

## ارزیابی چند مدل هوش مصنوعی برای پیش‌بینی کیفیت آب زیرزمینی (مطالعه موردی: دشت گرو)

مجتبی دولت کردستانی<sup>۱</sup>، احمد نوحه‌گر<sup>۲\*</sup>، سعید جانی‌زاده<sup>۳</sup>

تاریخ دریافت: ۱۳۹۶/۰۱/۲۰

تاریخ پذیرش: ۱۳۹۶/۰۹/۲۴

### چکیده

مدل‌سازی مناسب کیفیت آب‌زیرزمینی از ابزارهای مهم برنامه‌ریزی و تصمیم‌گیری در مدیریت منابع آب است. در این مطالعه به منظور مدل‌سازی تغییرات متغیرهای کیفی آب‌زیرزمینی دشت گرو از داده‌های ۱۴ چاه در دوره آماری (۱۳۸۸ تا ۱۳۹۵) استفاده شد. متغیرهای Na، Mg، Ca، SO<sub>4</sub>، Cl و HCO<sub>3</sub> به‌عنوان متغیر مستقل و EC، SAR، TDS و TH به‌عنوان متغیر وابسته در نظر گرفته شد. از روش‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی - فازی تطبیقی برای مدل‌سازی استفاده شد. نتایج حاصل از مدل‌سازی نشان داد که شبکه عصبی مصنوعی - فازی تطبیقی در متغیرهای EC ( $R^2=0/99$ ،  $RMSE=109/13$ ) و SAR ( $R^2=0/98$ ،  $RMSE=0/28$ ،  $CE=0/98$ ) و TH ( $R^2=0/99$ ،  $RMSE=0/49$ ،  $CE=0/99$ ) نسبت به دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان عملکرد بهتری دارد و در متغیر TDS مدل شبکه عصبی مصنوعی ( $R^2=0/99$ ،  $RMSE=109/13$ ،  $CE=0/99$ ) نسبت به دو مدل دیگر کارایی بهتری داشته است. پهنه‌بندی بر اساس دو طبقه‌بندی کیفیت آب شرب شور و کشاورزی و یلکوکس نشان داد که متغیر TDS دارای سه طبقه نامناسب (۲۱/۱٪)، بد (۷۴/۵۹٪) و غیرقابل شرب (۴/۳۱٪) و متغیر TH دارای ۴ طبقه خوب (۰/۸۵٪)، قابل قبول (۲۳/۴۸٪)، نامناسب (۶۷/۵۵٪) و بد (۸/۱۲٪) و بر اساس طبقه‌بندی یلکوکس نیز متغیر EC دارای سه طبقه عالی (۹/۴۱٪)، خوب (۸۹/۷۹٪) و متوسط (۰/۸٪) و متغیر SAR دارای دو طبقه عالی (۱۹٪) و خوب (۸۱٪) است.

**واژه‌های کلیدی:** پهنه‌بندی، شبکه عصبی - فازی تطبیقی، شبکه عصبی مصنوعی، کیفیت آب زیرزمینی و ماشین بردار پشتیبان.

۱. راتبه دانشگاه جیرفت، بخش مرتع و آبخیزداری، دانشکده علوم کشاورزی و منابع طبیعی دانشگاه جیرفت

۲. استاد گروه برنامه‌ریزی، مدیریت و آموزش محیط زیست، دانشکده محیط زیست دانشگاه تهران، نویسنده مسئول / nohegar@ut.ac.ir

۳. دانشجوی دکتری مهندسی آبخیزداری، باشگاه پژوهشگران جوان و نخبگان دانشگاه آزاد اسلامی واحد اردبیل

## مقدمه

است. عیسی‌زاده و همکاران (۲۰۱۶) به ارزیابی عملکرد روش‌های زمین‌آمار و شبکه عصبی مصنوعی در تخمین پارامترهای کیفی دشت قروه پرداختند. نتایج تحقیق آنان نشان داد که شبکه عصبی مصنوعی کارایی بهتری در تخمین پارامترهای کیفی آب دارد. میرزاوند و همکاران (۲۰۱۵) مقدار غلظت کلر آبخوان کاشان را که در معرض جبهه آب شور دریاچه نمک قرار داشت، با استفاده از شبکه عصبی مصنوعی MLP و RBF مورد ارزیابی قرار دادند. نتایج شبیه‌سازی آنان نشان داد که عملکرد مدل MLP بهتر از مدل RBF بوده است. ادیب و زمانی (۲۰۱۵) تغییرات مکانی شاخص‌های کیفی آب‌زیرزمینی دشت دزفول را با استفاده از روش‌های زمین‌آمار مورد بررسی قرار دادند. نتایج حاصل از تحقیق آنان نشان داد که روش کوکریجینگ بهترین روش زمین‌آمار برای پهنه‌بندی کیفی دشت دزفول است و نتایج حاصل از پهنه‌بندی حاکی از وضعیت نامطلوب کیفی منابع آب‌زیرزمینی در قسمت‌های جنوب شرقی و شرقی دشت است. زارع ایبانه و همکاران (۲۰۱۱) مقدار نیترا را با استفاده از شبکه عصبی مصنوعی با سه ترکیب مختلف در دشت همدان-بهار مورد ارزیابی قرار دادند. نتایج بررسی آنان نشان داد هر سه ترکیب کارایی بالایی در تخمین نیترا در این دشت را دارد. چادوری<sup>۷</sup> و همکاران (۲۰۱۰) کارایی شبکه عصبی مصنوعی و روش کریجینگ معمولی را جهت درون‌یابی مقدار آرسینک مورد ارزیابی قرار دادند. نتایج آنان نشان داد که مدل شبکه عصبی مصنوعی عملکرد بهتری نسبت به روش کریجینگ داشته است. طاهری تیزرو<sup>۸</sup> و همکاران (۲۰۱۴) به بررسی تغییرات مکانی کیفیت آب‌زیرزمینی در دشت زیرین‌آباد زنجان با استفاده از روش‌های زمین‌آمار پرداختند. بررسی آنان نشان داد که روش کوکریجینگ در مقایسه با روش IDW عملکرد بهتری در بررسی تغییرات مکانی EC و SAR داشته است. نورانی<sup>۹</sup> و همکاران (۲۰۱۶) از مدل‌های شبکه عصبی مصنوعی به‌منظور پیش‌بینی تغییرات زمانی و مکانی کیفیت آب زیرزمینی (EC و SAR) استفاده کردند. نتایج حاصل از این تحقیق نشان داد که

