



دانشگاه گواران، منابع آب و خاک

نشریه پژوهش‌های حفاظت آب و خاک  
جلد بیست و ششم، شماره چهارم، ۱۳۹۸  
۲۰۷-۲۲۲

<http://jwsc.gau.ac.ir>

DOI: 10.22069/jwsc.2019.16020.3123

## شبیه‌سازی سطح ایستابی آب زیرزمینی دشت سرخس با ترکیب روش‌های هوش مصنوعی و زمین‌آمار

فرشته علیمرزائی<sup>۱</sup>، \*مریم آذرخشئی<sup>۲</sup>، آرش ملکیان<sup>۳</sup> و محمد رستمی خلج<sup>۴</sup>

<sup>۱</sup>دانش‌آموخته کارشناسی‌ارشد گروه مهندسی طبیعت و گیاهان دارویی، دانشگاه تربیت حیدریه،  
<sup>۲</sup>استادیار گروه مهندسی طبیعت و گیاهان دارویی، دانشگاه تربیت حیدریه، <sup>۳</sup>دانشیار دانشکده منابع طبیعی، دانشگاه تهران،  
<sup>۴</sup>استادیار بخش تحقیقات حفاظت خاک و آبخیزداری، سازمان تحقیقات آموزش و ترویج کشاورزی، مشهد، ایران  
تاریخ دریافت: ۱۳۹۷/۰۹/۱۹؛ تاریخ پذیرش: ۱۳۹۸/۰۲/۰۳

### چکیده

**سابقه و هدف:** شبیه‌سازی جریان زیرزمینی به‌منظور پیش‌بینی سطح ایستابی، در مطالعات هیدروژئولوژی و مدیریتی، احداث سازه‌ها، مصارف کشاورزی و دسترسی به آب‌های زیرزمینی با کیفیت بالا از اهمیت بسزایی برخوردار است. در دهه‌های اخیر به سبب پیچیدگی و ویژگی‌های غیرخطی سیستم‌های آب زیرزمینی، مدل‌های هوش مصنوعی برای شبیه‌سازی آبخوان‌ها مورد آزمایش قرار گرفته‌اند. هدف این مطالعه مقایسه مدل‌های شبکه عصبی مصنوعی (پرسپترون چند لایه، تابع پایه شعاعی و نروفازی) و ترکیب آن با روش‌های زمین‌آمار برای مدل‌سازی سطح ایستابی دشت سرخس می‌باشد. بررسی مطالعات قبلی نشان می‌دهد، شبیه‌سازی سطح آب زیرزمینی با روش‌های هوش مصنوعی در مناطق مختلف نتایج متفاوتی ارائه کرده است.

**مواد و روش‌ها:** شهرستان سرخس، با پهنه‌ای بیش از ۵ هزار کیلومترمربع در طول‌های جغرافیایی  $60^{\circ}30'$  تا  $61^{\circ}15'$  شرقی و عرض جغرافیایی  $35^{\circ}55'$  تا  $36^{\circ}40'$  شمالی واقع شده است. آبخوان دشت سرخس از نوع آزاد و دارای یک‌لایه آبرفتی می‌باشد. در این پژوهش از داده‌های سطح ایستابی ۱۸ حلقه چاه در طول دوره آماری (۱۳۷۰-۱۳۹۴)، بارش و تبخیر پتانسیل ماهانه استفاده شد. با استفاده از روش تیسن سطح اثر ایستگاه‌های هواشناسی مشخص شد و داده‌های اقلیمی هر ایستگاه به چاه‌های واقع در پلیگون مربوطه تعمیم داده شد. مدل‌های شبکه عصبی مورد استفاده شامل پرسپترون چندلایه (MLP)، تابع پایه شعاعی (RBF) و روش نروفازی (NF) یا شبکه تطبیقی عصبی فازی (ANFIS) و روش‌های زمین‌آمار شامل روش کریجینگ، کوکریجینگ و روش عکس فاصله بود. ۷۰ درصد داده‌های ورودی برای آموزش مدل و ۳۰ درصد باقیمانده داده‌ها برای آزمایش آن‌ها به‌کار گرفته شد. برای ارزیابی نتایج شبیه‌سازی مدل‌های شبکه عصبی مصنوعی از آماره‌های همبستگی بین داده‌ها (R)، مجذور میانگین خطای مطلق (MAE) و ضریب تبیین ( $R^2$ ) و برای ارزیابی روش‌های زمین‌آمار از معیارهای ارزیابی ریشه میانگین مربع خطا (RMSE) و میانگین مربعات خطا (MSE) استفاده شد.

\* مسئول مکاتبه: m.azarakhshi@torbath.ac.ir

یافته‌ها: نتایج به دست آمده نشان داد که مدل پرسپترون چندلایه نسبت به مدل‌های دیگر با توجه به  $R^2=0/60$ ،  $MAE=0/80$  و  $R=0/77$  از دقت بیشتری برخوردار است. برای تعیین بهترین مدل زمین‌آمار برای پیش‌بینی مکانی سطح ایستابی آب‌های زیرزمینی نتایج مدل پرسپترون چندلایه، به عنوان ورودی مدل‌های زمین‌آمار استفاده شد. نتایج نشان که روش کریجینگ با  $RMSE=1$  و  $RMS=0/68$  مدل بهتری برای شبیه‌سازی مکانی سطح آب زیرزمینی دشت سرخس می‌باشد و براساس آن نقشه‌های شبیه‌سازی سطح آب زیرزمینی هر سال ترسیم گردید. تحلیل نقشه‌های به دست آمده نشان داد بیش‌ترین افت در قسمت شمالی منطقه می‌باشد و قسمت جنوبی از افت کم‌تری برخوردار بوده است.

**نتیجه‌گیری:** ترکیب مدل MLP و روش درونیابی کریجینگ، راه‌حلی مناسب و کم هزینه برای شبیه‌سازی تراز آب زیرزمینی دشت سرخس می‌باشد. پیشنهاد می‌گردد برای افزایش دقت مدل‌های هوش مصنوعی در صورت امکان از متغیرهای وابسته بیش‌تری استفاده شود. همچنین برای پیش‌بینی بهتر سطح آب زیرزمینی از مدل‌های هوش مصنوعی دیگر با الگوریتم‌های متفاوت استفاده شود.

**واژه‌های کلیدی:** آب زیرزمینی، پهنه‌بندی، کریجینگ، مدل پرسپترون چندلایه

#### مقدمه

یکی از مهم‌ترین دغدغه‌های امروز در بسیاری از کشورهای جهان به خصوص کشورهای خاورمیانه، تأمین آب در راستای تداوم توسعه پایدار است. در بسیاری از کشورهای خشک جهان و به خصوص ایران، اصلی‌ترین منبع تأمین آب، ذخایر آب زیرزمینی است. با پیشرفت فناوری، بهره‌برداری از این ذخایر در چند دهه اخیر به شدت رو به فزونی گذاشته و در نتیجه روند افت سطح ایستابی و کاهش این ذخایر را به دنبال داشته است. عدم شناخت صحیح و بهره‌برداری بی‌رویه از این منابع خسارات جبران‌ناپذیری مانند افت شدید سطح آب زیرزمینی و در نتیجه آن کاهش کیفیت آب زیرزمینی و پیشروی جبهه‌های آب شور و تداخل آب‌های شور و شیرین را به دنبال خواهد داشت. برآورد توزیع مکانی سطح ایستابی، در طیف گسترده‌ای از مسائل، مانند سدهای زیرزمینی، طرح‌های محیط‌زیست، طرح‌های آبخیزداری و بسیاری از بحث‌های منابع آب کاربرد دارد. تغییرات زیاد سطح ایستابی در نقاط مختلف آبخوان، کمبود چاه‌های مشاهداتی و پیچیدگی ارتباط سطح ایستابی با

