



## بررسی کارایی روش‌های رگرسیون بردار پشتیبان، شبکه عصبی پرسپترون چندلایه و رگرسیون خطی چندمتغیره به منظور پیش‌بینی تراز سطح آب زیرزمینی (مطالعه موردی: دشت شهرکرد)

عبداله رضانی چرمهینه<sup>۱</sup> و محمد ذونعت کرمانی<sup>۲</sup>

۱- دانش‌آموخته کارشناسی ارشد، دانشگاه شهید باهنر کرمان

۲- دانشیار، دانشگاه شهید باهنر کرمان، (نویسنده مسوول: zounemat@uk.ac.ir)

تاریخ پذیرش: ۹۴/۱/۲۲

تاریخ دریافت: ۹۳/۵/۲

### چکیده

تراز سطح آب زیرزمینی عاملی است که امکان قضاوت صحیح در مورد روند تغییرات آبخوان و مدیریت لازم در حوزه آبخیز را ایجاد می‌کند. در این تحقیق از اطلاعات ماهانه ۱۸ چاه مشاهده‌ای در دشت شهرکرد طی سال‌های ۱۳۷۹ تا ۱۳۸۹ به منظور شبیه‌سازی و پیش‌بینی سطح آب زیرزمینی با مدل‌های رگرسیون خطی چند متغیره (MLR)، شبکه عصبی پرسپترون چند لایه (MLP) و دو مدل رگرسیونی ماشین بردار پشتیبان (SVR) با توابع کرنل پایه شعاعی (RBF) و خطی (Linear) استفاده شده است. با توجه به معیارهای خطای ضریب راندمان (NS) و ریشه میانگین مربعات خطا (RMSE)، مدل MLP در ۵۶ درصد و مدل SVR نیز در ۴۴ درصد موارد عملکرد بهتری نسبت به نتایج کل سایر مدل‌ها داشته‌اند. به‌عنوان نمونه در چاه شماره ۱ (بخش مرکزی دشت)، مدل SVR-RBF با ترکیب ورودی پارامترهای متشکل از تراز سطح آب زیرزمینی، دما، تبخیر و بارش بر سایر مدل‌ها برتری داشته است. همچنین مقایسه کلی نتایج دو روش SVR، حاکی از برتری تابع کرنل RBF بر حالت خطی بوده است. عملکرد کلی مدل‌های MLP، SVR-RBF و SVR-Linear برای معیار NS به ترتیب برابر با ۰/۷۰۳، ۰/۷۵۶ و ۰/۶۵۵ و در شاخص RMSE نیز به ترتیب برابر با ۰/۸۵۷، ۰/۹۰۵ و ۰/۹۱۴ متر به دست آمده است.

واژه‌های کلیدی: پیش‌بینی سطح آب زیرزمینی، رگرسیون بردار پشتیبان، شبکه عصبی پرسپترون، رگرسیون چند متغیره، دشت شهرکرد

### مقدمه

امروزه منابع آب یکی از پایه‌های اصلی توسعه پایدار به شمار می‌رود (۱۶) و در بیشتر مناطق ایران، منابع آب‌های سطحی محدود هستند و حتی در بعضی مناطق، این منابع وجود ندارند (۲). شایان توجه است که قسمت عمده‌ای از کشور ایران با توجه به موقعیت خاص جغرافیایی خود دارای اقلیم خشک تا نیمه‌خشک می‌باشد به طوری که ۷۴ درصد از سطح کشور دارای بارندگی سالانه کمتر از ۲۵۰ میلی‌متر است. به دلیل کمبود نزولات جوی، عدم پراکنش متعادل آن از نظر زمانی و مکانی و همچنین عدم وجود رودخانه‌های دائمی در مناطق خشک و نیمه‌خشک، بهره‌برداری از منابع آب زیرزمینی در این مناطق در سطح وسیع و گسترده صورت می‌گیرد (۱۳). از این رو یکی از مباحث مهم در مدیریت حوزه آبخیز، پیش‌بینی تراز سطح آب زیرزمینی است تا بتوان با توجه به آن، برنامه‌ریزی‌های لازم در این زمینه را انجام داد و مدیریت موفق منابع آب در حوزه آبخیز نیازمند رویکردهای جهت‌دار، جامع و هدفمند می‌باشد تا بتواند با وجود روند تشدید مشکلات مربوط به آب و افزایش رو به رشد تقاضای آن، نیاز مصرف‌کنندگان را برطرف سازد. از طرفی در سال‌های اخیر، رشد روزافزون کاربرد هوش محاسباتی در حل مسائلی مشاهده می‌شود که تأثیر پارامترهای بسیار زیاد در برخی فرآیندهای فیزیکی و وجود روابط کاملاً غیرخطی میان آن‌ها حاکم می‌باشد و مبنای روش‌های هوشمند، استفاده از دانش نهفته در داده‌ها، تلاش برای استخراج روابط ذاتی بین آن‌ها و تعمیم آن در موقعیت‌های دیگر است (۱۴). بنابراین بهره‌گیری

از شیوه‌های نوین شبیه‌سازی منابع آب از جمله روش‌های ماشین بردار پشتیبان (SVM) و شبکه عصبی مصنوعی (ANN) از اهمیت ویژه‌ای برخوردار می‌باشد. همچنین جهت مدیریت جامع‌تر آبخوان‌ها، توجه به روش‌های آماری هم‌خالی از لطف نیست. از جمله این روش‌ها، رگرسیون خطی چند متغیره (MLR) را می‌توان نام برد (۲۶). یو و همکاران (۲۵) با استفاده از مدل ماشین بردار پشتیبان به پیش‌بینی تراز آب در رودخانه لانیانگ در تایوان پرداختند. نتایج نشان داد که مدل به‌خوبی سطح آب رودخانه را برای ۱ تا ۶ ساعت بعد پیش‌بینی می‌کند. لیجن و شیکوان (۱۲) روش حداقل مربعات ماشین بردار پشتیبان را در پیش‌بینی رواناب میان‌مدت و بلندمدت به کار گرفتند و آن را با مدل شبکه عصبی مصنوعی مقایسه کردند. نتایج نشان داد که ماشین بردار پشتیبان عملکرد بهتری داشته است. یون و همکاران (۲۴) روش‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی را برای پیش‌بینی تراز سطح آب زیرزمینی آبخوان ساحلی در کره جنوبی بررسی کردند. نتایج حاکی از کارایی دو روش بود به طوری که جذر میانگین مربعات خطا در مدل شبکه عصبی مصنوعی در مراحل آموزش و آزمون کمتر بوده است اما ضریب راندمان بیشتر در ماشین بردار پشتیبان موجب عملکرد بهتر آن شده است. لالاهایم و همکاران (۱۱) شبکه عصبی مصنوعی را در جهت ارزیابی تراز سطح آب زیرزمینی در آبخوانی آهکی در شمال فرانسه به کار گرفتند. نتایج حاکی از این بود که شبکه پرسپترون چندلایه (MLP) با حداقل نرون میانی در کوتاه‌مدت بهترین پیش‌بینی را انجام می‌دهد.

چشمه فعال است که سالانه حدود ۲۳۰ میلیون مترمکعب از منابع آب زیرزمینی دشت را تخلیه کرده و به مصارف گوناگون می‌رساند. درصد بسیار بالایی از آن (بیش از ۹۰ درصد) در بخش کشاورزی در فصل زراعی استفاده می‌شود. بخشی از آب شرب مردم شهرستان شهرکرد نیز از همین چاه‌ها تأمین می‌شود (۱۰). موقعیت جغرافیایی دشت شهرکرد در شکل ۱ نشان داده شده است.