در شرایط کنونی، بخش قابل ملاحظه‌ای از مصارف آب کشور ایران به‌خصوص در بخش شرب توسط منابع آب‌زیرزمینی تأمین می‌شود (خدایی و همکاران، ۲۰۰۶). بهره‌برداری از منابع آب‌زیرزمینی، مستلزم آگاهی از وضعیت کمی و کیفی آبخوان‌هاست. با تعیین کیفیت شیمیایی آب‌های زیرزمینی می‌توان برآوردی از وضعیت سلامت این منابع آبی به دست آورد و متناسب با وضعیت آن، نوع کاربری آن را مشخص کرد (هیگون و لینگ<sup>۱</sup>، ۲۰۰۸). در این زمینه می‌توان از روش‌های مستقیم و غیرمستقیم برای آگاهی از خصوصیات کیفی آب استفاده کرد. روش‌های مستقیم علی‌رغم دقت بالایی که دارند به‌علت ارزش بسیار بالای داده‌های مشاهداتی، به‌کارگیری آن‌ها مستلزم صرف زمان طولانی و صرف هزینه است. ازاین‌رو روش‌های غیرمستقیم متعددی برای شبیه‌سازی سیستم‌های طبیعی و برآورد پارامترهای آن با استفاده از کامپیوتر و بر اساس محاسبات پیچیده ابداع شده است. از جمله این روش‌ها مدل‌سازی یا شبیه‌سازی هیدرولوژیکی است. این فرایندها در محدوده زمان و مکان بیشترین تغییرات را داشته و شبیه‌سازی آن‌ها به‌لحاظ سرشت غیرخطی و ابعاد زیاد، همواره با مشکلات زیادی همراه است. امروزه به‌کارگیری و ترکیب روش‌های هوشمند همچون شبکه عصبی مصنوعی<sup>۲</sup>، شبکه عصبی-فازی تطبیقی<sup>۳</sup>، منطق فازی<sup>۴</sup> و الگوریتم ژنتیک<sup>۵</sup> برای کنترل سیستم‌ها بسیار موردتوجه قرار گرفته است (عبقری، ۲۰۰۸). مزیت عمده این روش‌ها، امکان بهره‌گیری از قابلیت یادگیری سری‌های زمانی و پیش‌بینی است. از خصوصیات مهم روش‌های هوش مصنوعی، توانایی آن‌ها در برقرار کردن ارتباط بین ورودی و خروجی یک فرایند بدون در نظر گرفتن فیزیک آن مسئله است (وفاخواه<sup>۶</sup>، ۲۰۱۲). این توانایی هوش مصنوعی در مطالعات هیدروژئولوژی و مخصوصاً در زمینه برآوردهای کیفی مرتبط با آن‌ها به‌طور ویژه‌ای موردتوجه محققان مختلف قرار گرفته

1. Huiqun and Ling
2. Artificial Neural Network(ANN)
3. Adaptive Neuro-fuzzy Inference System (ANFIS)
4. Fuzzy Logic
5. Genetic Algorithm
6. Vafakhah

7. Chowdhury  
8. Taheri Tizro  
9. Nourani

۵۷ درجه و ۱۵ دقیقه تا ۵۷ درجه و ۲۷ دقیقه طول شرقی و در ۲۶ درجه و ۴۸ دقیقه تا ۲۶ درجه و ۵۶ دقیقه عرض شمالی واقع شده است. این دشت در فاصله ۱۴۰ کیلومتری شرق بندرعباس و ۴۰ کیلومتری جنوب شرق میناب قرار گرفته است. دشت گرو همانند اغلب دشت‌های جنوب کشور در قلمرو مناطق خشک قرار گرفته است. که به سبب جبر جغرافیایی حاکم بر منطقه میزان بارندگی آن کم و رگباری است. جریان‌های سطحی این دشت از طریق رودخانه زرانی به دریای عمان ریخته می‌شود. بر اساس اطلاعات گردآوری شده از ایستگاه کیماتولوژی مازابی، دمای متوسط سالانه این منطقه ۲۶/۹ درجه سانتی‌گراد و مقدار بارندگی سالانه ۲۰۲ میلی‌متر است. این دشت تحت تأثیر ویژگی‌های زمین‌شناسی و ژئومورفولوژی، نفوذپذیری اندکی دارد و تغذیه آب‌های زیرزمینی آن فقط در قسمت‌های کم‌شیب و مسطح دشت صورت می‌گیرد. علاوه بر تغذیه نامناسب، بهره‌برداری بیش از ظرفیت از منابع آبی آن، باعث تنزل کمی آبخوان دشت شده است (عقیفی و همکاران، ۲۰۱۲). شکل (۱) موقعیت مکانی دشت گرو واقع در استان هرمزگان و در قسمت جنوبی ایران را به همراه موقعیت چاه‌های مورد مطالعه را نشان می‌دهد.

### روش تحقیق

در این تحقیق مدل‌سازی متغیرهای کیفی آب زیرزمینی دشت گرو بر پایه استفاده از داده‌های ۱۴ چاه مشاهده‌ای با طول دوره آماری ۸ سال (۱۳۸۷-۱۳۸۸ تا ۱۳۹۴-۱۳۹۵) که از شرکت سهامی آب منطقه‌ای استان هرمزگان تهیه شده بود، صورت گرفت. که پس از بررسی‌های انجام شده مجموعاً ۱۴۱ نمونه انتخاب گردید. متغیرهای استفاده شده در این تحقیق شامل  $\text{Na}$ ،  $\text{Mg}$ ،  $\text{Ca}$ ،  $\text{SO}_4$ ،  $\text{Cl}$  و  $\text{HCO}_3$  به عنوان متغیر مستقل و  $\text{EC}$ ،  $\text{SAR}$ ،  $\text{TDS}$  و  $\text{TH}$  به عنوان متغیر وابسته در نظر گرفته شد. بر این اساس مقادیر کیفی متغیرهای  $\text{EC}$ ،  $\text{SAR}$ ،  $\text{TDS}$  و  $\text{TH}$  برای یک دوره ۸ ساله، که ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای آزمون و با استفاده از روش‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی فازی تطبیقی برآورد خواهد شد. در شکل (۲) نمودار مراحل کار نشان داده شده است.