دیگر پارامترها، اهمیت توسعه روش‌های کارآمد را در برآورد توزیع مکانی سطح ایستابی دو چندان می‌نماید (۲۷). روش‌های هیدروژئولوژی مختلفی مانند MODFLOW، Visual MOFLOW، PMWIN (۲۱) و PASTIC (۱۷) برای تخمین تراز آب زیرزمینی وجود دارند که هر کدام در زمینه‌های مختلفی مورد استفاده قرار گرفته و به طور نسبی از کارایی برخوردار هستند. از مدل‌های شبکه عصبی مصنوعی نیز می‌توان به پرسپترون چندلایه ( $MLP^1$ )، تابع پایه شعاعی ( $RBF^2$ ) و روش نروفازی (NF) یا ( $ANFIS^3$ ) اشاره کرد. پرسپترون چندلایه در بسیاری از مسائل پیچیده ریاضی که به حل معادلات بفرنج غیرخطی منجر می‌شود. از مهم‌ترین قسمت‌های تعیین ساختار بهینه شبکه پرسپترون چندلایه، تعیین تعداد لایه‌های پنهان و تعداد نرون‌های هر لایه پنهان برای دست‌یابی به کم‌ترین خطا می‌باشد. تابع پایه شعاعی برای حل بسیاری از مسائل متفاوت، به ویژه در مسائل

- 1- Multi-Layer Perceptron
- 2- Radial Basis Function
- 3- Adaptive Network-based Fuzzy Inference System

وجود دارد که این امر باعث می‌شود فرایندهای هیدرولوژی و نحوه ارتباط آن‌ها در مدل‌ها در نظر گرفته شود. البته استفاده از مدل‌های فیزیکی مستلزم استفاده از داده‌های زیادی بوده که گاهی این داده‌ها موجود نیست و یا باید با پیش‌فرض‌ها و فرمول‌هایی به دست آید (۴). در چند سال اخیر مدل‌های هوش مصنوعی به‌طور گسترده‌ای در تخمین پارامترهای هیدروژئولوژیکی (۶، ۱۳، ۲۲، ۲۳، ۲۴، ۲۵ و ۲۷) مورد استفاده قرار گرفته‌اند. این روش‌ها برخلاف آزمون‌های صحرایی و آزمایشگاهی در زمانی کوتاه‌تر و با صرف هزینه کم‌تر و با داده‌های در دسترس محدود، تخمین قابل‌قبولی از پارامترهای هیدروژئولوژیکی ارائه می‌دهند (۲۰). همچنین از آن‌جا که روش‌های آمار کلاسیک قادر به در نظر گرفتن ارتباط مکانی موجود بین مشاهدات سطح آب زیرزمینی نیستند، از روش‌های زمین‌آمار نیز برای بررسی تغییرات مکانی و پهنه‌بندی تراز سطح آب زیرزمینی (۱، ۳، ۸، ۱۵ و ۱۶) و شبیه‌سازی تغییرات مکانی کیفیت آب زیرزمینی (۳ و ۵) استفاده شده است. از ترکیب مدل‌های شبکه عصبی و روش‌های زمین‌آمار نیز برای شبیه‌سازی تغییرات سطح آب زیرزمینی (۷، ۱۰، ۱۱، ۱۲ و ۲۶) استفاده شده است. نتایج به‌دست آمده در مناطق مختلف، متفاوت بوده و در هر پژوهش یکی از مدل‌های شبکه عصبی و زمین‌آمار به‌عنوان مدل مناسب‌تر بر اساس شاخص‌های ارزیابی معرفی گردیده است. در سال‌های گذشته سطح آب‌های زیرزمینی دشت سرخس افت کرده است زیرا میزان برداشت از آب‌های زیرزمینی سرخس بیش‌تر از میزان تغذیه بوده است (۱۹). در دشت سرخس کشاورزی از فعالیت‌های مهم اقتصادی می‌باشد و همچنین عمده تقاضا برای آب از طریق آب زیرزمینی تأمین می‌شود. با توجه به رشد جمعیت، محدودیت منابع آبی و این‌که تنها منبع تأمین‌کننده آب دشت سرخس آب‌های زیرزمینی می‌باشد، پیش‌بینی تغییرات سطح

طبقه‌بندی، الگوشناسی و تحلیل سری زمانی مورد استفاده قرار گرفته است. به‌علت انتخاب تابع گوسی در نرون‌های لایه میانی، این شبکه مسائل دسته‌بندی را به خوبی حل می‌کند. زیرا به‌صورت شعاعی می‌تواند الگوها را بر روی دواير متحدالمرکزی تقسیم نماید و بردارهای مختلف با فاصله‌های یکسان از مرکز را در یک دسته قرار دهد. روش نروفازی (NF) یا (ANFIS<sup>۱</sup>)، ترکیبی از روش فازی و شبکه عصبی مصنوعی است و از مزایای هر دو روش استفاده می‌کند. به‌طوری‌که از شبکه عصبی مصنوعی برای تعیین قوانین و از فازی برای تعیین توابع عضویت استفاده می‌شود. در این روش شبکه عصبی مصنوعی به‌جای بهینه کردن وزن‌ها، قوانین فازی را بهینه می‌کند (۲).

درون‌یابی یکی از مهم‌ترین روش‌هایی است که هیدرولوژیست‌ها در مطالعات پهنه‌بندی از آن بهره‌مند می‌شوند. در روش‌های کلاسیک، به‌دلیل در نظر نگرفتن پراکنش نقاط و فاصله مکانی و یا زمانی آن‌ها، امکان دستیابی به دقت مطلوب، همیشه امکان‌پذیر نمی‌باشد. بر خلاف روش‌های کلاسیک، روش‌های زمین‌آمار، ضمن در نظر گرفتن ارتباط بین نقاط و موقعیت مکانی آن‌ها، اغلب دقت قابل‌قبولی را ارائه می‌دهند.

مدل‌های شبکه عصبی از مدل‌های جعبه سیاه هستند، در مدل‌های جعبه سیاه فرایندهای مؤثر بر سیستم در نظر گرفته نمی‌شود و فقط پاسخ سیستم به ورودی در قالب یک خروجی مانند هیدروگراف، سطح ایستابی، تبخیر و تعرق و غیره ارائه می‌شود. در حالی‌که در مدل‌های جعبه سفید و مدل‌های فیزیکی فرایندهای حاکم بر سیستم در نظر گرفته شده و در نهایت با واسنجی مدل، آنالیز حساسیت و آنالیز عدم قطعیت مدل بهینه‌سازی می‌شود و پایان بهینه‌سازی آغازی برای روند مدل‌سازی هیدرولوژی است. در مدل‌های فیزیکی امکان ارزیابی مرحله به مرحله مدل