### روش‌های مورد استفاده در این تحقیق رگرسیون خطی چند متغیره

رگرسیون خطی چند متغیره از روش‌هایی است که برای پیش‌بینی پدیده‌ها استفاده می‌شود (۹). این روش رابطه یک متغیر وابسته و مجموعه‌ای از متغیرهای مستقل را به‌طور همزمان مورد تجزیه و تحلیل قرار می‌دهد (۸). شکل کلی این مدل به‌صورت رابطه ۱ می‌باشد.

$$Y = a + B_1X_1 + B_2X_2 + \dots + B_nX_n + e \quad (1)$$

Y: متغیر وابسته، a: عدد ثابت مدل،  $X_1, X_2, \dots, X_n$ : متغیرهای مستقل،  $B_1, B_2, \dots, B_n$ : ضرایب مربوط به هر یک از متغیرهای مستقل و e: خطای مدل رگرسیون می‌باشند.

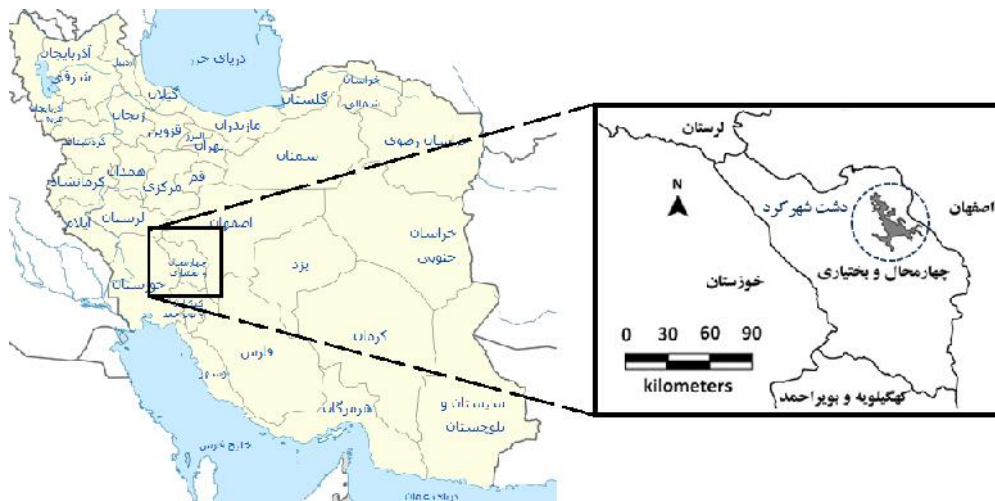
### شبکه عصبی پرسپترون چندلایه

در شبکه‌های چندلایه یک‌لایه ورودی وجود دارد که اطلاعات را دریافت می‌کند و دارای تعدادی لایه مخفی است که اطلاعات را از لایه‌های قبلی می‌گیرد. در اصل وجود لایه پنهان زمانی مفید است که تابع فعال‌سازی غیرخطی باشد و در نهایت یک‌لایه خروجی نیز وجود دارد که نتیجه محاسبات وارد آن و خروجی شبکه حاصل می‌شود (۱). در این شبکه‌ها مقادیر خروجی با مقادیر واقعی مقایسه شده و میزان خطا مشخص می‌گردد. سپس خطای محاسبه‌شده جهت تنظیم وزن‌ها و مقادیر بایاس شبکه پخش می‌شود که این روش به پس انتشار خطا موسوم است (۱۵، ۲۷، ۲۸).

سریکنت و همکاران (۲۲) تحقیقی در مورد کاربرد شبکه عصبی در پیش‌بینی نوسان‌های زمانی سطح آب زیرزمینی در حوزه آبخیز مهشورام در هندوستان انجام دادند. این تحقیق مؤید قابلیت شبکه عصبی مصنوعی در پیش‌بینی تراز سطح آب زیرزمینی با ریشه میانگین مربعات خطای ۴/۵ متر و ضریب تعیین ۰/۹۳ بود. رامیرز و همکاران (۱۸) مدل‌های رگرسیون خطی چند متغیره و شبکه عصبی را برای پیش‌بینی بارش در منطقه ساووپائولو در برزیل به کار گرفتند. دمای پتانسیل، مؤلفه قائم باد، رطوبت ویژه، دمای هوا، آب قابل بارش، چرخندگی نسبی و شار واگرایی رطوبت پارامترهای ورودی به مدل را تشکیل دادند. نتایج کارایی قابل قبول هر دو روش را در پیش‌بینی بارش نمایان کرد. محققین مختلفی از روش‌های رگرسیون خطی چند متغیره، شبکه عصبی مصنوعی و ماشین بردار پشتیبان به‌عنوان ابزارهایی مناسب و کارآمد در پژوهش‌های حوزه‌های آبخیز استفاده کرده‌اند. در نتیجه آبخوان‌ها از اهمیت زیادی در حوزه‌های آبخیز برخوردار هستند و تراز سطح آب زیرزمینی عامل مهمی در استفاده از آبخوان‌ها و مدیریت صحیح آن‌ها می‌باشد. تحقیق حاضر به ارزیابی کارایی روش‌های یادشده در پیش‌بینی تراز سطح آب زیرزمینی در دشت شهرکرد می‌پردازد.

### مواد و روش‌ها منطقه مورد مطالعه

دشت شهرکرد با وسعتی نزدیک به ۵۵۱ کیلومتر مربع در ناحیه زاگرس بلند و استان چهارمحال و بختیاری و نیز در طول جغرافیایی ۵۰° ۳۸' تا ۵۱° ۱۰' شرقی و عرض جغرافیایی ۳۲° ۰۷' تا ۳۲° ۳۵' شمالی قرار گرفته است. این دشت دارای ۴۱۷ حلقه چاه کشاورزی، ۵۹ حلقه چاه آب شرب، ۱۵۹ حلقه چاه صنعتی، ۷۹ رشته قنات و ۴۰ دهنه



شکل ۱- موقعیت جغرافیایی دشت شهرکرد  
Figure 1. Geographical location of the Shahrekord Plain

### ماشین بردار پشتیبان

SVM یک نوع سیستم یادگیری نظارت شده است که هم برای گروه بندی و هم برای تخمین و برآورد تابع برازش داده ها در مسائل رگرسیون به کار می رود به طوری که کمترین خطا در گروه بندی داده ها یا تابع برازش رخ دهد. این روش بر مبنای تئوری یادگیری آماری استوار است که از اصل کمینه سازی خطای ساختاری (SRM) بهره می جوید و موجب یک جواب بهینه کلی می گردد (۲۳). هدف رگرسیون بردار پشتیبان (SVR) که مدل رگرسیونی SVM می باشد این است که تابع  $f(x)$  را برای الگوهای آموزشی  $x$  طوری تشخیص دهد که بیشینه حاشیه را از مقادیر آموزشی  $y$  داشته باشد. به عبارت دیگر مدل SVR مدلی است که منحنی با ضخامت  $\varepsilon$  را به داده ها برازش می دهد به نحوی که کمترین خطا در داده های آزمون صورت گیرد (۲۰). در مدل SVM از مجموعه توابع به فرم  $f(x) = w \cdot x + b$  برای پیش بینی استفاده می شود که  $w$  وزن بردار  $x$  و  $b$  مقدار بایاس می باشند. برای کمینه کردن خطای آزمون باید عبارت پیچیدگی حداقل شود که مستلزم کمینه سازی نرم بردار وزن است. این شرایط می تواند به راحتی برای SVR با حاشیه نرم<sup>۴</sup> گسترش داده شود. در حقیقت، وپنیک برای کاربرد ماشین بردار پشتیبان در مسائل رگرسیون از تابع خطای جدیدی استفاده کرد که خطاهایی را که در یک فاصله معین از مقادیر واقعی می باشند، نادیده می گیرد (۲۱). این موضوع بدان معناست که باید مقداری انحراف<sup>۵</sup> از  $\varepsilon$  را قابل قبول دانست. انحراف اشاره شده به صورت رابطه ۲ تعریف می شود و بامنتور نمودن متغیرهای کمبود<sup>۶</sup>  $\xi_i^+$  و  $\xi_i^-$  در رابطه ۳ لحاظ می شود که در نهایت بر اساس اصل کمینه سازی خطای ساختاری، محدوده خطا به وسیله مسئله بهینه سازی<sup>۷</sup> در رابطه ۳ مطلوب و بهینه می گردد.