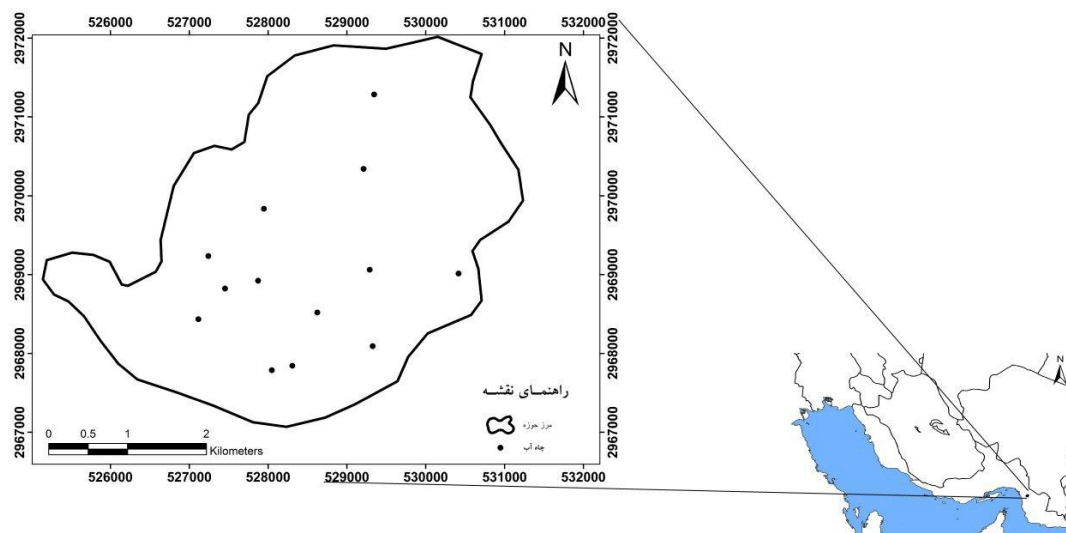
مدل پیش‌خور (FFNN) نسبت به مدل رگرسیون خطی چندگانه (MLR) عملکرد بهتری در پیش‌بینی تغییرات زمانی و مکانی کیفیت آب زیرزمینی دارد. جلالی<sup>۱</sup> و همکاران (۲۰۱۶) به بررسی کیفیت آب زیرزمینی دشت اراک با استفاده از روش‌های زمین آماری پرداختند. در این تحقیق، ۷ متغیر کیفی آب مورد بررسی قرار گرفت که نتایج تحقیق نشان داد که روش کریجینگ دقیق‌تر از روش‌های سنتی قادر به درون‌یابی متغیرهای کیفی در این دشت است. استفاده از هوش مصنوعی در دیگر زمینه‌های هیدرولوژیکی نیز مورد توجه قرار گرفت که در این زمینه می‌توان به مدل‌سازی بارش-رواناب (ال شافی<sup>۲</sup> و همکاران، ۲۰۱۱؛ کیشی<sup>۳</sup> و همکاران، ۲۰۱۲)، پیش‌بینی سطح آب زیرزمینی (شیرمحمدی<sup>۴</sup> و همکاران، ۲۰۱۳؛ موسوی<sup>۵</sup> و همکاران، ۲۰۱۳) و پیش‌بینی دبی روزانه و ماهانه (وانگ<sup>۶</sup> و همکاران، ۲۰۰۹؛ وفاخواه، ۲۰۱۲) اشاره کرد. بر اساس نتایج حاصل از مطالعات گذشته در این زمینه، می‌توان دریافت که روش‌های هوش مصنوعی را می‌توان به عنوان روشی کارآمد و برتر برای تخمین متغیرهای مختلف هیدرولوژیکی قلمداد نمود که با توجه به محدودیت‌های ابزار و فنون اندازه‌گیری پارامترهای هیدرولوژی و نیز محدودیت اطلاعات موجود، شبیه‌سازی متغیرهای کیفی امری اجتناب‌ناپذیر است. بنابراین، هدف از این تحقیق شناسایی توانایی مدل‌های هوشمند ماشین‌های بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی-فازی تطبیقی جهت مدل‌سازی متغیرهای کیفی آب زیرزمینی ( $\text{EC}$ ،  $\text{SAR}$ ،  $\text{TDS}$  و  $\text{TH}$ ) در دشت گرو و پهنه‌بندی این متغیرها است تا بتوان به کمک آن ابزار، مدیریتی مناسبی برای کنترل پارامترهای کیفی از نظر شرب و کشاورزی ارائه کرد.

### مواد و روش‌ها

#### منطقه مورد مطالعه

دشت گرو با وسعت ۱۷/۶۳ کیلومترمربع در محدوده جغرافیایی

1. Jalali
2. El-Shafie
3. Kisi
4. Shirmohammadi
5. Moosavi
6. Wang



شکل (۱): موقعیت دشت گرو و چاه‌های مورد مطالعه

Figure (1): The position of the Gero and the wells studied



شکل (۲): نمودار مراحل انجام تحقیق

Figure (2): Diagrams of research steps

زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین  $f$  به علاوه یک مقدار اضافی نویز مشخص شود. در این تحقیق با توجه به پرکاربرد بودن تابع کرنل شعاعی از این تابع استفاده شد. فرایند محاسبات ماشین بردار پشتیبان بر اساس کدنویسی در محیط Matlab انجام و پارامترهای تابع

شکل (۲) مراحل انجام تحقیق را به صورت خلاصه نشان می‌دهد، مراحل تهیه و تقسیم داده‌ها در قسمت روش تحقیق توضیح داده شده است. بقیه مراحل به شرح ذیل انجام شد.

### ماشین‌های بردار پشتیبان<sup>۱</sup>

در یک مدل رگرسیونی SVM لازم است وابستگی تابعی متغیر وابسته  $y$  به مجموعه‌ای از متغیرهای مستقل  $x$  تخمین

1. Sub Vector Machine (SVM)

کرنل از طریق سعی و خطا بهینه شد (یو و لیونگ<sup>۱</sup>، ۲۰۰۶).  
 استنتاج فازی ساگنوف با تابع ورودی تفاوت دو سیگموئید و تابع خروجی خطی با استفاده از نرم‌افزار Matlab انجام شد و برای غیر فازی نمودن از تابع میانگین متحرک استفاده شد (وفاخواه، ۲۰۱۲). در این تحقیق از دو روش تفکیک شبکه‌ای (با تابع عضویت‌های مثلثی، زنگوله‌ای تعمیم‌یافته) و تفکیک خوشه‌ای برای فازی‌سازی داده‌ها استفاده شد که تعداد دور آموزشی، ۱۰۰۰ دور در نظر گرفته شد.

### روش‌های پهنه‌بندی کیفی آب زیرزمینی

#### روش وزن‌دهی عکس فاصله (IDW)

روش IDW برای هر یک از نقاط اندازه‌گیری، وزنی بر اساس فاصله بین آن نقطه تا موقعیت نقطه مجهول در نظر می‌گیرد. سپس این وزن‌ها توسط عامل وزن‌دهی کنترل می‌شود. به طوری که توان‌های بزرگ‌تر اثر نقاط دورتر از نقطه مورد برآورد را کاهش داده و توان‌های کوچک‌تر وزن‌ها را به‌طور یکنواخت‌تری بین نقاط همجوار توزیع می‌کنند. مقدار عامل وزنی با استفاده از رابطه زیر محاسبه می‌شود:

$$\lambda_i = \frac{D_i - a}{\sum_{i=1}^n D_i - a} \quad (2)$$

که در آن،  $\lambda_i$  وزن ایستگاه  $i$  ام،  $D_i$  فاصله ایستگاه  $i$  ام تا نقطه مجهول و  $a$  توان وزن‌دهی است (ادیب و زمانی، ۲۰۱۵).

#### روش زمین‌آماری کریجینگ

کریجینگ برآوردگری است که بر منطق میانگین متحرک وزن‌دار استوار است، مقادیر یک متغیر را در نقاط نمونه‌برداری نشده به صورت ترکیبی از خطی از مقادیر همان متغیر در نقاط اطراف آن در نظر می‌گیرد. از نمونه‌ها وزنی نسبت داده و بهترین برآوردکننده خطی نااریب است (معادله ۳).

$$Z_0 = \sum_{i=1}^n \lambda_i Z(X_i) \quad (3)$$

که در آن،  $Z(X_i)$  مقدار اندازه‌گیری شده متغیر در مکان  $(X_i)$ ،  $Z_0$  مقدار برآورد شده متغیر در نقطه  $(X_i)$ ،  $\lambda_i$  وزن یا اهمیت کمیت وابسته به نمونه  $i$  ام که بر اساس مقدار کمیت وابسته به نمونه در نقاط معلوم، به پارامتر مورد نظر

### شبکه عصبی مصنوعی<sup>۲</sup>

شبکه‌های عصبی مصنوعی، قابلیت یادگیری، فراخوانی و تعمیم یافتن از الگوهای یادگیری داده‌ها را دارند. این شبکه‌ها می‌توانند برای یک عمل خاص با تعدیل وزن‌های بین عناصر، آموزش ببینند. معمولاً شبکه‌های عصبی آموزش می‌بینند تا یک ورودی خاص را به یک خروجی خاص تبدیل کنند (رید<sup>۳</sup> و همکاران، ۲۰۰۴).