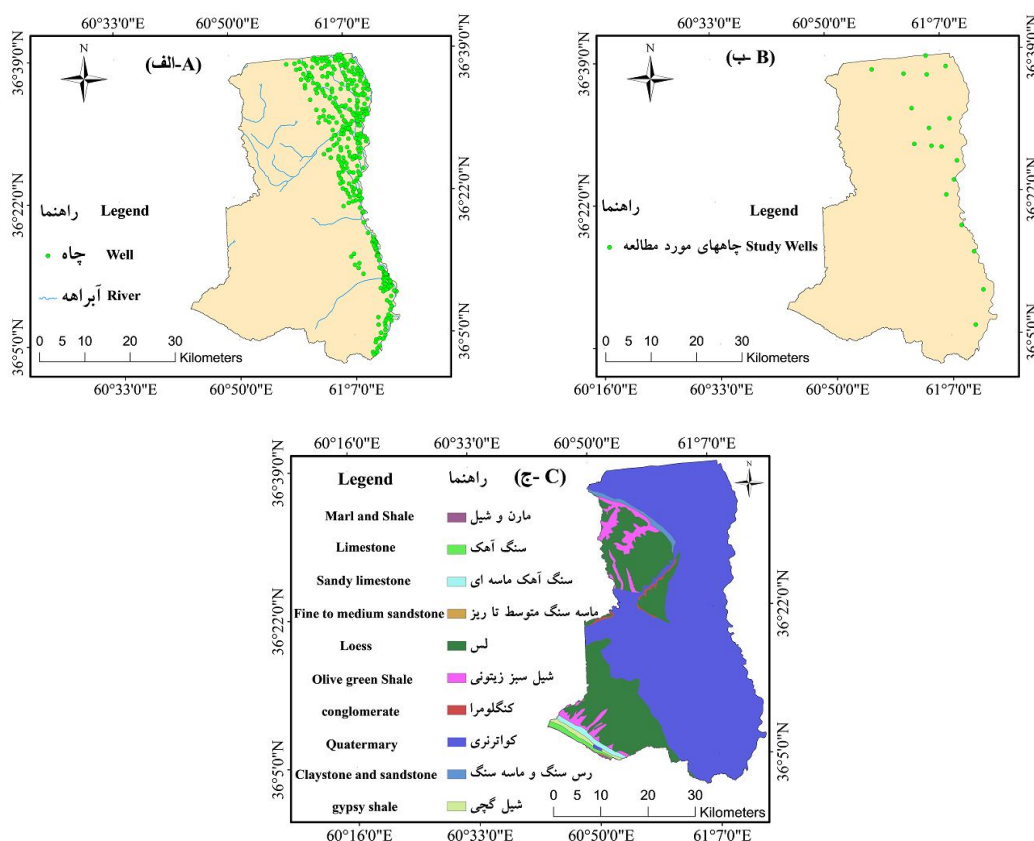
1- Adaptive Network-based Fuzzy Inference System

حداقل مطلق دما و حداکثر مطلق دمای سالانه ایستگاه سرخس در دوره آماری ۱۳۹۴-۱۳۷۰، به ترتیب ۱۹۴/۲۵ میلی‌متر، ۱۷/۹، ۱۸/۶- و ۴۶/۶ درجه سانتی‌گراد می‌باشد. متوسط سطح ایستابی آب چاه‌ها در طول دوره تحقیق ۱۶/۶۵ متر و متوسط تبخیر پتانسیل ۱۹۵۲ میلی‌متر است. شکل (A-۱) منابع آبی دشت سرخس را نشان می‌دهد. در این پژوهش ۱۸ حلقه چاه در محدوده مورد مطالعه، با توجه به کامل بودن دوره آماری (۱۳۷۰-۱۳۹۴) و با پراکنش مناسب انتخاب گردید. موقعیت جغرافیایی چاه‌های منتخب در شکل B-۱ آورده شده است. آبخوان دشت سرخس از نوع آزاد و دارای یک‌لایه آبرفتی می‌باشد (۷). شکل C-۱ نقشه زمین‌شناسی دشت سرخس را نشان می‌دهد.

آب زیرزمینی یکی از مسائل مهم در مطالعات هیدروژئولوژیکی این دشت می‌باشد. هدف این پژوهش تعیین مناسب‌ترین روش هوش مصنوعی و زمین‌آماری برای شبیه‌سازی سطح ایستابی آب زیرزمینی دشت سرخس می‌باشد.

### مواد و روش‌ها

**منطقه مورد مطالعه:** شهرستان سرخس، با پهنه‌ای بیش از ۵ هزار کیلومترمربع، در شمال استان خراسان رضوی، در کنار مرز ایران و جمهوری ترکمنستان در ۱۸۰ کیلومتری شرق مشهد می‌باشد. این شهرستان در طول‌های جغرافیایی ۳۰' ۶۰° تا ۱۵' ۶۱° شرقی و عرض جغرافیایی ۵۵' ۳۵° تا ۴۰' ۳۶° شمالی واقع شده است. میانگین بارندگی، میانگین درجه حرارت،




شکل ۱- (A): منابع آبی، (B): موقعیت چاه‌های انتخابی و (C) نقشه زمین‌شناسی منطقه مورد مطالعه.

Figure 1. (A): Water resources, (B): The Geographical position of selected wells and (C) The Geology map of study area.

۷۰ درصد از داده‌ها برای واسنجی (آموزش) و ۳۰ درصد جهت اعتبارسنجی (آزمون) در نظر گرفته شد. از آنجا که داده‌های ورودی نرمال نبودند برای استانداردسازی داده‌ها از روش باکس-کاکس استفاده گردید. برای تعیین داده‌های مناسب بارش و تبخیر پتانسیل هر چاه، با توجه به ایستگاه‌های هواشناسی موجود در منطقه، از روش مثلث‌بندی تیسن استفاده شد (شکل ۲). بر این مبنا دشت مورد نظر به دو منطقه تقسیم شده و داده‌های مربوط به هر ایستگاه هواشناسی به چاه‌های موجود در سطح اثر هر ایستگاه تعمیم داده شد.

نمونه‌های شبکه عصبی: نمونه‌های شبکه عصبی مورد مطالعه در این پژوهش عبارت‌اند از پرسپترون چندلایه (MLP)، تابع پایه شعاعی (RBF) و روش نروفازی (NF) یا (ANFIS). در این پژوهش از داده‌های ماهانه سطح ایستابی، بارش و تبخیر پتانسیل دشت سرخس استفاده شده که از اداره آب منطقه‌ای استان خراسان رضوی اخذ گردید. برای شبیه‌سازی سطح آب زیرزمینی توسط مدل‌های هوش مصنوعی ذکر شده از نرم‌افزار MATLAB (۲۰۱۳a) و برای تهیه نقشه‌های پهنه‌بندی منطقه مورد مطالعه از نرم‌افزار ArcGIS نسخه ۱۰/۳ و برای تجزیه و تحلیل آماری از نرم‌افزار SPSS نسخه ۲۲ استفاده شد. به این منظور



شکل ۲- سطح تأثیر ایستگاه‌های هواشناسی در منطقه مورد مطالعه با روش تیسن.

Figure 2. The effective area of meteorological station in study area with Thiessens method.

برای ارزیابی توانایی مدل‌های شبکه عصبی مصنوعی در عکس‌العمل نسبت به متغیرهای ورودی، از آماره‌های همبستگی بین داده‌ها R (رابطه ۳)، مجذور میانگین خطای مطلق MAE (رابطه ۴) و ضریب تبیین R<sup>2</sup> (رابطه ۵) استفاده شد.

$$R = \sqrt{\frac{\sum_{i=1}^n ((x_i - \bar{x})(y_i - \bar{y}))^2}{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2}} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |x_i - Y_i|}{n} \quad (4)$$

$$R^2 = \frac{\sum_{i=1}^n ((x_i - \bar{x})(y_i - \bar{y}))^2}{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2} \quad (5)$$

گردید. روش‌های زمین‌آمار مورد استفاده در این پژوهش شامل روش کریجینگ (ساده، معمولی و جهانی)، کوکریجینگ و IDW می‌باشد. برای ارزیابی روش‌های زمین‌آمار از معیارهای ارزیابی ریشه میانگین مربع خطا (RMSE) (رابطه ۶) و میانگین مربعات خطا (MSE) (رابطه ۷) استفاده شد.

$$RMSE = \sqrt{\sum_{i=1}^n (y_i - x_i)^2 / n} \quad (6)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \quad (7)$$

### نتایج و بحث

جدول ۱ خلاصه آماری داده‌های نرمال شده سطح ایستابی، بارش و تبخیر پتانسیل در دشت سرخس را نشان می‌دهد. از آنجایی که ضریب چولگی و کشیدگی داده‌ها بین (۱ و -۱) قرار دارد این متغیرها دارای توزیع نرمال می‌باشند (۵).