$$|\xi|_{\varepsilon} = \begin{cases} 0 & \text{if } |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & \text{otherwise} \end{cases} \quad (2)$$

$$\begin{aligned} \text{Minimize: } & \frac{1}{2}(w \cdot w) + C \sum_{i=1}^N (\xi_i^+ + \xi_i^-) \\ \text{Constraints: } & \begin{cases} w \cdot x_i + b - y_i \leq \varepsilon + \xi_i^+ & i=1,2,3,\dots,N \\ y_i - (w \cdot x_i + b) \leq \varepsilon + \xi_i^- & i=1,2,3,\dots,N \\ \xi_i^+ \geq 0, \xi_i^- \geq 0 & i=1,2,3,\dots,N \end{cases} \end{aligned} \quad (3)$$

محدوده لوله تقریب را تعیین می کند و  $C^A$  که ثابت گنجایش است خطای مربوط به انحراف بیشتر از  $\varepsilon$  را کنترل می کند. به طور کلی رگرسیون گیری داده ها به شیوه خطی به ندرت اتفاق می افتد و در عمل نحوه قرارگیری داده ها به صورت غیرخطی است. در این شرایط از روش غیرخطی رگرسیون بردار پشتیبان استفاده می شود. در این حالت الگوهای ورودی به فضایی با ابعاد بیشتر نگاشت می یابند به طوری که در فضای نگاشت یافته می توان به صورت خطی رگرسیون گیری کرد. معمولاً یافتن نگاشتی که مربوط به تابع کرنل خاصی باشد و یا پیدا کردن تابع کرنل<sup>۹</sup> مربوط به نگاشتی ویژه، سخت و حتی غیرممکن می باشد. انتخاب تابع کرنل موضوع مهمی است که بر اساس آزمون، اطلاع از مسائل طبقه بندی و

رگرسیون و همچنین ملاحظات نظری است (۶). از توابع کرنل شناخته شده در SVM می توان کرنل های خطی<sup>۱۰</sup> و پایه شعاعی (RBF)<sup>۱۱</sup> را نام برد (۴). معادله کرنل خطی به صورت رابطه ۴ می باشد. کرنل گوسی<sup>۱۲</sup> که به عنوان تابع RBF شناخته می شود (۶) در رابطه ۵ مشخص شده است. طرح کلی از مدل های ماشین بردار پشتیبان و شبکه عصبی مصنوعی در شکل ۲ نشان داده شده است.

$$k(u, v) = u \cdot v \quad (4)$$

$$k(u, v) = \exp\left(-\frac{\|u - v\|^2}{2\sigma^2}\right), \quad \frac{1}{2\sigma^2} = \gamma \quad (5)$$

### پیش بینی تراز سطح آب زیرزمینی دشت شهرکرد

به منظور مدیریت و برنامه ریزی منابع آب در دشت شهرکرد می توان از پیش بینی تراز سطح آب زیرزمینی بهره گرفت. پیش بینی تراز سطح آب دشت می تواند پایه بسیاری از تصمیم گیری ها در فرآیندهای هیدرولوژیکی و بهره برداری از منابع آب در حوزه آبخیز باشد. بنابراین پارامترهای مجموع بارندگی ماهانه، مجموع تبخیر ماهانه، متوسط دمای ماهانه و تراز سطح آب زیرزمینی در ماه های قبل (بین ۱ تا ۱۳ ماه با توجه به تأخیر زمانی) به عنوان ورودی برای مدل های MLP، SVR و SVR در نظر گرفته شده است. جهت پیش بینی تراز سطح آبخوان از اطلاعات ۱۸ چاه مشاهده ای طی سال های ۱۳۷۹ تا ۱۳۸۹ استفاده شده است. در همه مدل ها از ۸۰ درصد اول داده ها برای آموزش و از ۲۰ درصد باقی مانده برای آزمون استفاده شده است.

موقعیت چاه های مشاهده ای مورداستفاده در شکل ۳ و ویژگی های آن ها در جدول ۱ مشخص شده است. وضعیت توپوگرافی نشان داده شده در شکل ۳، بیانگر مرتفع بودن نواحی شمال غربی و شرقی است. در حالی که نواحی مرکزی و جنوبی دشت دارای کمترین ارتفاع می باشند.

نحوه رفتار تغییرات تراز سطح آب زیرزمینی مربوط به ۴ چاه مشاهده ای در نواحی شمال غربی، مرکزی، شرقی و جنوبی دشت شهرکرد در شکل ۴ مشخص شده است که نشان دهنده نوسانات قابل توجه تراز سطح آب زیرزمینی در این دشت است.

### پارامترهای ورودی و مدل

پارامترهای ورودی به مدل ها عبارت اند از: P (مجموع بارندگی ماهانه برحسب میلی متر)، E (مجموع تبخیر ماهانه برحسب میلی متر)، T (متوسط دمای ماهانه برحسب درجه سانتی گراد) و G (تراز سطح آب زیرزمینی برحسب متر). با استفاده از این پارامترها برای هر چاه مدل سازی انجام شده است.

### تأخیر زمانی

با توجه به این که داده های موجود تشکیل سری زمانی می دهند در ابتدا تأخیر زمانی بر روی پارامترهای ورودی لحاظ شده است که به صورت  $X - a$  مشخص شده است. X پارامتر ورودی و a تعداد ماه تأخیر می باشد. برای به دست آوردن مقدار تأخیر از توابع خودهمبستگی (ACF) و همبستگی متقابل (CCF) استفاده شده است. لازم به ذکر است با توجه به


1- Statistical learning theory  
4- Soft margin  
7-Optimization problem  
10- Linear

2- Structural Risk Minimization  
5-Deviation  
8- Capacity  
11- Radial Basis Function

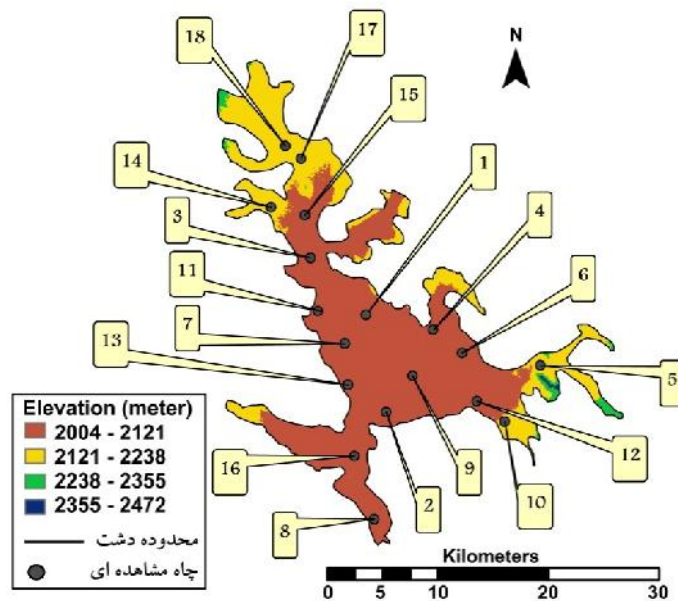
3-Support Vector Regression  
6- Slack variables  
9- kernel function  
12- Gaussian kernel