برای جلوگیری از کوچک شدن بیش از حد وزن‌های شبکه‌های عصبی مصنوعی، ورودی‌های شبکه‌های عصبی مصنوعی باید استاندارد شوند (وفاخواه، ۲۰۱۲؛ ایمری<sup>۴</sup> و همکاران، ۲۰۰۰؛ حسینی و برهانی، ۲۰۰۹). در این تحقیق به منظور استانداردسازی داده‌ها از رابطه (۱) استفاده شد.

$$N_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

که در این رابطه،  $N_i$  مقادیر استاندارد شده،  $X_i$  مقادیر واقعی،  $X_{\min}$  حداقل مقادیر واقعی و  $X_{\max}$  حداکثر مقادیر واقعی است. این رابطه ورودی‌های شبکه عصبی را بین ۰ و ۱ نرمال می‌کند.

به منظور مدل‌سازی از شبکه پیش‌خور با الگوریتم آموزش انتشار خطا به عقب و توقف آموزش مورد استفاده قرار گرفت. و داده‌ها به دو دسته آموزش و آزمون تقسیم به طوری که ۸۰٪ داده‌ها برای آموزش و ۲۰٪ برای آزمون در نظر گرفته و از دو تابع سیگموئید و تابع تانژانت هیپربولیک در لایه میانی و از تابع خطی در لایه خروجی استفاده شد تعداد نورون‌ها از ۲ تا ۲۰ نورون متغیر بود و بهترین تعداد نورون به صورت سعی و خطا تعیین شد.

### شبکه عصبی فازی - تطبیقی<sup>۵</sup>

در طراحی مدل نروفازی، از شبکه عصبی چند لایه پیش‌خور (MFNN) با الگوریتم یادگیری پس‌انتشار خطا و سیستم

1. Yu and Liangs
2. Artificial Neural Network
3. Riad
4. Imrie
5. Adaptive Neuro-Fuzzy Inference System (ANFIS)

داده می‌شود و  $n$  تعداد نقاطی که اندازه‌گیری شده است معیارهای طبقه‌بندی شولر (جدول ۱) و ویلکوکس (جدول (زهتابیان و همکاران، ۲۰۱۰)).

پهنه‌بندی برای تمامی متغیرها، دشت از نظر کیفیت آب برای طبقه‌بندی کیفیت آب برای شرب و کشاورزی به ترتیب در بخش‌های شرب و کشاورزی طبقه‌بندی شد.

### روش طبقه‌بندی

جدول (۱): معیارهای طبقه‌بندی از نظر شرب (عسکری و همکاران، ۲۰۰۱)

TH (میلی‌گرم بر لیتر)	TDS (میلی‌گرم بر لیتر)	
<۲۵۰	<۵۰۰	خوب
۲۵۰-۵۰۰	۵۰۰-۱۰۰۰	قابل قبول
۵۰۰-۱۰۰۰	۱۰۰۰-۲۰۰۰	نامناسب
۱۰۰۰-۲۰۰۰	۲۰۰۰-۴۰۰۰	بد
۲۰۰۰-۴۰۰۰	۴۰۰۰-۸۰۰۰	تقریباً قابل شرب
>۴۰۰۰	>۸۰۰۰	غیرقابل شرب

جدول (۲): معیارهای طبقه‌بندی از نظر کشاورزی (عسکری و همکاران، ۲۰۰۱)

SAR	EC (دسی‌زیمنس بر متر)	
<۱۰	<۲۵۰	عالی
۱۰-۱۸	۲۵۰-۷۵۰	خوب
۱۸-۲۶	۷۵۰-۲۲۵۰	متوسط
>۲۶	>۲۲۵۰	نامناسب

### معیار ارزیابی مدل‌ها

به منظور مقایسه مدل‌های مورد استفاده در این تحقیق، از نمایه‌های آماری ضریب کارایی ناش-ساتکیف (CE) (رابطه ۴)، مجذور میانگین مربعات خطا (RMSE) (رابطه ۵) و ضریب تبیین (رابطه ۶) استفاده شد.

$$R^2 = \frac{\sum_{i=1}^n (Y_o - \bar{Y}_o)(Y_e - \bar{Y}_e)}{(\sum_{i=1}^n (Y_o - \bar{Y}_o)^2)^{0.5} (\sum_{i=1}^n (Y_e - \bar{Y}_e)^2)^{0.5}}$$

که در آن‌ها  $Y_o$  مقدار مشاهده‌ای متغیر وابسته، مقدار تخمینی متغیر وابسته،  $\bar{Y}_o$  میانگین مقدار مشاهده‌ای متغیر وابسته و میانگین مقدار تخمینی متغیر وابسته است.

### نتایج

برای مدل‌سازی متغیرهای کیفی آب زیرزمینی توسط مدل SVM لازم است که سه ضریب  $C$ ،  $\varepsilon$  و  $\gamma$  بهینه شوند. برای بهینه‌سازی این ضرایب از روش سعی و خطا استفاده شد. نتایج حاصل از تخمین پارامترهای SAR، EC، TDS و TH در دو دشت گرو و رودان در جدول (۳) نشان داده شده است

$$CE = 1 - \frac{\sum_{i=1}^n (Y_o - Y_e)^2}{\sum_{i=1}^n (Y_o - \bar{Y}_o)^2} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_o - Y_e)^2} \quad (5)$$

جدول (۳): نتایج حاصل از تخمین متغیرهای کیفی در مرحلهٔ آزمون

Table (3): The results of estimating the qualitative variables at the test stage

CE	RMSE	R <sup>2</sup>	ضریب $\gamma$	ضریب $\epsilon$	ضریب C	متغیر	دشت
۰/۹۸	۱۸۱/۲۸	۰/۹۹	۰/۱۶۷	۰/۱	۱۰	EC	گرو
۰/۷۱	۱/۷۱	۰/۹	۰/۲۳۹	۰/۱۵	۱۰	SAR	
۰/۹۸	۱۱۶/۱۲	۰/۹۹	۰/۲۱	۰/۱	۱۰	TDS	
۰/۹۷	۴۹/۵۹	۰/۹۸	۰/۲۷	۰/۲	۱۰	TH	

نتایج مدل‌سازی پارامترهای کیفی در دشت گرو نشان می‌دهد که مدل SVM با کارایی بالایی توانسته این متغیرها را برآورد کند. برای انتخاب ساختار بهینه شبکه عصبی مصنوعی، تعداد نرون لایهٔ میانی از ۱ تا ۲۰ برای دو تابع انتقال سیگموئید و تانژانت هیپربولیک در لایهٔ پنهان تغییر داده شد و در هر مرحله میزان خطا، کارایی و ضریب همبستگی محاسبه شد. در نهایت ساختاری که دارای کمترین خطا بود، به‌عنوان ساختار بهینه انتخاب شد. نتایج شبکه عصبی مصنوعی برای دو تابع سیگموئید و تانژانت هیپربولیک در جدول (۴) نشان داده شده است.