پس از شبیه‌سازی سطح ایستابی منطقه مورد مطالعه با مدل‌های شبکه عصبی مصنوعی MLP، RBF و NF، سطح ایستابی محاسبه شده با داده‌های مشاهده‌ای مورد مقایسه قرار گرفت.

به منظور تشریح پیوستگی مکانی پارامترهای کمی سطح تراز آب‌های زیرزمینی منطقه، اقدام به ترسیم نیم‌تغییرنمای داده‌های سطح ایستابی شد. پس از بررسی نرمال بودن داده‌ها و تغییر شکل داده‌های غیرنرمال، الگوهای واریوگرام ترسیم شد و بهترین واریوگرام بر اساس کم‌ترین مقدار RSS، بیش‌ترین مقدار R<sup>2</sup> و استحکام ساختار فضایی قوی‌تر انتخاب

در رابطه‌های (۳ تا ۷) X<sub>i</sub> و Y<sub>i</sub>، i امین داده سطح ایستابی برآوردی و اندازه‌گیری شده است  $\bar{x}$  و  $\bar{y}$  به ترتیب میانگین داده‌های X<sub>i</sub> و Y<sub>i</sub> می‌باشند، n نیز تعداد داده‌های مورد ارزیابی در مدل است. (۱۶).

جدول ۱- نتایج آماره‌های توصیفی داده‌های نرمال شده سطح ایستابی، بارش و تبخیر پتانسیل در منطقه مورد مطالعه.

**Table 1. The descriptive statistics results of normalization data of water table, precipitation and potential evaporation.**

متغیر Variable	میانگین Mean	انحراف معیار Standard deviation	چولگی Skewness	کشیدگی kurtosis
سطح ایستابی water table	4	1	0.070	-0.08
بارش precipitation	4	0.002	-0.028	-1
تبخیر پتانسیل Potential evaporation	4.05	0.001	-0.001	-1

می‌گیرد. نتایج شبیه‌سازی با مدل MLP در جدول ۲ ارائه شده است. بر اساس نتایج جدول ۲ شبکه MLP با الگوریتم Gradient descent و تابع سیگموئید و یک لایه پنهان مناسب‌ترین مدل برای شبیه‌سازی سطح ایستابی در دشت سرخس می‌باشد.

برای آموزش شبکه MLP از روش آموزشی پس‌انتشار خطا استفاده شد. با توجه به اینکه برای انتخاب تعداد گره‌های مخفی این شبکه‌ها، روش مستقیم و دقیقی وجود ندارد، بنابراین روش آزمون و خطا به صورت بسیار گسترده‌ای مورد استفاده قرار

جدول ۲- ارزیابی نتایج مدل MLP.

**Table 2. Assessment the results of MLP Model.**

خروجی Out put			ورودی Input					
R <sup>2</sup>	R	MAE	الگوریتم Algorithm	آموزش Education	تابع انتقال Transfer function	تعداد لایه پنهان Number of hidden layers	تابع فعال‌کننده Activation function	شماره مدل Number of model
0.07	0.26	0.80	Gd	O	Ht	1	N	1
<b>0.60</b>	<b>0.77</b>	<b>0.80</b>	<b>Gd</b>	<b>O</b>	<b>S</b>	<b>1</b>	<b>N</b>	<b>2</b>
0.02	0.14	0.80	Gd	Mb	Ht	1	N	3
0.20	0.45	0.80	Gd	Mb	S	1	N	4
0.13	0.35	0.80	Gd	O	Ht	2	N	5
0.001	0.03	0.79	Gd	O	S	2	N	6
0.57	0.76	0.80	Gd	Mb	Ht	2	N	7
0.00	0.06	0.80	Gd	Mb	S	2	N	8
0.00	0.00	0.80	Gd	O	Ht	1	S	9
0.00	0.06	0.80	Gd	O	S	1	S	10
0.01	0.07	0.80	Gd	Mb	Ht	1	S	11
0.00	0.05	0.80	Gd	Mb	S	1	S	12
0.01	0.09	0.80	Gd	O	Ht	2	S	13
0.02	0.14	0.80	Gd	O	S	2	S	14
0.00	0.01	0.80	Gd	Mb	Ht	2	S	15
0.00	0.06	0.80	Gd	Mb	S	2	S	16
0.00	0.04	0.80	Gd	O	Ht	1	No	17
0.00	0.01	0.80	Gd	O	Ht	1	No	18
0.00	0.02	0.80	Gd	Mb	Ht	1	No	19
0.01	0.09	0.80	Gd	Mb	Ht	1	No	20
0.00	0.03	0.80	Gd	O	Ht	2	No	21
0.00	0.03	0.80	Gd	O	S	2	No	22
0.00	0.00	0.80	Gd	Mb	Ht	2	No	23
0.01	0.11	0.80	Gd	Mb	S	2	No	24
0.00	0.00	0.80	Gd	O	Ht	1	No	25
0.00	0.002	0.80	Gd	O	S	1	No	26
0.06	0.25	0.80	Gd	Mb	Ht	1	AN	27
0.00	.0004	0.80	Gd	Mb	S	1	AN	28
0.00	0.002	0.80	Gd	O	Ht	2	AN	29
0.00	0.002	0.80	Gd	O	S	2	AN	30
0.00	0.003	0.79	Gd	Mb	Ht	2	AN	31
0.00	0.01	0.79	Gd	Mb	S	2	AN	32

اختصاصی به‌کار رفته در جدول‌های ۲ و ۳ عبارت‌اند از AN، (Standardized) S، (Normalized) No، (Non) N، (Online) O، (Adjust Normalized) Ht، (Sigmoid) S، (Gradient descent) Gd، (Mini-batch) Mb، (Hyberbolic tangent)

نتایج حاصل از شبیه‌سازی سطح آب زیرزمینی با شبکه عصبی RBF در جدول ۳ نشان داده شده است. در مدل‌های اجرا شده با شبکه عصبی RBF، داده‌های شبیه‌سازی شده با تابع انتقال بایاس، ۷ لایه پنهان و پارامتر حساس بارش دارای بیش‌ترین ضریب همبستگی با داده‌های مشاهده‌ای است. علائم

جدول ۳- ارزیابی نتایج مدل RBF.  
Table 3. Assessment the results of RBF model.