پیشنهاد می‌شود که پارامتر ورودی  $G$  (با توجه به نمودار الف) به اندازه ۱، ۲ و ۳ ماه تأخیر ( $G-1$ ،  $G-2$ ،  $G-3$ ) برای مدل‌سازی در نظر گرفته شود. به همین ترتیب با توجه به نمودارهای ب، ج و د پیشنهاد می‌شود که پارامترهای  $P$  به اندازه ۳ ماه ( $P-3$ )،  $E$  به اندازه ۸ ماه ( $E-8$ ) و  $T$  به اندازه ۳ ماه ( $T-3$ ) برای مدل‌سازی تأخیر یابند.

اهمیت و تأثیر زیاد تراز سطح آب زیرزمینی در ماه‌های قبل در مدل‌سازی، این پارامتر تا ۳ مرتبه تأخیر داده شده است. به عنوان نمونه، نمودارهای ACF و CCF برای چاه مشاهده‌ای شماره ۱ در شکل ۵ آورده شده‌اند. همان‌طور که در نمودارهای شکل ۵، میزان بیشینه همبستگی بین پارامترهای ورودی به مدل ( $T$  و  $E$ ،  $P$ ،  $G$ ) با خروجی از مدل ( $G$ ) با علامت پیکان مشخص شده است،



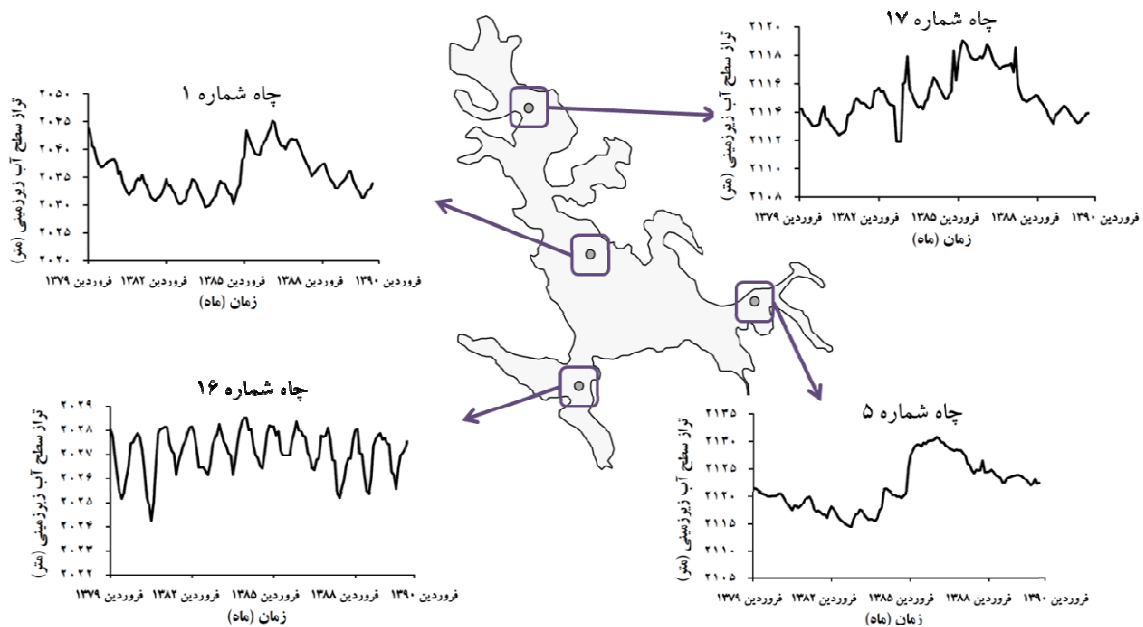
شکل ۲- طرح کلی از مدل‌های مورد استفاده در مطالعه حاضر، الف: ماشین بردار پشتیبان، ب: شبکه عصبی مصنوعی (۲۴)  
Figure 2. A schematic diagram of the models used in this study: (a) SVM, (b) ANN [24]



شکل ۳- نقشه پراکنش چاه‌های مشاهده‌ای مورد استفاده در مدل‌های MLR، MLP و SVR طی سال‌های ۱۳۷۹ تا ۱۳۸۹  
Figure 3. Map of distribution of observational wells used in MLR, MLP and SVR models during 2000 to 2010

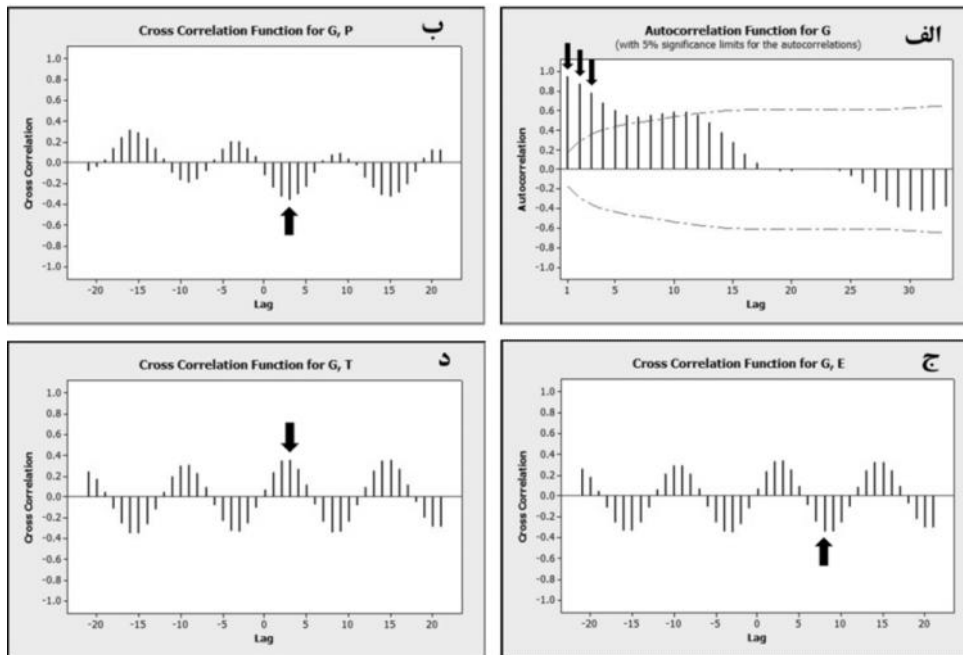
جدول ۱- مشخصات چاه‌های مشاهده‌ای به کاررفته در مدل‌های MLP، MLR و SVR طی سال‌های ۱۳۷۹ تا ۱۳۸۹  
Table 1. Characteristics of observational wells used in MLR, MLP and SVR models during 2000 to 2010