جدول (۴): نتایج حاصل از تخمین متغیرهای کیفی در مرحلهٔ آزمون

Table (4): The results of estimating the qualitative variables at the test stage

CE	RMSE	R <sup>2</sup>	تابع انتقال	آرایش شبکه	متغیر	دشت
۰/۹۸	۱۴۴/۵۹	۰/۹۸	سیگموئید	۶-۱۴-۱	EC	گرو
۰/۸	۶۰۴/۳۸	۰/۸۱	تانژانت هیپربولیک	۶-۶-۱		
۰/۸۳	۰/۸۸	۰/۸۵	سیگموئید	۶-۱۲-۱	SAR	
۰/۷۹	۰/۹۸	۰/۸۴	تانژانت هیپربولیک	۶-۹-۱		
۰/۹۶	۱۶۱/۰۸	۰/۹۷	سیگموئید	۶-۴-۱	TDS	
۰/۹۹	۱۳/۱۰	۰/۹۹	تانژانت هیپربولیک	۶-۴-۱		
۰/۹۹	۲/۷۵	۰/۹۹	سیگموئید	۶-۷-۱	TH	
۰/۹۹	۷/۱۴	۰/۹۹	تانژانت هیپربولیک	۶-۵-۱		

نتایج بررسی شبکه عصبی مصنوعی برای متغیرهای کیفی نشان می‌دهد که متغیر EC (با ضریب همبستگی ۰/۹۸، میانگین مربعات خطای ۱۴۴/۵۹ و ضریب کارایی ۰/۹۸)، SAR (با ضریب همبستگی ۰/۸۵، میانگین مربعات خطای ۰/۸۸ و ضریب کارایی ۰/۸۳) و TH (با ضریب همبستگی ۰/۹۹، میانگین مربعات خطای ۲/۷۵ و ضریب کارایی ۰/۹۹) تابع انتقال سیگموئید نسبت به تابع انتقال تانژانت هیپربولیک عملکرد بهتری داشته است و در متغیر TDS تابع انتقال هیپربولیک با ضریب همبستگی ۰/۹۹، میانگین مربعات خطای ۷/۱۴ و ضریب کارایی ۰/۹۹، خطای ۱۳/۱۰ و ضریب کارایی ۰/۹۹ عملکرد بهتری نسبت به تابع انتقال سیگموئید دارد. برای انجام مدل شبکه عصبی فازی-تطبیقی از دو تابع عضویت (مثلثی و زنگوله‌ای تعمیم‌یافته) و روش تفکیک خوشه‌ای با تعداد عضویت بهینه که با سعی و خطا تعیین شد استفاده گردید. در جدول (۵) نتایج حاصل از شبکه عصبی-فازی تطبیقی با نوع تابع عضویت نشان داده شده است.


جدول (۵): نتایج حاصل از تخمین متغیرهای کیفی در مرحلهٔ آزمون

Table (5): The results of estimating the qualitative variables at the test stage

CE	RMSE	R <sup>2</sup>	تابع عضویت	روش	متغیر	دشت
۰/۹۸	۱۷۵/۰۶	۰/۹۸	مثالی			
۰/۹۳	۳۵۶/۶۰	۰/۹۴	زنگوله‌ای	تفکیک شبکه‌ای	EC	
۰/۹۹	۱۰۹/۱۳	۰/۹۹		تفکیک خوشه‌ای		
۰/۹۷	۰/۳۶	۰/۹۷	مثالی			
۰/۳۸	۱/۷۱	۰/۵۸	زنگوله‌ای	تفکیک شبکه‌ای	SAR	
۰/۹۸	۰/۲۸	۰/۹۸		تفکیک خوشه‌ای		
۰/۹۸	۱۱۲/۰۳	۰/۹۸	مثالی			
۰/۹۷	۱۳۹/۹۱	۰/۹۷	زنگوله‌ای	تفکیک شبکه‌ای	TDS	
۰/۹۹	۲۲/۲۵	۰/۹۹		تفکیک خوشه‌ای		
۰/۹۸	۳۸/۰۲	۰/۹۸	مثالی			
۰/۹۳	۷۰/۵۵	۰/۹۳	زنگوله‌ای	تفکیک شبکه‌ای	TH	
۰/۹۹	۰/۴۹	۰/۹۹		تفکیک خوشه‌ای		

است. نتایج حاصل از تخمین پارامترهای کیفی آب زیرزمینی با استفاده از سه مدل SVM، شبکهٔ عصبی مصنوعی و شبکهٔ عصبی فازی- تطبیقی در شکل‌های (۳) تا (۶) نشان داده شده است.


با توجه به نتایج جدول (۳) مشاهده می‌شود که در مدل شبکهٔ عصبی- فازی تطبیقی روش تفکیک خوشه‌ای در مقایسه با روش تفکیک شبکه‌ای با داشتن ضریب کارایی، همبستگی بالا و میانگین مربعات خطا عملکرد بهتری در تخمین پارامترهای کیفی آب زیرزمینی در دشت گرو داشته



شکل (۳): نمودار مشاهداتی و تخمینی متغیر EC در مرحلهٔ آزمون


Figure (3): Observation and Estimated Chart EC in the test stage






شکل (۴): نمودار مشاهداتی و تخمینی متغیر SAR در مرحلهٔ آزمون

Figure (4): Observation and Estimated Chart SAR in the test stage



شکل (۵): نمودار مشاهداتی و تخمینی متغیر TDS در مرحلهٔ آزمون

Figure (5): Observation and Estimated Chart TDS in the test stage




شکل (۶): نمودار مشاهداتی و تخمینی متغیر TH در مرحلهٔ آزمون

Figure (6): Observation and Estimated Chart TH in the test stage

### نتایج پهنه‌بندی کیفی آب‌زیرزمینی


(با تابع انتقال تانژانت هیپربولیک) با داشتن کمترین خطا و ضریب کارایی بالا جهت پهنه‌بندی کیفیت آب زیرزمینی انتخاب و با استفاده از روش IDW در محیط نرم‌افزار 9.3 GIS انجام شد. شکل‌های ۷ تا ۱۰ نتایج حاصل از پهنه‌بندی و جداول ۶ و ۷ مساحت هر یک از طبقه‌های مختلف کیفیت آب زیرزمینی را در منطقه مورد مطالعه نشان می‌دهد.

پهنه‌بندی کیفیت آب‌زیرزمینی در دشت گرو پس از مدل‌سازی متغیرهای کیفی با استفاده روش‌های هوشمند و ارزیابی آن‌ها در مرحله آزمون، برای متغیرهای SAR، EC و TH مدل شبکه عصبی فازی- تطبیقی (روش تفکیک خوشه‌ای) و برای متغیر TDS مدل شبکه عصبی مصنوعی



شکل (۷): تغییرات مکانی متغیر TDS در دشت گرو بر مبنای طبقه‌بندی شولر

Figure (7): The spatial variations of the TDS variable in the Garoo plain based on the Schuler classification



شکل (۸): تغییرات مکانی متغیر TH در دشت گرو بر مبنای طبقه‌بندی شولر


Figure (8): The spatial variations of the TH variable in the Garoo plain based on the Schuler classification

جدول (۶): مساحت طبقه‌های مختلف کیفیت آب زیرزمینی براساس طبقه‌بندی شولر

Table (6): Groundwater quality area of different classes based on the Schuler classification


TH		TDS		وضعیت
مساحت (%)	مساحت (کیلومتر مربع)	مساحت (%)	مساحت (کیلومتر مربع)	
۰/۸۵	۰/۱۵	-	-	خوب
۲۳/۴۸	۴/۱۴	-	-	قابل قبول
۶۷/۵۵	۱۱/۹۱	۲۱/۱	۳/۷۲	نامناسب
۸/۱۲	۱/۴۳	۷۴/۵۹	۱۳/۱۵	بد
-	-	-	-	تقریباً قابل شرب
-	-	۴/۳۱	۰/۷۶	غیرقابل شرب

با توجه به نتایج حاصل از پهنه‌بندی متغیرهای کیفی TH و TDS در شکل‌های (۷) و (۸) و جدول (۶) مشاهده می‌شود که در متغیر TDS کیفیت آب زیرزمینی در سه طبقه نامناسب (۲۱/۱٪)، بد (۷۴/۵۹٪) و غیرقابل شرب (۴/۳۱٪) قرار دارد و بیشترین مساحت مربوط به طبقه کیفیت بد است. بررسی متغیر TH نشان داد که پهنه‌بندی کیفی آب زیرزمینی بر اساس این متغیر دارای ۴ طبقه خوب (۰/۸۵٪)، قابل قبول نامناسب (۲۳/۴۸٪)، نامناسب (۶۷/۵۵٪) و بد (۸/۱۲٪) است.