R	R <sup>2</sup>	MSE	پارامتر حساس Sensitive parameter	تعداد لایه پنهان Number of hidden layers	تابع انتقال Transfer function	تابع فعال‌کننده Activation function	شماره مدل Number of model
0.01	0.00	0.79	Precipitation بارش	9	Bias بایاس	S	1
0.11	0.01	0.79	Precipitation بارش	8	Bias بایاس	N	2
0.03	0.00	0.79	Precipitation بارش	10	Bias بایاس	AN	3
0.03	0.00	0.79	Potential Evaporation تبخیر پتانسیل	10	Bias بایاس	N	4
0.06	0.00	0.79	Precipitation بارش	9	Bias بایاس	S	5
0.54	0.30	0.79	Precipitation بارش	7	Bias بایاس	No	6
0.1	0.01	0.79	Potential Evaporation تبخیر پتانسیل	9	Bias بایاس	AN	7
0.01	0.00	0.79	Precipitation بارش	7	Bias بایاس	N	8

دقت شبیه‌سازی سطح ایستابی شد. معیارهای ارزیابی آماری خروجی مدل در جدول ۴ ارائه شده است.

مدل نروفازی با تابع گوسی با ورودی‌های مختلف برای پیش‌بینی سطح ایستابی اجرا شد. در این مدل استفاده از متغیر تبخیر پتانسیل باعث افزایش

جدول ۴- ارزیابی نتایج مدل NF.  
Table 4. Assessment the results of NF model.

R	R <sup>2</sup>	MAE	تابع Function	ورودی مدل Input of model	شماره مدل Model number
0.4	0.16	0.65	Gaussian	بارش و تبخیر پتانسیل Rainfall and Potential evaporation	1
0.33	0.11	0.60	Gaussian	بارش Rainfall	2

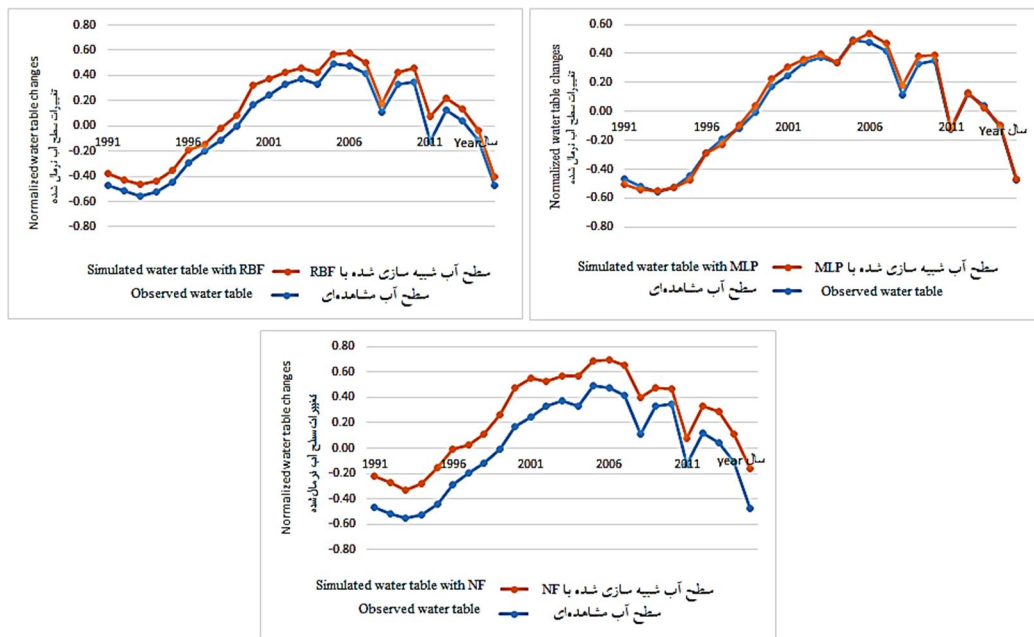
شبیه‌سازی سطح تراز آب زیرزمینی دشت سرخس برخوردار است. زارع‌ایبانیه و همکاران (۲۰۱۳) و زمانی احمد محمودی و همکاران (۲۰۱۳) نیز با مقایسه نتایج مدل‌های شبکه عصبی و فازی و تابع

نتایج ارزیابی سه مدل شبکه عصبی مصنوعی RBF، MLP و NF با توجه به جدول‌های ۲، ۳ و ۴ بیانگر آن است که مدل MLP با  $R^2=0/60$ ،  $MAE=0/80$  و  $R=0/77$  از دقت بالاتری نسبت به دو مدل دیگر برای



به ترتیب ۰/۱۴ و ۰/۸۶ و در مرحله اعتبارسنجی به ترتیب ۰/۱۲ و ۰/۸۸ بود (۱۴). مقایسه سطح ایستابی مشاهده‌ای و شبیه‌سازی با روش‌های شبکه عصبی در شکل ۳ آورده شده است. همان‌طور که شکل ۳ نشان می‌دهد سطح تراز آب زیرزمینی شبیه‌سازی شده با مدل MLP تقریباً با داده‌های مشاهداتی منطبق است. نتایج مدل RBF و مدل NF نشان می‌دهد که روند داده‌های شبیه‌سازی شده مشابه روند داده‌های مشاهداتی است اما هر دو مدل سطح ایستابی را بیش‌تر برآورد کرده‌اند. نتایج پژوهش‌های زارع ایبانه و همکاران (۲۰۱۳) و حبیبی و همکاران (۲۰۱۶) نیز نشان داد که مدل‌های شبکه عصبی نسبت به مدل نروفازی تراز آب زیرزمینی را دقیق‌تر و بهتر شبیه‌سازی کرده‌اند (۱۰ و ۲۷).

پایه شعاعی، به برتری مدل MLP در مدل‌سازی توزیع مکانی سطح ایستابی اشاره کرده‌اند (۲۶ و ۲۷). رمضانی چرمهینه و ذونعمت کرمانی (۲۰۱۷) نیز نشان دادند که MLP در ۵۶ درصد موارد نسبت به SVR عملکرد بهتری در پیش‌بینی تراز آب زیرزمینی دشت شهرکرد داشته است (۲۲). ضریب همبستگی به‌دست آمده در مدل‌های مورد بررسی پایین بوده که علت غیرخطی بودن داده‌ها و حجم زیاد داده‌های ورودی به مدل است. در مدل MLP، تابع سیگموئید بهترین تابع برای مدل‌سازی این سیستم طبیعی غیرخطی تشخیص داده شد. با تغییر تعداد لایه پنهان نتایج مدل RBF تغییر می‌کند، نتایج مشابهی توسط میرزاوند و همکاران (۲۰۱۵) گزارش شده است. در مدل MLP متوسط وزن متغیر بارش و تبخیر در مرحله آموزش



شکل ۳- مقایسه مقدار شبیه‌سازی شده و مشاهداتی سطح ایستابی زیرزمینی با استفاده از مدل‌های شبکه عصبی.

Figure 3. Comparison of the simulated and observed water table data with artificial intelligence methods.

مقدار  $R^2$  بیش‌تر و RSS کم‌تر از بین مدل‌های آزمون شده، مدل گوسین مناسب‌ترین مدل برازش واریوگرام در این منطقه بود. نتایج مشابهی توسط زمانی احمد محمودی و همکاران (۲۰۱۳) در دشت شهرکرد

مشخصات واریوگرامی سطح آب زیرزمینی دشت سرخس در سال‌های مختلف محاسبه شده و نتایج به‌دست آمده در سال‌های ابتدایی، میانی و انتهایی پژوهش در جدول ۵ نشان داده شده است. با توجه به

متوسط است (۱۲). نتایج نشان داد همبستگی مکانی تغییرات سطح آب زیرزمینی در دشت سرخس در سال‌های مختلف متوسط تا زیادی است. بر اساس نقشه‌های سه‌بعدی واریوگرام مشخص شد جهت روند در سال ابتدایی و میانی پژوهش، شمال شرقی و جنوب غربی در سال انتهای پژوهش شرقی- غربی است.

