1997. *Course in Fuzzy Systems and Control*, Prentice Hall PTR. Pp: 192-205.
23. Merchant, J. 1994. GIS-based groundwater pollution hazard assessment: a critical review of the DRASTIC model. *Photogrammetric Engineering and Remote Sensing.* 60: 9. 1117-1127.
24. Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S., and Dawei, H. 2009. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources.* 32: 88-97.
25. Motkan, A.A., Naseri, H.R., and Ostad Hashemi, Z. 2008. Correction of DRASTIC method based on GIS using statistical methods and Analytical Hierarchy Process: A Case Study of Hamadan plain. *Iran. J. Appl. Geol.* 4: 3. 205-222. (In Persian)
26. Nakhaii, M., Amiri, V., and Rahimi Shahrehabaki, M. 2013. Evaluation of the contamination potential and sensitivity analysis using DRASTIC model based on GIS. *J. Adv. Appl. Geol.* 3: 8. 1-10. (In Persian)
27. Nazifkar, M., and Asghari, K. 2011. Adaptive Neuro-fuzzy inference system using fuzzy clustering in runoff predicting. *The Sixth National Congress of Civil Engineering, Semnan University, Iran.* (In Persian)
28. Neshat, A., Biswajeet, P., and Mohsen, D. 2014. Groundwater vulnerability assessment using an improved DRASTIC method in GIS. *J. Resour. Cons. Recycl.* 86: 74-86.
29. Newton, S.C., Pemmaraju, S., and Mitra, S. 1992. Adaptive fuzzy leader clustering of complex data sets in pattern recognition. *IEEE Transactions on Neural Networks.* 5: 794-800.
30. 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. *Hydrogeol. J.* 14: 894-911.

31. Report of Knowledge studies of available water resources in the Ramhormoz study area. 2006. Ministry of Power, Khuzestan Water and Electricity Company. April, Khuzestan. (In Persian)
32. Report of weather, climate and water resources in Khuzestan province. 2009. General Directorate of economic studies and surveys. Winter, Khuzestan. (In Persian)
33. Sabziparvar, A.A., and Bayat Varkeshi, M. 2011. Evaluation of artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS) methods in prediction of global solar radiation. 10: 4. 347-357. (In Persian)
34. Sabziparvar, A.A., Zare Abyaneh, H., and Bayat Varkeshi, M. 2010. A model Comparison between Predicted Soil Temperatures Using ANFIS Model and Regression Methods in Three Different Climates. J. Water Soil. 24: 2. 274-285. (In Persian)
35. Sajadi, Z., Kalantari, N., Makvandi, M., Keshavarzi, M., Ghafari, H., Ahmadnejad, Z., and Booslik, Z. 2011. Study of the aquifer vulnerability in Assaluee using DRASTIC model. First national conference on water and wastewater science and technology. Islamic Azad University of Ahwaz, April. (In Persian)
36. Samey, A.A., and Gang, C. 2008. A GIS Based DRASTIC Model for the Assessment of Groundwater vulnerability to pollution in West Mitidja: Blida city, Algeria. Res. J. Appl. Sci. 3: 7. 500-507.
37. Sener, E., and Sehnaz, S. 2015. Evaluation of groundwater vulnerability to pollution using fuzzy analytic hierarchy process method. J. Environ. Earth Sci. 73: 12. 8405-8424.
38. Soper, R.C. 2006. Groundwater vulnerability to agrochemicals: A GIS-based DRASTIC model analysis of Carrol, Chariton, and Saline Counties, Missouri, USA. M.Sc. Thesis, University of Missouri-Columbia.
39. Sugeno, M., and Yasukawa, T. 1993. A Fuzzy-Logic-based Approach to Qualitative Modeling. IEEE Transactions on Fuzzy Systems. 1: 1. 7-31.
40. Vrba, J., and Zaporozec, A. 1994. Guidebook on Mapping Groundwater Vulnerability. International Association of Hydrogeologists-International Contributions to Hydrogeology 16 Water and Environ. J. 26: 3. 381-391.
41. Yarmohamadi, A., Chitsazan, M., and Rangzan, K. 2006. Calculation of the amount of DRASTIC model Parameters impact on Aghili plain aquifer vulnerability. Twenty-fifth Conference on Earth Sciences, Geological survey of Iran, Tehran. (In Persian)
42. Zounemat-Kermani, M., and Teshnehlab, M. 2008. Using adaptive neuro-fuzzy inference system for hydrological time series prediction. Applied Soft Computing. 8: 2. 928-936.