شماره	نام محل	$X_{UTM}$ (متر)	$Y_{UTM}$ (متر)	تراز دهانه چاه (متر)
۱	اول قلنگان جاده کمربندی	۴۸۴۳۸۶	۳۵۷۶۸۶۸	۲۰۴۹/۴۲
۲	بهرام آباد	۴۸۶۲۱۹	۳۵۶۸۰۴۵	۲۰۴۰/۳۰
۳	چالشر - نرسیده به مزرعه ستوده	۴۷۹۳۴۹	۳۵۸۲۰۲۳	۲۰۸۲/۶۹
۴	دوتوه شهرکرد	۴۹۰۴۷۹	۳۵۷۵۵۱۲	۲۰۵۹/۷۴
۵	دوراهی بروجن - اصفهان	۵۰۰۲۴۵	۳۵۷۲۲۸۰	۲۱۳۵/۴۳
۶	روبروی انبار نفت	۴۹۳۱۳۲	۳۵۷۳۴۰۸	۲۰۶۳/۳۸
۷	سه راه هفشجان	۴۸۲۴۶۵	۳۵۷۴۲۶۱	۲۰۵۳/۷۵
۸	شمس آباد	۴۸۵۱۴۳	۳۵۵۸۳۲۲	۲۰۲۰/۲۰
۹	شهرک	۴۸۸۶۲۷	۳۵۷۱۳۳۰	۲۰۴۴/۸۰
۱۰	شورابچه	۴۹۷۰۰۵	۳۵۶۷۱۸۳	۲۱۳۲/۳۷
۱۱	قلنگان - جاده گاز	۴۸۰۰۱۲	۳۵۷۷۲۰۱	۲۰۷۱/۶۴
۱۲	گود قرق فرخشهر	۴۹۴۴۷۷	۳۵۶۹۰۳۰	۲۰۸۵/۱۲
۱۳	مزرعه استکی	۴۸۲۷۴۹	۳۵۷۰۵۱۷	۲۰۵۰/۸۸
۱۴	نافج - پیر بلوط	۴۷۵۷۵۸	۳۵۸۶۶۳۵	۲۱۳۹/۲۴
۱۵	نافج - کوره آجر پزی	۴۷۸۸۳۳	۳۵۸۵۸۹۹	۲۱۰۵/۷۲
۱۶	نوآباد	۴۸۳۳۳۸	۳۵۶۴۰۵۱	۲۰۲۹/۴۶
۱۷	وردنجان - نافج	۴۷۸۴۸۴	۳۵۹۱۰۳۸	۲۱۳۹/۹۲
۱۸	وردنجان - هرچگان	۴۷۷۰۶۱	۳۵۹۲۱۸۸	۲۱۵۰/۲۵



شکل ۴- نمودار تراز سطح آب زیرزمینی چاه‌های مشاهده‌ای شماره‌های ۱، ۵، ۱۶ و ۱۷ به ترتیب در نواحی مرکزی، شرقی، جنوبی و شمال غربی دشت طی سال‌های ۱۳۷۹ تا ۱۳۸۹

Figure 4. Plot of groundwater level in wells No. 1, 5, 16 and 17 in the Central, Eastern, Southern and Northwestern plain parts respectively during 2000 to 2010




شکل ۵- نمودارهای ACF و CCF چاه مشاهده‌ای شماره ۱، الف): نمودار ACF تراز سطح آب زیرزمینی، ب): نمودار CCF بارندگی و تراز سطح آب زیرزمینی، ج): نمودار CCF تبخیر و تراز سطح آب زیرزمینی، د): نمودار CCF دما و تراز سطح آب زیرزمینی  
Figure 5. Plot of ACF and CCF in observational well No. 1: (a) ACF of groundwater level, (b) CCF of precipitation and groundwater level, (c) CCF of evaporation and groundwater level, (d) CCF of temperature and groundwater level

این رابطه کاهش می‌یابد. بنابراین محور افقی در نمودار Mallow's Cp مبنای ترتیب اضافه شدن پارامترهای تأخیر یافته‌ی ورودی به مدل قرار گرفته است. به عبارت دیگر نحوه اضافه شدن پارامترها به ورودی مدل و در نتیجه ایجاد ترکیب‌های ورودی به همین ترتیب انتخاب شده است (شکل ۶-ب). مزیت چنین روشی این است که کشف روابط غیرخطی پارامترهای ورودی با خروجی مدل به عهده روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان قرار می‌گیرد. پس میزان کارایی این روش‌ها به خوبی مشخص می‌شود.

### روش رگرسیون گام به گام

زمانی که تعداد داده‌های پیش‌بینی کننده زیاد می‌شود روش گام به گام می‌تواند بهترین متغیرها را انتخاب کند (۱۷). بنابراین با این روش پارامترهای ورودی مورد بررسی قرار گرفته‌اند. برای روشن شدن مطلب، نمودار آماری Mallow's Cp برای پارامترهای تأخیر یافته ورودی به مدل و همچنین ترکیب‌های آن‌ها برای چاه مشاهده‌ای شماره ۱ در شکل ۶ آورده شده است. همان‌طور که در شکل ۶-الف مشخص است بیشترین رابطه خطی بین پارامتر ورودی با خروجی مدل را G-1 دارد که با اضافه شدن سایر پارامترها



شکل ۶- مدل‌سازی چاه مشاهده‌ای شماره ۱، الف) نمودار Mallow's Cp برای پارامترهای تأخیر یافته‌ی ورودی به مدل، ب) ترکیب‌های ورودی به مدل

Figure 6. Modeling of observational well No. 1: (a) Plot of Mallow's Cp in lagged inputs to the model, (b) Input combinations to the model

### استانداردسازی داده‌ها

در این تحقیق استانداردسازی داده‌های ورودی به مدل با استفاده از رابطه ۶ صورت گرفته است و داده‌ها در دامنه  $[0,1]$  قرار گرفته‌اند.

$$X_s = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (6)$$

جایی که  $X_s$  مقدار استاندارد شده،  $X$  مقدار واقعی،  $X_{\min}$  کمترین مقدار و  $X_{\max}$  بیشترین مقدار داده مورد نظر می‌باشند.

### مدل MLR

در پژوهش حاضر از رگرسیون خطی چند متغیره بر پایه متغیرهای مجموع بارندگی ماهانه، مجموع تبخیر ماهانه، متوسط دمای ماهانه و تراز سطح آب زیرزمینی در ماه‌های قبل به‌عنوان متغیرهای مستقل و تراز سطح آب زیرزمینی به‌عنوان متغیر وابسته بهره گرفته شده است.

### مدل MLP

در این مقاله از شبکه عصبی پرسپترون چندلایه استفاده شده است. این شبکه یکی از مهم‌ترین شبکه‌های عصبی در مدل‌سازی و حل مسائل پیچیده غیرخطی است (۳). این مدل دارای یک لایه ورودی، یک لایه پنهان و یک لایه خروجی بوده است. توابع فعال‌سازی سیگموئید لجستیک و تانژانت هیپربولیک به کار گرفته شده‌اند چرا که دامنه داده‌های استاندارد شده در دامنه این توابع قرار دارد و سبب بهبود عملکرد شبکه می‌شوند. همچنین از الگوریتم آموزش BFGS استفاده شده است.

### مدل SVR

در این نوشتار توابع کرنل RBF و خطی به کار گرفته شده‌اند چرا که تابع RBF به‌عنوان یکی از بهترین توابع کرنل گزارش شده است (۵) و جهت امکان مقایسه بهتر نتایج تابع خطی نیز آورده شده است. پارامتر  $\gamma$  برابر با  $\frac{1}{k}$  در نظر گرفته شده است که  $k$  برابر با تعداد پارامترهای ورودی به مدل است. پارامترهای  $C$  و  $\epsilon$  با استفاده از سعی و خطا به دست آمده‌اند.