به‌دست آمد (۲۶). کرد و اصغری‌مقدم (۲۰۱۵) در بررسی پارامترهای کیفی دشت اردبیل مدل کروی را به‌عنوان مدل مناسب تشخیص دادند (۱۲). نسبت اثر قطعه‌ای به سقف  $(C_0/C_0+C)$ ، معیاری برای ارزیابی ساختار مکانی داده‌ها در نظر گرفته می‌شود. بر این اساس مقادیر کم‌تر از ۰.۲۵، بین ۰.۲۵ تا ۰.۷۵ و بیش از ۰.۷۵ به‌ترتیب نشان‌دهنده وابستگی مکانی زیاد، کم و

جدول ۵- مشخصات مدل واریوگرام مناسب برازش داده شده سطح آب زیرزمینی دشت سرخس در سال‌های ابتدایی، میانی و انتهای پژوهش.

**Table 5. Characteristics of the appropriate variogram model fitted groundwater level of Sarakhs plain in the early, middle and end years of research.**

RSS	R <sup>2</sup>	دامنه تأثیر Effective parameter	دامنه تغییرات Range Parameter	C <sub>0</sub> /(C <sub>0</sub> +C)	اثر آستانه Still(C <sub>0</sub> +C)	اثر قطعه‌ای Nugget(C <sub>0</sub> )	بهترین مدل Best Model	سال
1.98*10 <sup>-8</sup>	0.71	24543.15	14170	0.04	0.00022	0.00001	Gussian	1991
1.79*10 <sup>-8</sup>	0.686	30414.81	17560	0.24	0.00025	0.00006	Gussian	2004
3.5*10 <sup>-8</sup>	0.594	21615.99	12480	0.41	0.00024	0.0001	Gussian	2015

(ساده، معمولی، جهانی)، IDW و کوکریجینگ، اقدام به انتخاب بهترین مدل نموده که نتایج این مدل‌ها در جدول ۶ آمده است. در روش کوکریجینگ از متغیر تبخیر پتانسیل به‌عنوان متغیر کمکی استفاده شد.

با توجه به ارزیابی مدل‌های هوش مصنوعی و انتخاب شبکه پرسپترون چندلایه (MLP) به‌عنوان شبکه دقیق‌تر، داده‌های پیش‌بینی‌شده این مدل وارد نرم‌افزار GIS شده و تحلیل‌های زمین‌آماری بر روی آن‌ها انجام شده است. از بین روش‌های کریجینگ

جدول ۶- ارزیابی مدل‌های زمین‌آمار.

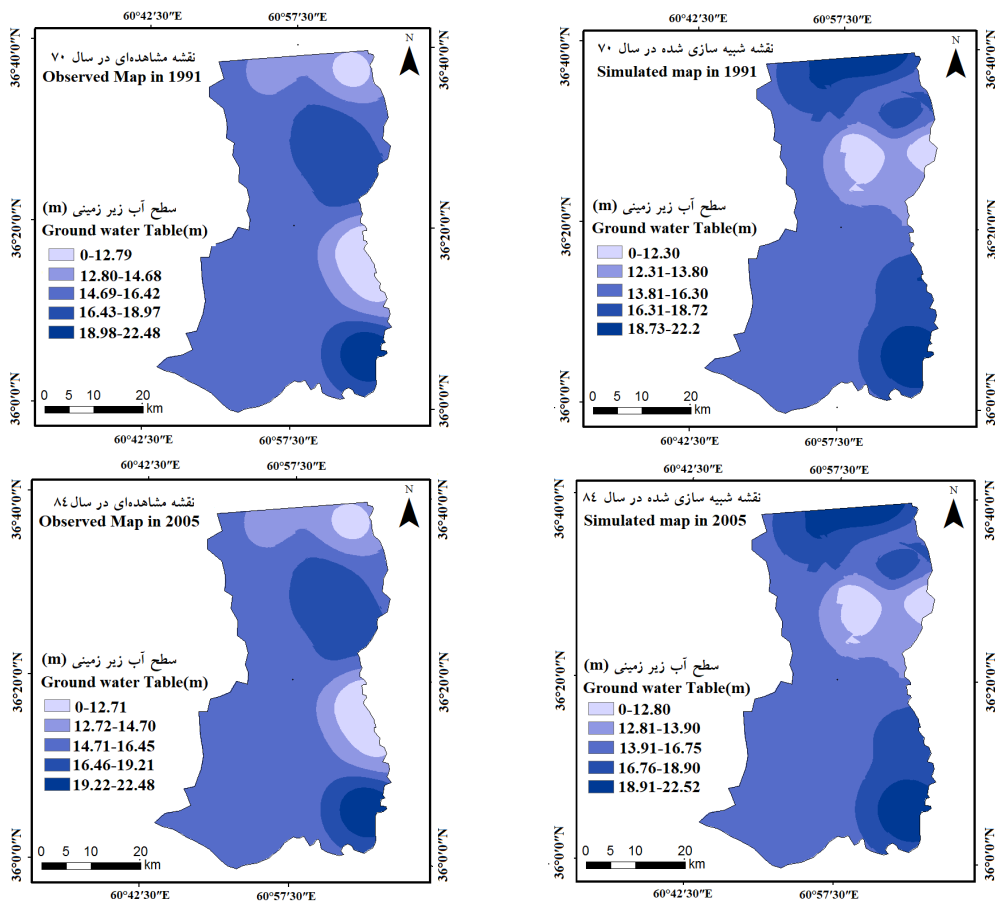
**Table 6. The assessments of geostatistical models.**

MSE	RMSE	مدل Model	مدل Model
0.068	1	کریجینگ معمولی Normal Kriging	
0.075	0.98	کریجینگ ساده Simple Kriging	کریجینگ Kriging
0.70	0.95	کریجینگ جهانی Universal Kriging	
0.073	1		کوکریجینگ Cocriging
0.074	-	IDW1	
0.090	-	IDW2	IDW
0.074	-	IDW3	
0.073	-	IDW4	
0.076	-	IDW5	

داده‌ها بر اساس واریانس فضایی است. کریجینگ همراه هر تخمین میزان خطای آن را نیز ارائه می‌دهد و با استفاده از این ویژگی منحصر به فرد می‌توان قسمت‌هایی را که خطا زیاد است را مشخص کرد. این روش خطای پیش‌بینی با توجه به توزیع مکانی داده‌های پیش‌بینی شده کمینه می‌شود (۷).


در نهایت ۲۵ نقشه شبیه‌سازی شده برای دوره آماری مورد مطالعه و ۲۵ نقشه سطح ایستابی هر چاه به صورت جداگانه به روش کریجینگ و به تفکیک هر سال در نرم‌افزار ArcGIS تهیه گردید. نقشه پهنه‌بندی شبیه‌سازی شده با مدل MLP و نقشه پهنه‌بندی با داده‌های مشاهداتی در سال‌های ابتدایی، میانی و انتهایی پژوهش در شکل ۴ آورده شده است.