Improve the results of the DRASTIC model using artificial intelligence methods to assess groundwater vulnerability in Ramhormoz alluvial aquifer plain

***N. Ghanbari¹, K. Rangzan², M. Kabolizade³ and P. Moradi¹**

¹M.Sc. Graduate, Dept. of Remote Sensing and Geographic Information System, University of Shahid Chamran, Ahvaz, ²Associate Prof., Dept. of Remote Sensing and Geographic Information System, University of Shahid Chamran, Ahvaz, ³Assistant Prof., Dept. of Remote Sensing and Geographic Information System, University of Shahid Chamran, Ahvaz

Received: 06/27/2016; Accepted: 06/10/2017

Abstract

Background and Objectives: Groundwater pollution is a complex and full of uncertainty process, on a regional scale. Development of an integrated method for assessing groundwater vulnerability, can be efficient in order to optimized management and protection of them. Because of fertile soil and sufficient water resources, Ramhormoz plain is suitable area for agriculture that by development of agriculture, use of chemical fertilizers and pesticide, this plain always is at risk of contamination. One of the suitable approach to prevent groundwater contamination, identify areas of potential contamination. The aim of this study is to produce vulnerability map of Ramhormoz plain alluvial aquifer using DRASTIC model and then use artificial intelligence techniques to improve the results of the DRASTIC model. Due to the importance of groundwater resources in the study area that are used for various purposes including agriculture, Aquifer vulnerability study and protect these areas for development and management of water resources is essential.

Materials and Methods: In this study, first, vulnerability evaluation of Ramhormoz alluvial aquifer plain was performed using DRASTIC model and in the following, artificial intelligence methods was used to optimize the model. DRASTIC model includes the following parameters: depth to water table, net recharge, aquifer media, soil media, topography, impact of vadose zone and hydraulic conductivity that are effective in groundwater vulnerability assessment. This method, based on the standard weights of DRASTIC model and obtained layers for each of the seven parameters, calculates the amount of aquifer vulnerability. After preparation of the layers, vulnerability of Ramhormoz alluvial aquifer plain was determined using drastic model. Also the groundwater vulnerability map and DRASTIC index was calculated for the entire area. In order to evaluation of accuracy of the obtained results from the model, nitrate concentration data existing in groundwater have been used for verification. Following In order to improve results, DRASTIC model was integrated by artificial neural networks, fuzzy logic (Sugeno and Mamdani) and Adaptive Neuro-Fuzzy Inference System methods and four vulnerability maps was obtained using different models of artificial intelligence.

Results: The groundwater vulnerability map toward the contamination was prepared by the division into three vulnerability ranges including low, medium and high and DRASTIC index was calculated for the entire area between 48 and 156. Correlation coefficient 0.97 between DRASTIC index and nitrate concentration reflects the relatively good accuracy of this method. Also, the results of the implementation of these models showed that the used artificial intelligence models have the ability to improve the primary DRASTIC model results. By comparing the results of the models can be concluded that the Adaptive Neuro-Fuzzy Inference System model has the best result.

Conclusion: The determination coefficient, R², for the Adaptive Neuro-Fuzzy Inference System, neural networks and Mamdani fuzzy and Sugeno fuzzy models, is 0.99, 0.94, 0.98 and 0.87 respectively. According to the final model, South- Southeast regions have the highest potential for contamination.

Keywords: Groundwater vulnerability, DRASTIC model, Geographic information system, Artificial intelligence

* Corresponding Author; Email: ghanbari_nazanin70@yahoo.com