شکل (۹): تغییرات مکانی متغیر EC در دشت گرو بر مبنای طبقه‌بندی ویلکوکس

Figure (9): The spatial variations of the EC variable in the Garoo plain based on the Wilcox classification



شکل (۱۰): تغییرات مکانی متغیر SAR در دشت گرو بر مبنای طبقه‌بندی ویلکوکس

Figure (10): The spatial variations of the SAR variable in the Garoo plain based on the Wilcox classification

جدول (۷): مساحت طبقه‌های مختلف کیفیت آب زیرزمینی براساس طبقه‌بندی ویلکوکس

Table (7): Groundwater quality area of different classes based on the Wilcox classification

SAR		EC		وضعیت
مساحت (%)	مساحت (کیلومتر مربع)	مساحت (%)	مساحت (کیلومتر مربع)	
۱۹	۳/۳۵	۹/۴۱	۱/۶۶	عالی
۸۱	۱۴/۲۸	۸۹/۷۹	۱۵/۸۳	خوب
-	-	۰/۸	۰/۱۴	متوسط
-	-	-	-	نامناسب

جهت مدل‌سازی متغیرهای کیفیت آب زیرزمینی استفاده گردد، همچنین پهنه‌بندی متغیرهای کیفیت آب زیرزمینی بر اساس طبقه‌بندی‌های شرب و کشاورزی صورت گرفت تا علاوه بر بررسی نوسانات زمانی، تغییرات مکانی متغیرها نیز در سطح دشت مشخص و تحلیل گردد.

در این پژوهش، شبیه‌سازی متغیر کیفی آب زیرزمینی (EC، SAR، TDS و TH) با استفاده ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی فازی-تطبیقی در دشت گرو صورت گرفت. همان‌طور که از نتایج جداول (۳) تا (۵) بر می‌آید شبکه عصبی فازی تطبیقی جهت برآورد متغیرهای EC، SAR و TH دارای عملکرد بهتری نسبت به دو مدل شبکه عصبی مصنوعی و ماشین پشتیبان بردار است. شبکه عصبی فازی-تطبیقی سیستم را با کمک قواعد توصیف می‌کند که این قواعد در ساختاری شبکه‌ای پیاده‌سازی شده‌اند که می‌توانند الگوریتم‌های یادگیری مورد استفاده در شبکه عصبی مصنوعی را به آن‌ها اعمال کنند. به‌واسطه این ساختار است که مدل شبکه عصبی فازی-تطبیقی، برای تحلیل و تفسیر از شفافیت بیشتری برخوردار است. نتایج به‌دست‌آمده از این تحقیق با نتایج پژوهش‌های وفاخواه (۲۰۱۲)، ال شافی و همکاران (۲۰۱۱)، شیرمحمدی و همکاران (۲۰۱۳) و وانگ و همکاران (۲۰۰۹) همخوانی دارد. آن‌ها نیز نشان دادند که شبکه عصبی فازی-تطبیقی کارایی بالایی در مدل‌سازی فرایندهای هیدرولوژیک دارد. در متغیر TDS شبکه عصبی مصنوعی کارایی بهتری نسبت به دو مدل دیگر دارد. که این نتیجه با نتایج وفاخواه و همکاران (۲۰۱۱) مبنی بر شبیه‌سازی رواناب حاصل از ذوب برف به‌کمک شبکه عصبی مصنوعی و نروفازی در حوزه آبخیز طالقان همخوان است. آن‌ها نیز نشان

در اشکال (۹) و (۱۰) و جدول (۷) طبقات کیفیت آب زیرزمینی از لحاظ مصارف کشاورزی نشان داده شده است. با توجه به جدول (۷) مشاهده می‌شود که متغیر EC داری سه طبقه عالی (۹/۴۱٪)، خوب (۸۹/۷۹٪) و متوسط (۰/۸٪)، متغیر SAR دارای دو طبقه عالی (۱۹٪) و خوب (۸۱٪) است.

نقشه‌های پهنه‌بندی نشان می‌دهند که کیفیت آبخوان دشت گرو متناسب با هر یک از متغیرهای کیفی مورد بررسی در وضعیت متفاوتی قرار می‌گیرد. به‌طوری که این آبخوان بر اساس متغیر کیفی TDS و TH در شرایط بدتری نسبت به متغیرهای EC و SAR قرار می‌گیرد. تغییرات مکانی کیفیت آب در این آبخوان نشان‌دهنده تنزل کیفیت آب در قسمت غرب و جنوب غربی دشت نسبت به قسمت‌های جنوبی و جنوب شرقی آن است. دامنه تغییرات متغیرهای مورد بررسی در این تحقیق همچنین نشان می‌دهد که در متغیر TDS قسمت جنوب شرقی دشت بر اساس طبقه‌بندی شولر وضعیت کیفی آب مطلوب است، در حالی که بیشتر دشت از وضعیت نامطلوبی برخوردار بوده و در قسمت غربی دشت کیفیت آب غیرقابل شرب می‌باشد. در متغیر TH نیز بیشتر دشت کیفیت نامناسبی دارد و بهترین کیفیت آب در قسمت جنوب شرقی و بدترین کیفیت در قسمت غربی دشت است. بررسی متغیرهای EC و SAR بر اساس طبقه‌بندی کشاورزی ویلکوکس نشان می‌دهد که این دشت از لحاظ کیفیت آب کشاورزی در حد مطلوبی قرار دارد.