### معیارهای ارزیابی مدل

جهت مقایسه و ارزیابی عملکرد مدل‌های مورد بررسی در پژوهش حاضر از معیارهای راندمان نش ساکلیف (NS)، ریشه میانگین مربعات خطا (RMSE)، میانگین درصد خطای مطلق (MAPE) و ضریب همبستگی (CORR) استفاده شده است (۲۴). رابطه‌های ۷ تا ۱۰ این معیارها را نشان می‌دهند.

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (8)$$

$$MAPE = 100 \times \frac{1}{n} \left( \sum_{i=1}^n \frac{|O_i - P_i|}{O_i} \right) \quad (9)$$

$$CORR = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \quad (10)$$

$O_i$  مقدار مشاهداتی،  $P_i$  مقدار پیش‌بینی شده با مدل،  $\bar{O}$  میانگین مقادیر مشاهداتی،  $\bar{P}$  میانگین مقادیر پیش‌بینی شده با مدل و  $n$  تعداد مقادیر مشاهداتی یا پیش‌بینی شده می‌باشند. هر اندازه مقادیر NS و CORR به یک و هر چه معیارهای RMSE و MAPE به صفر نزدیک‌تر باشند بیانگر کارایی و دقت بیشتر مدل است (۷).

### نتایج و بحث

در مطالعه حاضر با استفاده از روش‌های MLP، MLR و SVR با توابع کرنل RBF و خطی برای ۱۸ چاه مشاهده‌ای در دشت شهرکرد در سال‌های ۱۳۸۸ و ۱۳۸۹ تراز سطح آب زیرزمینی پیش‌بینی شده است. با توجه به این که NS و RMSE معیارهایی توانمند برای ارزیابی مدل‌های هیدرولوژیکی هستند (۲۴،۴) در این تحقیق از آن‌ها به‌عنوان معیارهای اصلی مقایسه مدل‌ها استفاده شده است. به‌عنوان نمونه، نتایج مدل‌سازی برای چاه مشاهده‌ای شماره ۱ در جدول‌های ۲ و ۳ آورده شده است. جدول ۲ ساختار شبکه و توابع فعال‌سازی لایه‌های پنهان و خروجی در مدل MLP و مقادیر  $\gamma$ ،  $C$  و  $\epsilon$  در مدل SVR را در چاه شماره ۱ نشان داده است. در جدول ۳ با توجه به معیارهای ارزیابی مشخص است که در چاه مشاهده‌ای شماره ۱، مدل MLP بهتر از سایر مدل‌ها آموزش دیده است و مدل SVR با تابع کرنل RBF بهترین عملکرد را داشته است. علت این موضوع، آن است که با افزایش پارامترهای ورودی و پیچیده شدن روابط غیرخطی مدل SVR از توانایی بیشتری نسبت به سایر مدل‌ها برخوردار بوده است.

برای مثال، نمودار پراکنش مقادیر مشاهداتی و پیش‌بینی شده با مدل و نمودار تراز سطح آب زیرزمینی مشاهداتی و پیش‌بینی شده برای بهترین ترکیب در مرحله آزمون (ترکیب شماره ۳ با مدل MLP) برای چاه مشاهده‌ای شماره ۱ طی سال‌های ۱۳۸۸ و ۱۳۸۹ در شکل ۷ آورده شده‌اند. با توجه به نتایج ارائه شده در شکل، توانایی بالای مدل MLP در پیش‌بینی تراز سطح آب زیرزمینی در چاه مورد نظر مشخص می‌شود.

همچنین رابطه رگرسیونی برتر مدل MLR در مرحله آزمون متشکل از متغیرهای مستقل تراز سطح آب زیرزمینی در ماه قبل، تبخیر ۸ ماه قبل و دمای ۳ ماه قبل برای چاه مشاهده‌ای شماره ۱ در رابطه ۱۱ آورده شده است.

$$G = 46.7523 + 0.976245 (G-1) + 0.00645913 (E-8) + 0.0446427 (T-3) \quad (11)$$

توجه به نتایج جدول ۴ نشان می‌دهد که برای ۱۸ چاه مشاهده‌ای مورد بررسی در دشت شهرکرد مدل‌های MLP و SVR نتایج قابل قبولی در پیش‌بینی تراز سطح آب زیرزمینی

تابع کرنل RBF عملکرد بهتری از حالت خطی در هر دو مرحله آموزش و آزمون داشته است. صحت این موضوع با توجه به عملکرد غیرخطی تابع RBF در پردازش اطلاعات نسبت به تابع خطی نیز دور از انتظار نیست. توجه به نتایج جدول ۴ بیانگر عملکرد مناسب روش رگرسیون خطی چند متغیره در مرحله آموزش در قیاس با روش‌های غیرخطی است (۳۷/۰۴ درصد موارد)، با این وجود به دلیل وجود ماهیت پیچیده و غیرخطی مدل‌سازی سطح آب زیرزمینی، این روش در مرحله آزمون کفایت لازم را نسبت به مدل‌های غیرخطی نشان نداده است (در هیچ‌یک از موارد برتر نبوده است). بنابراین با توجه به یافته‌های حاصل از این تحقیق پیشنهاد می‌شود جهت مدل‌سازی رفتار سری زمانی تغییرات سطح آب زیرزمینی استفاده از روش‌های غیرخطی داده محور نسبت به روش‌های خطی در اولویت قرار داده شوند، که این مسئله با نتایج حاصل از محققان دیگر نیز همسو می‌باشد (۱۹).

ارائه کرده‌اند و نسبت به روش رگرسیون خطی چند متغیره برتری داشته‌اند. به طوری که برتری مدل‌های MLP، MLR، SVR-RBF و SVR-Linear در مرحله آزمون به ترتیب برابر با ۰، ۵۵/۵۵، ۲۷/۷۸ و ۱۶/۶۷ درصد نسبت به نتایج کل مدل‌ها بوده است. یکی از دلایل این موضوع را می‌توان به دلیل وجود رابطه غیرخطی تراز سطح آب زیرزمینی با بارندگی، دما و تبخیر نسبت داد. برتری مدل‌های MLP، SVR-RBF و SVR-Linear در مرحله آموزش به ترتیب برابر با ۳۷/۰۴، ۵۰، ۱۲/۹۶ و ۰ درصد نسبت به نتایج کل مدل‌ها بوده است. این مسئله بیانگر برتری عملکرد MLP در مراحل آموزش و آزمون در قیاس با مدل SVR می‌باشد. یکی از دلایل بالقوه عدم برتری SVR نسبت به MLP، بزرگ بودن بازه زمانی ماهانه برای پیش‌بینی تراز سطح آب زیرزمینی برای روش SVR است؛ به طوری که امکان فراگیری کامل اطلاعات در فواصل زمانی ماهانه توسط روش SVR وجود ندارد. در استفاده از ماشین بردار پشتیبان


جدول ۲- نتایج پارامترهای مدل‌های MLP و SVR برای چاه مشاهده‌ای شماره ۱

Table 2. Results of parameters of MLP and SVR models in observational well No. 1

مدل						شماره ترکیب	
SVR-Linear		SVR-RBF		MLP			
$\sigma$	C	$\sigma$	C	$\gamma$	تابع لایه پنهان	ساختار شبکه	
۰/۸	۱۰	۰/۸	۱۰	۱	Tanh	Logistic Sigmoid	۱-۴-۱
۰/۸	۱۰	۰/۸	۱۰	۰/۵	Tanh	Logistic Sigmoid	۲-۶-۱
۰/۸	۱۰	۰/۰۰۱	۱۰	۰/۳۳۳	Tanh	Logistic Sigmoid	۳-۵-۱
۰/۸	۱۰	۰/۰۰۱	۱۰	۰/۲۵	Logistic Sigmoid	Logistic Sigmoid	۴-۵-۱
۰/۸	۱۰	۰/۰۰۱	۱۰	۰/۲	Logistic Sigmoid	Logistic Sigmoid	۵-۸-۱
۰/۸	۱۰	۰/۰۰۱	۱۰	۰/۱۶۷	Logistic Sigmoid	Logistic Sigmoid	۶-۶-۱