روش کریجینگ معمولی با توجه به معیار ریشه میانگین مربع خطا (RMSE) بیش‌تر و میانگین مربع خطا (MSE) کم‌تر نسبت به سایر روش‌ها (جدول ۶) به عنوان مناسب‌ترین روش برای تهیه نقشه‌های پهنه‌بندی انتخاب شد که با نتایج بامری و همکاران (۲۰۱۵) و دلبری و همکاران (۲۰۱۶) مطابقت دارد (۵ و ۸). اما با نتایج ندیری و همکاران (۲۰۱۴) که کوکریجینگ را با پارامتر ثانویه توپوگرافی (۱۸) و دهقانی و نورعلینی (۲۰۱۶) که روش کوکریجینگ ساده (۷) و زمانی احمد محمودی (۱۳۹۲) که کوکریجینگ را با نیم‌تغییرنمای گوسین بهترین روش زمین‌آمار برای تخمین آب زیرزمینی تشخیص داده بودند مغایر است (۲۶). کوکریجینگ یک روش زمین‌آمار برای درون‌یابی



شکل ۴- نقشه‌های پهنه‌بندی تراز آب دشت سرخس بر اساس شبیه‌سازی با مدل MLP و داده‌های مشاهداتی در سال‌های ابتدایی، میانی و انتهایی پژوهش.

Figure 4. Zonation maps of the water table of Sarakhs plain based on simulation with MPL model and observed data in first, middle and end of research years.



ادامه شکل ۴-

Figure 4.

ابزاری قدرتمند جهت شبیه‌سازی فرآیندهای پیچیده و غیرخطی استفاده کرد. استفاده از این روش‌ها به‌ویژه در جاهایی که با کمبود داده‌های اندازه‌گیری مواجه هستیم می‌تواند به‌عنوان روشی جایگزین برای مدل‌های پیچیده و با هزینه بالا که نیاز به اطلاعات اندازه‌گیری زیادی دارند، باشد. نکته قابل توجه آن‌که در مدل‌های شبکه عصبی فرایندهای هیدرولوژی در نظر گرفته نمی‌شود و فقط بر اساس داده‌های ورودی و الگوریتم‌های تعریف‌شده شبیه‌سازی انجام می‌شود. بنابراین اگر تغییری در شرایط هیدرولوژی حوزه اتفاق بیافتد تأثیر آن تغییر فقط بر خروجی مشخص شده و تغییرات سایر فرایندهای هیدرولوژی حوزه موردنظر مشخص نمی‌شود. نتایج این پژوهش نشان داد ترکیب مدل MLP و روش درون‌یابی کریجینگ، راه‌حلی مناسب و کم‌هزینه برای شبیه‌سازی سطح تراز آب زیرزمینی دشت سرخس است. پیشنهاد می‌گردد برای داشتن دقت بیشتر در مدل هوش مصنوعی از بازه زمانی کم‌تری و متغیرهای وابسته بیشتری در صورت امکان استفاده شود. همچنین برای افزایش کارایی مدل‌های هوش مصنوعی برای پیش‌بینی سطح آب زیرزمینی از مدل‌های دیگر با الگوریتم‌های متفاوت استفاده شود.

نقشه‌ها و نمودارهای میزان افت سطح ایستابی منطقه نشان داد که میزان افت سطح ایستابی متوسط چاه‌های بخش شمالی در طی ده سال اخیر از ۱۷/۷۲ متر به ۲۳/۴۵ متر و در چاه‌های بخش جنوبی منطقه از ۲۰/۷۴ متر به ۲۳/۷۱ متر افزایش یافته است. نتایج مشابهی توسط فخاری و همکاران (۲۰۱۴) در دشت سرخس به‌دست آمده است، در این پژوهش مشخص شده پس از احداث سد دوستی در منطقه، میزان افت در چاه‌های شمال و جنوب دشت سرخس افزایش یافته است (۹).

### نتیجه‌گیری

برای برنامه‌ریزی بهتر و دقیق‌تر سطح آب‌های زیرزمینی منطقه، نقشه افت این منابع می‌تواند کمک شایانی باشد. آب‌های زیرزمینی به‌عنوان یک منبع مهم تأمین آب شیرین، جایگاه خاصی در مطالعات منابع آب دارد به‌طوری‌که پیش‌بینی نوسانات سطح آب زیرزمینی جهت برنامه‌ریزی برای بهره‌برداری از آن ضرورت دارد. شناخت رفتار یک سیستم آب زیرزمینی، نیازمند حفر تعدادی زیادی چاه اکتشافی و انجام عملیات پمپاژ و آزمایش‌های ژئوفیزیک و انجام یک سری مطالعات طولانی‌مدت است که با صرف هزینه‌های فراوان عملی می‌گردد. اما امروزه می‌توان از توانمندی‌های شبکه‌های عصبی مصنوعی به‌عنوان

منابع

1. Ahmadi, S.H., and Sedghamiz, A. 2008. Application and evaluation of Kriging and cokriging methods on groundwater depth mapping. *Environ. Monit. Assess.* 138: 1-3. 357-368.
2. Asghari Moghaddam, A., Fijani, E., and Nadiri, A. 2015. Optimization of DRASTIC model by artificial intelligence for groundwater vulnerability assessment in Maragheh-Bonab Plain. *Geosciences.* 24: 94. 169-176. (In Persian)
3. Azareh, A., Zehtabian, Gh.R., Nazari Samani, A.A., and Khosravi, H. 2015. Desertification monitoring in Garmsar plain with emphasis on water and agriculture criteria. *J. Range Water. Manage.* 68: 3. 427-439. (In Persian)
4. Bahremand, A. 2016. HESS Opinions: Advocating process modeling and De-emphasizing parameter estimation. *Hydrol. Earth Syst. Sci.* 20: 1433-1445.
5. Bameri, A., Piri, H., and Ganji, F. 2015. Assessment of groundwater pollution in Bajestan Plains for agricultural purposes using indicator Kriging. *J. Water Soil Cons.* 22: 1. 211-229. (In Persian)
6. Chang, X., Hui, J., Rong, W., and Hao, W. 2013. Groundwater level prediction based on BP and RBF neural network. *J. Appl. Sci. Engin. Res.* 3: 2. 263-269.
7. Dehghani, R., and Noorali, A. 2016. Comparison of geo-Statistical methods and artificial neural network in estimating groundwater level (Case study: Nourabad Plain, Lorestan). *J. Environ. Sci. Technol.* 18: 1. 31-43. (In Persian)
8. Delbari, M., Boustanian, M., and Afrasiyab, P. 2016. Investigation of spatial and temporal variations and zonation of ground water level in Kohpaye-Segzi Aquifer (Isfahan Province). *Geographic Space.* 52: 15. 305-324. (In Persian)
9. Fakhari, M., Saadat, S., and Fazel Valipour, M.E. 2014. The effect of Dosty dam construction on the groundwater resources of Sarakhs Plain. *International conference on sustainable development, strategies and challenges with focus on agriculture, natural Resources, environment and tourism, Tabriz.* 9p. (In Persian)
10. Habibi, M.H., Nadiri, A.A., Asghari Moghaddam, A., and Naderi, K. 2016. Combination of geostatistical and artificial intelligence methods for predicting spatiotemporal water level in the Hadishahr plain. *Iran-Watershed Management Science & Engineering.* 10: 32. 27-32. (In Persian)
11. Komasi, M., Goudarzi, H., and Behniya, A. 2017. Investigation spatial- temporal fluctuation ground water level by support vector machine and kriging method (Case study: Silakhor plain). *J. Water Soil Cons.* 24: 4. 195-209. (In Persian)
12. Kord, M., and Asghari Moghaddam, A. 2015. Evaluation of drinking water quality of Ardabil plain aquifer by cokriging and Fuzzy Logic. *J. Water Soil Cons.* 21: 5. 225-240. (In Persian)
13. Lohani, A.K., and Krishan, G. 2015. Application of artificial neural network for ground water level simulation in Amritsar and Gurdaspur Districts of Punjab, India. *J. Earth Sci. Clim. Change.* 6: 4. 1-5.
14. Mirzavand, M., Ghasemieh, H., Akbari, M., and Sadatinejad, S.J. 2015. Artificial neural Network (ANN) model for ground water quality simulation (Case study: Kashan aquifer). *J. Range Water. Manage.* 68: 1. 159-171. (In Persian)
15. Moslemzadeh, M., Salarijazi, M., and Soleymani, S. 2011. Application and assessment of kriging and cokriging methods on groundwater level estimation. *J. Amer. Sci.* 7: 7. 34-39.
16. Mozafari, Gh., and Behzadi Karimi, H. 2017. Estimation of groundwater levels in Bayza plain using geostatistical methods. *J. Geograph. Environ. Stud.* 6: 21. 145-163. (In Persian)
17. Nadiri, A., Sedghi, Z., and Kazemian, N. 2017. Optimization of DRASTIC method using ANN to evaluating of vulnerability of multiple Varzqan Aquifer. *J. Eco Hydrol.* 4: 4. 1089-1103. (In Persian)
18. Nadiri, A., Naderi, K., Asghari Moghaddam, A., and Habibi, M.H. 2014. Spatiotemporal predicting of