## بحث و نتیجه‌گیری

با توجه به اینکه پیش‌بینی و تعیین کیفیت آب زیرزمینی در برنامه‌ریزی و مدیریت آب زیرزمینی کمک شایانی می‌کند، در این پژوهش سعی شد که از مدل‌های هوشمند با توابع مختلف

فرسایش داشته و نفوذپذیری کمی دارند، همچنین کاربری اراضی منطقه شامل مراتع فقیر، کشاورزی و مسکونی می‌باشد که قسمت‌های شمالی و غرب دشت دارای کاربری مراتع فقیر و قسمت مرکزی دشت شامل کاربری کشاورزی و مسکونی است. این عوامل به‌همراه پوشش گیاهی ضعیف، کمبود بارندگی، خشکسالی‌های اتفاق افتاده و حفر چاه‌های عمیق و نیمه‌عمیق جهت شرب و افزایش سطح زیر کشت سبب تشدید تخریب منابع آبی و افت آب‌زیرزمینی شده است. و به دلیل اینکه دشت گرو در واحد مورفوتکتونیک مکران واقع شده، این دشت تحت تأثیر ویژگی‌های زمین‌شناسی و ژئومورفولوژیکی از نفوذ پذیری اندکی در بیشتر قسمت‌های دشت برخوردار می‌باشد که وجود این عوامل اثرات منفی بر روی کیفیت آب زیرزمینی داشته به طوری که در بیشتر دشت کیفیت آب تقلیل پیدا کرده است. تغذیه آب‌زیرزمینی در دشت گرو در قسمت‌های کم‌شیب و سطح دشت صورت می‌گیرد. قسمت جنوبی شرقی دشت دارای شیب کمی بوده و رسوبات کف دشت متشکل از آبرفت‌های دانه متوسط و دانه‌درشت به ضخامت ۴۵ متر است. عمده گسل‌های منطقه دارای روند تقریباً شمالی- جنوبی هستند. و امتداد و سیر گسل‌ها و شکستگی‌ها به سمت دشت گرو می‌باشند. بنابراین، این گسل‌ها می‌توانند با افزایش نفوذپذیری ثانویه باعث تغذیه آبخوان گردند. به همین دلیل کیفیت آب در این قسمت بهتر از سایر بخش‌های دشت است. نتایج پهنه‌بندی متغیرهای EC و SAR بر اساس طبقه‌بندی کشاورزی ویلکوکس نشان داد که کیفیت آب‌زیرزمینی از نظر کشاورزی در حد مقبولی قرار دارد. بنابراین ضروری است که به‌منظور بهبود کیفیت آب شرب اقداماتی در منطقه صورت پذیرد.

دادند که شبکه عصبی مصنوعی کارایی بالاتری نسبت به شبکه عصبی- فازی تطبیقی در پیش‌بینی جریان دارد. همچنین بررسی نتایج حاصل از این تحقیق نشان می‌دهد که مدل‌های استفاده‌شده توانسته‌اند با کارایی بالایی متغیرهای کیفی آب‌زیرزمینی را در این دشت برآورد کنند. نتایج این تحقیق با نتایج عیسی‌زاده و همکاران (۲۰۱۶)، میرزاوند و همکاران (۲۰۱۵)، زارع ایبانه و همکاران (۲۰۱۱) و نورانی و همکاران (۲۰۱۶) همخوانی دارد. آن‌ها نیز در بررسی متغیرهای کیفی آب زیرزمینی نشان دادند که روش‌های هوشمند کارایی بالایی در مدل‌سازی این متغیرها دارند.

به‌منظور پهنه‌بندی دشت گرو از نظر کیفیت آب زیرزمینی پس از مدل‌سازی متغیرهای کیفی آب‌زیرزمینی، از داده‌های مدل شبکه عصبی- فازی تطبیقی (روش تفکیک خوشه‌ای) به‌منظور پهنه‌بندی متغیرهای EC، SAR و TH از داده‌های مدل شبکه عصبی مصنوعی (تابع تانژانت هیپربولیک) به‌منظور پهنه‌بندی متغیر TDS به‌علت داشتن بهترین کارایی و خطای کم استفاده شد. پهنه‌بندی متغیرهای کیفی (TDS و TH) بر اساس طبقه‌بندی آب شرب شولر نشان داد که در متغیر TDS وضعیت کیفیت آب‌زیرزمینی در سه طبقه بد، نامناسب و غیرقابل شرب قرار دارد که بیشتر دشت وضیت نامناسب، جنوب شرقی دشت وضیت بد و غرب دشت وضیت غیرقابل شربی دارد. بررسی نقشه پهنه‌بندی TH بیانگر این است که دشت در چهار طبقه خوب، قابل قبول، نامناسب و بد قرار دارد، بیشترین قسمت دشت در طبقه نامناسب، غرب دشت در طبقه بد و جنوب شرقی دشت در طبقه قابل قبولی قرار دارد. به دلیل اینکه قسمت شمالی و غرب دشت دارای رسوبات فلیش و آمیزه‌های رنگی که تناوبی از مارن و شیل با لایه‌های نازک آهکی و ماسه سنگ است، حساسیت زیادی به

## منابع

1. Abghari, H., 2008. Intelligent prediction methods based on wavelet and neural network models between monthly river discharges. Ph.D. Dissertation, Faculty of Natural Resources, University of Tehran. 173pp. (In Persian).
2. Adib, A., Zamani, R., 2015. Spatial variability analysis of groundwater quality indicators Dezful plain using geostatistical method. Journal of Water Resources Engineering 8:1-12. (In Persian).
3. Afifi, E., Yamani, M., Hasanzadeh, Y., 2012.

- Hydrogeomorphology basin Garu plain (Hormozgan Province). *Journal of Geographical land* 9(35): 61-76. (In Persian).
4. Askari Marnani, S., Chitsazan, M., Mirzayi, Y., 2001. Investigation of Water Quality in Firoozabad Sub-Chachment in View of Domestic and Agricultural Usage using GIS. P 1-8, the 8 th International Congress on River Engineering, Shahid Chamran University, Iran. (In Persian).
  5. Chowdhury, M., Alouani, A., Hossain, F., 2010. Comparison of ordinary kriging and artificial neural network for spatial mapping of arsenic contamination of groundwater. *Stochastic Environ. Res. and Risk Assess* 24(1): 1-7.
  6. El-Shafie, A., Jafer, O., Seyed, A., 2011. Adaptive neuro-fuzzy inference system based model for rainfall forecasting in Klang River, Malaysia, *Int. J. Phys. Sci.* 6(12): 2875-2888.
  7. Hosseini, S.M., Borhani, R., 2009. The application of artificial neural network in estimating the river yield by minimum temperature and discharge (case study: Hamoon basin). The First International Conference of Water Crisis, 10-12 March. Zabol University. (In Persian).
  8. Huiqun, M., Ling, L., 2008. Water quality assessment using artificial neural network .In International Conference on Computer Science and Software Engineering 5-13 December, USA.
  9. Imrie, C.E., Durucan, S., Korre, A., 2000. River flow prediction using artificial neural networks :generalisation beyond the calibration range. *Journal of Hydrology* 233: 138-153.
  10. Isazadeh, M., Arabzadeh, R., Darbandi, S., 2016. Performance Evaluation of Geostatistical Methods and Artificial Neural Network in Estimation of Aquifer Quality Parameters(Case Study: Qorveh Dehghan Plain). *J. Water and Soil Sci.* 20(77): 197-210. (In Persian).
  11. Jalali, M., Karami, S., Marj, A.F., 2016. Geostatistical Evaluation of Spatial Variation Related to Groundwater Quality Database: Case Study for Arak Plain Aquifer, Iran. *Environmental Modeling & Assessment* 21(6):707-719.
  12. Khodai, K., Shahsavari, A.A., Etebari, B., 2006. Vulnerability assessment Jovin aquifer with DRASTIC and GODS methods. *Iranian Journal of Geology* 2(4): 73-87. (In Persian).
  13. Kisi, O., Shiri, J., Tombul, M., 2012. Modeling rainfall-runoff process using soft computing techniques. *Computers & Geosciences* 51: 108-117.
  14. Mirzavand, M., Ghasemiyeh, H., Sadatinejad, S.J., Akbari, M., 2015. Simulation of changes in groundwater quality using artificial neural network (case study: Kashan aquifer). *Journal of Iranian Natural Resource* 68 (1): 159-171. (In Persian).
  15. Moosavi, V., Vafakhah, M., Shirmohammadi, B., Behnia, N., 2013. A wavelet-ANFIS hybrid model for groundwater level forecasting for different prediction periods. *Water resources management* 27(5):1301-1321.
  16. Nourani, V., Alami, M.T., Vousoughi, F.D., 2016. Self-organizing map clustering technique for ANN-based spatiotemporal modeling of groundwater quality parameters. *Journal of Hydro informatics* 18(2):288-309.
  17. Riad, S., Mania, J., Bouchaou, L., Najjar, Y., 2004. Predicting catchment flow in a semi-arid region via an artificial neural network technique. *Hydrological Processes Journal*, 18(13): 2387-2393.
  18. Shirmohammadi, B., Vafakhah, M., Moosavi, V., Moghaddammia, A., 2013. Application of several data-driven techniques for predicting groundwater level. *Water resources management* 27(2):419-432.
  19. Taheri Tizro, A., Voudouris, K., Vahedi, S., Spatial variation of groundwater quality parameters: a case study from a semiarid region of Iran. *International Bulletin of Water Resources & Development* 1(3): 1-14.
  20. Vafakhah, M., 2012. Application of artificial neural networks and adaptive neuro-fuzzy inference system models to short-term streamflow forecasting. *Canadian Journal of Civil Engineering* 39(4), 402-414.
  21. Vafakhah, M., Mohseni saravi, M., Mahadavi, M., Alavipanah, S.K., 2011. Snowmelt Runoff Prediction by Using Artificial Neural Network in taleghan watershed. *Journal of Iran-Watershed Management Science & Engineering* 5(14): 23-36. (In Persian).
  22. Wang, W.C., Chau, K.W., Cheng, C.h.T., Qiu, L., 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology* 374(34), 323-331.
  23. Yu, X., Liongs, S.Y., 2006. Forecasting of