جدول ۳- نتایج ارزیابی مدل های MLP، MLR و SVR برای چاه مشاهده ای شماره ۱  
Table 3. Results of evaluation of MLP, MLR and SVR models in observational well No. 1

شماره ترکیب	مدل	مرحله آموزش				مدل	مرحله آزمون			
		NS	RMSE (m)	MAPE (%)	CORR		NS	RMSE (m)	MAPE (%)	CORR
۱	MLR	۰/۹۳۱	۱/۰۹۷	۰/۰۴۱	۰/۹۶۵	۰/۸۱۵	۰/۷۴۶	۰/۰۳۱	۰/۹۱۲	
	MLP	۰/۹۳۱	۱/۰۹۱	۰/۰۴۱	۰/۹۶۵	۰/۸۲۸	۰/۷۲۰	۰/۰۳۱	۰/۹۱۲	
	SVR-RBF	۰/۹۳۰	۱/۱۰۲	۰/۰۴۱	۰/۹۶۵	۰/۸۲۷	۰/۷۲۳	۰/۰۳۲	۰/۹۱۱	
	SVR-Linear	۰/۹۳۰	۱/۱۰۴	۰/۰۴۱	۰/۹۶۵	۰/۸۲۱	۰/۷۳۵	۰/۰۳۲	۰/۹۱۲	
۲	MLR	۰/۹۵۳	۰/۹۰۱	۰/۰۳۱	۰/۹۷۶	۰/۸۷۱	۰/۶۲۴	۰/۰۲۳	۰/۹۶۳	
	MLP	۰/۹۵۷	۰/۸۶۰	۰/۰۲۹	۰/۹۷۸	۰/۸۹۸	۰/۵۵۵	۰/۰۲۰	۰/۹۶۳	
	SVR-RBF	۰/۹۵۵	۰/۸۷۹	۰/۰۲۹	۰/۹۷۸	۰/۸۸۳	۰/۵۹۴	۰/۰۲۱	۰/۹۵۸	
	SVR-Linear	۰/۹۵۳	۰/۹۰۵	۰/۰۳۱	۰/۹۷۶	۰/۸۸۱	۰/۵۹۹	۰/۰۲۲	۰/۹۶۱	
۳	MLR	۰/۹۵۶	۰/۸۷۵	۰/۰۳۰	۰/۹۷۸	۰/۸۸۳	۰/۵۹۵	۰/۰۲۲	۰/۹۶۰	
	MLP	۰/۹۶۲	۰/۸۱۶	۰/۰۲۶	۰/۹۸۱	۰/۹۱۱	۰/۵۱۸	۰/۰۱۹	۰/۹۶۵	
	SVR-RBF	۰/۹۵۸	۰/۸۵۷	۰/۰۲۵	۰/۹۷۹	۰/۹۰۵	۰/۵۳۵	۰/۰۲۰	۰/۹۵۸	
	SVR-Linear	۰/۹۵۵	۰/۸۷۸	۰/۰۳۰	۰/۹۷۸	۰/۸۹۵	۰/۵۶۴	۰/۰۲۰	۰/۹۶۱	
۴	MLR	۰/۹۵۷	۰/۸۶۵	۰/۰۳۰	۰/۹۷۸	۰/۸۸۰	۰/۶۰۲	۰/۰۲۱	۰/۹۵۶	
	MLP	۰/۹۵۸	۰/۸۴۹	۰/۰۳۰	۰/۹۷۹	۰/۸۹۷	۰/۵۵۷	۰/۰۲۱	۰/۹۵۴	
	SVR-RBF	۰/۹۵۹	۰/۸۴۴	۰/۰۲۵	۰/۹۷۹	۰/۹۰۲	۰/۵۴۴	۰/۰۲۱	۰/۹۶۰	
	SVR-Linear	۰/۹۵۳	۰/۸۹۸	۰/۰۳۰	۰/۹۷۷	۰/۸۸۷	۰/۵۸۵	۰/۰۲۲	۰/۹۶۴	
۵	MLR	۰/۹۵۹	۰/۸۴۷	۰/۰۳۱	۰/۹۷۹	۰/۸۶۲	۰/۶۴۶	۰/۰۲۴	۰/۹۵۰	
	MLP	۰/۹۶۲	۱/۰۰۵	۰/۰۳۵	۰/۹۷۵	۰/۸۹۲	۰/۵۷۱	۰/۰۲۲	۰/۹۵۸	
	SVR-RBF	۰/۹۶۰	۰/۸۳۴	۰/۰۲۴	۰/۹۸۰	۰/۸۹۳	۰/۵۶۷	۰/۰۲۲	۰/۹۵۷	
	SVR-Linear	۰/۹۵۶	۰/۸۷۲	۰/۰۳۱	۰/۹۷۸	۰/۸۷۶	۰/۶۱۲	۰/۰۲۳	۰/۹۵۹	
۶	MLR	۰/۹۵۹	۰/۸۴۷	۰/۰۳۱	۰/۹۷۹	۰/۸۶۲	۰/۶۴۵	۰/۰۲۴	۰/۹۵۰	
	MLP	۰/۹۶۷	۰/۷۵۲	۰/۰۲۷	۰/۹۸۴	۰/۸۷۴	۰/۶۱۷	۰/۰۲۳	۰/۹۴۶	
	SVR-RBF	۰/۹۶۵	۰/۷۷۹	۰/۰۲۴	۰/۹۸۳	۰/۹۰۹	۰/۵۲۵	۰/۰۲۱	۰/۹۵۹	
	SVR-Linear	۰/۹۵۶	۰/۸۷۳	۰/۰۳۱	۰/۹۷۸	۰/۸۷۲	۰/۶۲۱	۰/۰۲۳	۰/۹۶۰	



شکل ۷- مقادیر مشاهده‌ای و پیش‌بینی شده مربوط به بهترین ترکیب در چاه مشاهده‌ای شماره ۱ با استفاده از مدل MLP طی سال‌های ۱۳۸۸ و ۱۳۸۹ (الف) نمودار پراکنش، (ب) نمودار تراز سطح آب زیرزمینی  
Figure 7. Observed and predicted values of the best combination in observational well No. 1 using MLP model during 2009 and 2010: (a) Scatter plot, (b) Groundwater level plot

جدول ۴- درصد برتری مدل‌های MLP، SVR و MLP برای ۱۸ چاه مشاهده‌ای مورد بررسی در تحقیق حاضر  
Table 4. Percentage of superiority of MLP, MLP and SVR models in 18 observational wells used in this research

درصد برتری مدل		مدل
مرحله آزمون	مرحله آموزش	
۰	۳۷/۰۴	<b>MLR</b>
۵۵/۵۵	۵۰	<b>MLP</b>
۲۷/۷۸	۱۲/۹۶	<b>SVR-RBF</b>
۱۶/۶۷	۰	<b>SVR-Linear</b>