- groundwater level using artificial intelligence models and geostatistics model (Case study: Duzdizan plain). *J. Geograph. Plan.* 58: 20. 281-301. (In Persian)
19. Noor, H., Chezgy, J., Bagheriyan Kalat, A., Rajaie, S.H., and Seddigh, R. 2018. Assessment of quantitative status of groundwater resources in the Ghareghoom basin, Third National Conference of Soil and Water conservation, Tehran, Iran.
20. Notters, M., Brus, D.J., and Voshaar, O. 1995. A comparison of kriging, cokriging and combined with regression for spatial interpolation of horizon depth with censored observations, *Geoderma*. 67: 3. 227-246.
21. Pourseyadi, A., and Kashkuli, H.A. 2012. Studying of groundwater conditions in Jiroft Basin with MODFLOW, *J. Irrig. Sci. Engin.* 32: 2. 51-63. (In Persian)
22. Ramezani Charmahineh, A., and Zounemat-Kermani, M. 2017. Evaluation of the efficiency of support vector regression, multi-layer perceptron neural network and multivariate linear regression on groundwater level prediction (Case study: Shahrekord Plain). *J. Water. Manage. Res.* 8: 15. 1-12. (In Persian)
23. Sun, Y., Wendi, D., Kim, D.E., and Liong, S.Y. 2015. Application of artificial neural networks in groundwater table forecasting—a case study in Singapore swamp forest. *Hydrology and Earth System Science*. 5: 12. 9317-9336.
24. Suryanarayana, Ch., Sudheer, Ch., Mahammood, V., and Panigrahi, B.K. 2014. An integrated wavelet support vector machine for groundwater level prediction in Visakhapatnam, India. *Neurocomputing*. 15: 145. 324-335.
25. Yu, H., Wen, X., Feng, Q., Ravinesh, D., Jianhua, S., and Min, W. 2018. Comparative study of Hybrid-Wavelet artificial intelligence models for monthly groundwater depth forecasting in extreme arid regions, Northwest China. *Water Resources Management*. 23: 1. 301-323.
26. Zamani Ahmad Mahmoodi, R., Akhondali, A.M., Samadi Borojeni, H. and Zareei, H. 2013. Estimation of the groundwater level by using combined geostatistics with Artificial Neural Networks (Case study: Shahrekord Plain). *J. Irrig. Sci. Engin.* 36: 1. 45-56. (In Persian)
27. Zare Abyaneh, H., and Bayat Varkeshi, M. 2013. Development and application of statistical and neural, Fuzzy, Genetic Algorithm models in estimation of spatial distribution of water table level. *J. Water Soil Cons.* 20: 4. 1-25. (In Persian)



## Simulating the groundwater table of Sarakhs plain with combination of geostatistical and artificial intelligence methods

F. Ailmrzaei<sup>1</sup>, \*M. Azarakhshi<sup>2</sup>, A. Malekian<sup>3</sup> and M. Rostami Khalaj<sup>4</sup>

<sup>1</sup>M.Sc. Graduate, Dept. of Nature Engineering and Medicinal Plants, University of Torbat Heydarieh,

<sup>2</sup>Assistant Prof., Dept. of Nature Engineering and Medicinal Plants, University of Torbat Heydarieh,

<sup>3</sup>Associate Prof., Faculty of Natural Resources, University of Tehran, <sup>4</sup>Soil Conservation and Watershed Management Department, Agricultural and Natural Resources Research Center of Khorasan Razavi,

AREEO, Mashhad, Iran

Received: 12.10.2018; Accepted: 04.23.2019

### Abstract

**Background and Objectives:** Simulation of groundwater is very important in order to groundwater table prediction, hydrogeological and management studies, construction of structures, agricultural use, and access to high quality groundwater. In recent decades, artificial intelligence models have been tested for simulation of aquifers due to the complex and nonlinear properties of groundwater systems. The purpose of this study is comparison of the different models of artificial intelligence (artificial neural network, multi-layer perceptron, radial basis function and neuro-fuzzy) and its composition with geostatistics methods for modeling of the groundwater table in the Sarakhs plain. Investigation of recent studies shows that simulation of groundwater level with artificial intelligence methods in different regions has different results.

**Materials and Methods:** Sarakhs County with more than 5000 Km<sup>2</sup> area is located in 60° 30' to 61° 15' eastern longitude and 35° 55' to 36° 40' northern latitude. Sarakhs Plain's aquifer is unconfined type and shaped from a layer of alluvial. In this research, groundwater level data of 18 wells, rainfall and potential evaporation in statistical period (1992-2016) were used. The affected area of each climatology station was determined by Thiessen's method and climate data of each station generalized to wells which situated in related polygon. The artificial intelligence models that used in this study were Multi-Layer Perceptron (MLP), Radial Basis Function (RBF) and Neuro Fuzzy (NF) and geostatistics methods were Kocriging, Kriging and Inverse Distance Weighting. 70 percent of the input data was used for training of models and the remaining 30 percent was used to test them. To assess the results of simulations with Artificial Intelligence models, the criteria of correlation coefficient (R), Mean Absolute Error (MAE) and Coefficient of Determination (R<sup>2</sup>) and for evaluation of geostatistics method the criteria of Root Mean Square Error (RMSE) and Mean Square Error (MSE) were used.

**Results:** The results showed that the multi-layer perceptron model is more accurate than other models, according to R=0.77, R<sup>2</sup>=0.62 and MAE=0.80. To determine the best geostatistical model, for spatial prediction of the groundwater level, the results of multi-layer perceptron model were used as input data. The results showed that Kriging method with RMSS=1 and RMS=0.066, is better model to spatial simulation of groundwater level in Sarakhs plain and based on Kriging method, the maps of groundwater level in each year was designed. Assessment of these maps showed that the most decline of groundwater level is in the north parts of Skaraks plain and south part of this Palin has a little declining of groundwater level.

\* Corresponding Author; Email: m.azarakhshi@torbath.ac.ir

**Conclusion:** The combination of the MLP model and the Kriging interpolation method is a suitable and low cost solution for simulation of the groundwater level in the Sarakhs Plain. It is suggested that if possible more dependent variables be used to increase the accuracy of artificial intelligence models. Also, for better prediction of groundwater level, the other artificial intelligence models with different algorithms should be used.

**Keywords:** Groundwater, Kriging, Multi-Layer Perceptron model, Zoning