- hydrologic time series with ridge regression in feature space. *Journal of Hydrology* 332 (3-4), 290-302.
24. Zare Abyaneh, H., Bayat, M., Akhavan, S., Mohamadi, M., 2011. Estimation of nitrate in groundwater Hamedan-Bahar plain using artificial neural network and data separation effect on prediction accuracy. *Journal of Ecology* 37(58): 129-140. (In Persian).
25. Zehtabian, Gh., Janfaza, E., Mohammad asgari, H., Nematollahi, M.J., 2010. Modeling of ground water spatial distribution for some chemical properties (Case study in Garmsar watershed). *Iranian journal of Range and Desert Reseach* 17(1): 61-73. (In Persian).

## Assessment of some Artificial Intelligence (AI)-based Models for Groundwater Quality Prediction (Case Study: Gero plain)

Mojtaba Dolatkordestani<sup>1</sup>, Ahmad Nohegar<sup>2\*</sup>, Saeid Janizadeh<sup>3</sup>

Received: 09/04/2017

Accepted: 15/12/2017

### Introduction

Today, a significant portion of the water consumption in Iran, especially in the drinking sector, is provided by water resources. Exploitation of groundwater resources requires knowledge of the quantitative and qualitative status of aquifers. By determining the chemical quality of groundwater, an estimate of the health status of these water resources can be obtained and, depending on its state, the type of use is determined. In this regard, direct and indirect methods can be used to understand the qualitative characteristics of water. Direct methods, despite their high precision, require a high size of observational data, involves substantial time and cost. Hence, numerous indirect methods have been developed for simulating natural systems and estimating their parameters using a computer based on complex calculations. The main advantage of these methods is the ability to learn time series and prediction. One of these methods is modeling or hydrological simulation. The modeling of groundwater quality is an important tool for planning and decision-making in the management of water resources. The goal of this research is to identify the ability of intelligent model of Support Vector Machines (SVM), Artificial Neural Network (ANN), and Adaptive Neuro-Fuzzy Inference System (ANFIS) for modeling groundwater quality variables (EC, SAR, TDS, and TH) in Gero plain and zoning these variables. Therefore, it can provide an appropriate management tool for controlling quality parameters for drinking and farming.

### Material and methods

In this study, data from 14 wells over the 2008-2016 period was used in order to model the variations in quality variables of Gero plain groundwater. The observed values for Na, Mg, Ca, SO<sub>4</sub>, Cl, and HCO<sub>3</sub> are considered as independent variables and values of EC, SAR, TDS, and TH are considered as dependent variables. An SVM, an ANN, and an ANFIS design were used to model groundwater quality. Input data are randomly divided into two sets such that 80% of data are assigned to the training set and the remaining data (20%) form the test set.

### Results

Results showed that the ANFIS system had the best performance in the estimation of EC ( $R^2 = 0.99$ , RMSE=109.13, CE=0.99), SAR ( $R^2 = 0.98$ , RMSE=0.28, CE=0.98), and TH ( $R^2 = 0.99$ , RMSE=0.49, CE=0.99) among considered methods for the modeling of groundwater quality. Results also indicated that the ANN had the best performance in estimating TDS ( $R^2 = 0.99$ , RMSE=109.13, CE=0.99). Furthermore, Schoeller and Wilcox water quality classifications, for drinking and agricultural water, were respectively employed to perform groundwater quality zoning based on outcomes of the considered methods. According to Schoeller classification, TDS has three classes: inappropriate (21.1%), bad (74.59%), and non-drinking (4.31%) and TH variable has four class: good (0.84%), acceptable (23.48%), inappropriate (67.55%), and bad (8.16%). According to Wilcox classification, EC has three classes: excellent (9.41%), good (89.79%), middle (0.8%) and SAR has two classes: excellent (19%) and good (81%).

### Discussion and Conclusion

ANFIS for a better estimation of EC, SAR, and TH variables outperforms two models of ANN and SVM. The ANFIS system, using the if-then rules, describes that these rules are implemented in a network structure that can be used for learning algorithms used in ANN. Due to this structure, the fuzzy-comparative neural network model has more transparency for analysis and interpretation. The zoning of qualitative variables (TDS and TH) based on the classification of Schoeller drinking water showed that in the TDS variable, the groundwater quality has three classes: bad, inappropriate, and non-drinkable, with the most inadequate plain, southeastern plain bad status and the west of the plain has a terrible situation. The TH zoning map presents that the plain is in good, acceptable, inappropriate, and bad classes. The most part of the plain is in the inappropriate class, the west of the plain in the bad class, and the southeast plain is in an acceptable class. The results of zoning the variables EC and SAR based on the Wilcox agricultural classification showed that groundwater quality is acceptable four agricultural purposes. Therefore, it is essential to take measures to improve the quality of drinking water in the region.

**Keywords:** Garoo plain, support vector machine, artificial neural network, adaptive neuro-fuzzy, zoning and groundwater quality.

1. Ph.D, Student of Combat desertification, Jiroft University Scholarship, Dept. of Combat desertification, Faculty of Range and Watershed, Jiroft university, Jiroft

2. Full professor, Department of Environmental Management Planning, Faculty of Environmental, Tehran University, Tehran, Corresponding author: nohegar@ut.ac.ir

3. PhD student, Dept. of watershed engineering, Young Researchers and Elite Club, Ardebil Branch, Islamic Azad university