### منابع

1. Abraham, A. 2005. Artificial neural networks. In: Sydenham, P.H. and R. Thorn (eds.) Handbook of measuring system design, 901-908 pp., John Wiley & Sons, Stillwater, OK, USA.
2. Akbarzadeh, F., H. Hasanpour and S. Emamgholizadeh. 2016. Groundwater level prediction of Shahrood Plain using RBF neural networks. Journal of Watershed Management Research, 7: 104-118 (In Persian).
3. Ardicioglu, M., O. Kisi and T. Haktanir. 2007. Suspended sediment prediction using two different feed-forward backpropagation algorithms. Canadian Journal of Civil Engineering, 34: 120-125.
4. Chen, S.T. and P.S. Yu. 2007. Pruning of support vector networks on flood forecasting. Journal of Hydrology, 347: 67-78.
5. Dibike, Y.B., S. Velickov, D.P. Solomatine and M.B. Abbott. 2001. Model induction with support vector machines: introduction and applications. Journal of Computing in Civil Engineering, 15: 208-216.
6. Erasto, P. 2001. Support vector machines-backgrounds and practice. BSc Thesis, University of Helsinki, Faculty of Science, Rolf Nevanlinna Institute, Helsinki, Finland. 78 pp.
7. Govindaraju, R.S. 2000. Artificial neural networks in hydrology. I: preliminary concepts. Journal of Hydrologic Engineering, 5: 115-123.
8. Javadi, M.R., H. Tehranipour, Sh.A. Gholami and M.A. Fatahi Ardakani. 2012. Comparing methods of Mora and Varson and multivariate regression in zoning landslide hazard of Kan Watershed. Journal of Watershed Management Research, 3: 92-105 (In Persian).
9. Kiarash, S., A. Enderami, A. Malekian and M. Mahdavi. Investigation of the capability of artificial neural networks for estimating suspended sediment load (Case Study: Silakhor Watershed, Lorestan Province). 9<sup>th</sup> International River Engineering Conference, 8 pp., Ahwaz, Iran (In Persian).
10. Lalehzari, R. and S.H. Tabatabaei. 2010. Chemical characteristics of groundwater in Shahrekord Plain. Journal of Environmental Studies, 36: 55-62 (In Persian).
11. Lallahem, S., J. Mania, A. Hani and Y. Najjar. 2005. On the use of neural networks to evaluate groundwater levels in fractured media. Journal of Hydrology, 307: 92-111.
12. Lijun, F. and L. Shuquan. 2007. Forecasting the runoff using least square support vector machine. Tianjin Teaching Committee, TJGL06-099: 884-889.
13. Mahdavi, R., J. Abedi Koupaei, M. Rezaei and M. Abdolhosseini. 2004. Identification of appropriate sites for artificial recharge of groundwater resources using RS and GIS. 2<sup>nd</sup> Students Conference on Soil and Water Resources, 11 pp., Shiraz, Iran (In Persian).
14. Moharampour, M., A. Mehrabi and M. Katouzi. 2010. Evaluation of support vector machine on daily flow prediction. 4<sup>th</sup> Iran Water Resources Management Conference, 11 pp., Tehran, Iran (In Persian).
15. Mukerji, A., C. Chatterjee and N.S. Raghuvanshi. 2009. Flood forecasting using ANN, neuro-fuzzy, and neuro-GA models. Journal of Hydrologic Engineering, 14: 647-652.
16. Naserabadi, F., A. Esmali Ouri, H. Akbari and R. Rostamian. 2016. River flow simulation using SWAT model (Case study: Ghareh Su River in Ardabil Province-Iran). Journal of Watershed Management Research, 7: 50-59 (In Persian).
17. Pourkerman, M., A. Charkhabi, H. Mosadegh, H. Peyrowan and A. Talebi. 2011. Identification of effective chemical factors on soil resistivity using discriminant analysis stepwise method (case study: marls of Sorkheh Watershed). Iranian Journal of Watershed Management Science and Engineering, 5: 23-32 (In Persian).
18. Ramirez, M.C.V., H.F. Campos Velho and N.J. Ferreira. 2005. Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. Journal of Hydrology, 301: 146-162.
19. Razavi Ghahfarokhi, S.B., Sh. Karimi Googhari and M.B. Rahnama. 2013. Shahr-e-kord Plain groundwater level modeling using artificial neural networks and wavelet analysis. The 2<sup>nd</sup> International Conference on Plant, Water, Soil and Weather Modeling, 12 pp., Kerman, Iran (In Persian).
20. Sahrai, Sh. and M. Zaker Moshfegh. 2013. Using support vector machines for river flow prediction. 7<sup>th</sup> National Congress on Civil Engineering, 9 pp., Zahedan, Iran (In Persian).
21. Smola, A.J. and B. Scholkopf. 2004. A tutorial on support vector regression. Statistics and Computing, 14: 199-222.
22. Sreekanth, P.D., N. Geethanjali, P.D. Sreedevi, S. Ahmed, N. Ravi Kumar and P.D. Kamala Jayanthi. 2009. Forecasting groundwater level using artificial neural networks. Current Science, 96: 933- 939.
23. Vapnik, V. 1998. Statistical Learning Theory. John Wiley, New York, USA, 732 pp.

24. Yoon, H., S.C. Jun, Y. Hyun, G.O. Bae and K.K. Lee. 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology*, 396: 128-138.
25. Yu, P.S., S.T. Chen and I.F. Chang. 2006. Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 328: 704-716.
26. Zounemat-Kermani, M. 2013. Hydrometeorological parameters in prediction of soil temperature by means of artificial neural network: case study in Wyoming. *Journal of Hydrologic Engineering*, 18: 707-718.
27. Zounemat-Kermani, M. 2014. Principal component analysis (PCA) for estimating chlorophyll concentration using forward and generalized regression neural networks. *Applied Artificial Intelligence*, 28: 16-29.
28. Zounemat-Kermani, M., O. Kisi and T. Rajaei. 2013. Performance of radial basis and LM-feed forward artificial neural networks for predicting daily watershed runoff. *Applied Soft Computing*, 13: 4633-4644.

## 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)

Abdollah Ramezani-Charmahineh<sup>1</sup> and Mohammad Zounemat-Kermani<sup>2</sup>

1- Graduated M.Sc. Student, Shahid Bahonar University of Kerman

2- Associate Professor, Shahid Bahonar University of Kerman, (Corresponding author: zounemat@uk.ac.ir)

Received: July 24, 2014

Accepted: April 11, 2015

### Abstract

Accurate and reliable simulation and prediction of the groundwater level variation is significant and essential in water resources management of a basin. Models such as ANNs and Support Vector Regression (SVR) have proved to be effective in modeling nonlinear function with a greater degree of accuracy. In this respect, an attempt is made to predict monthly groundwater level fluctuations using Multivariate Linear Regression, Multi-Layer Perceptron neural network models and two SVRs with RBF and linear function. In the present study, monthly data (from 2000 to 2010) of 18 observational wells in Shahrekord Plain were used for simulating and predicting the groundwater level. Regarding to NS efficiency and RMSE criteria, MLP model in 56% and SVR in 44%, have the best performance in comparison with other models. For an instance, in well No. 1, SVR-RBF using input parameters of groundwater level, temperature, evaporation and precipitation is superior to other models. General efficiency of MLP, SVR-RBF, and SVR-Linear for NS criteria is 0.703, 0.656 and 0.655, respectively; and for RMSE criteria is 0.857, 0.905 and 0.914 meter, respectively. Results indicate that MLP and SVR models give better accuracy in predicting groundwater levels in the study area when compared to the linear model.

**Keywords:** Groundwater level prediction, Multivariate regression, Perceptron neural network, Shahrekord Plain, Support Vector Regression